

Diplomarbeit

Entwicklung von Lastprognosemodellen für rein elektrisch betriebene Fahrzeuge

ausgeführt zum Zwecke der Erlangung des akademischen Grades des
Diplom-Ingenieurs unter der Leitung von

Univ.-Prov. Dr.-Ing. Wolfgang Gawlik
und

Dipl.-Ing. Markus Litzlbauer

Institut für Energiesysteme und Elektrische Antriebe

Eingereicht an der Technischen Universität Wien
Fakultät für Elektrotechnik und Informationstechnik

von

Martin Zinggl
0728066

Bergen 20, 8241 Dechantskirchen

Wien, am 18.10.2016

Kurzfassung

Durch die steigende Anzahl von elektrisch betriebenen Fahrzeugen wächst der Bedarf an elektrischer Leistung, wodurch es zu einem Anstieg der Lastspitzen im Versorgungsnetz kommt. Dies führt zu einer höheren Auslastung des Netzes sowie zu höheren Kosten, da mehr Kraftwerke benötigt werden, welche diesen erhöhten Leistungsbedarf decken.

Deshalb ist es sinnvoll, eine Laststeuerung (engl. „Demand Side Management“, kurz DSM) einzusetzen, wodurch eine Lastverschiebung und somit eine Verringerung der Lastspitzen erreicht werden kann. Für den Einsatz von DSM ist es erforderlich, dass die benötigten Energiemengen im Vorhinein bekannt sind.

In dieser Arbeit werden mit Hilfe der Software MATLAB zwei Modelle entwickelt, mit denen der Energiebedarf von privat- beziehungsweise dienstlich genutzten Elektrofahrzeugen zeitlich und energetisch prognostiziert werden kann. Die verwendeten Daten wurden von der Modellregion Köstendorf aus Salzburg und von der Firma VLOTTE, deren Sitz in Vorarlberg ist, zur Verfügung gestellt.

Die entwickelten Prognosemodelle sollen eine Vorhersage des Energiebedarfs für den aktuellen sowie den folgenden Tag ermöglichen, wobei als Schrittweite eine Stunde gewählt wird.

Zuerst werden die vorliegenden Daten analysiert. Es wird sich zeigen, dass in beiden Datenmengen Aufzeichnungsfehler vorkommen. Danach erfolgt eine Bereinigung und Aufbereitung der Daten, sodass sie als Datengrundlage zur Prognoseerstellung verwendet werden können. Im Zuge dieser Datenaufbereitung werden die geladenen Energiemengen aufsummiert, wodurch regelmäßige Verläufe ohne große Sprünge entstehen.

Die bereinigten Datenmengen dienen als Grundlage zur Untersuchung verschiedener gängiger, in der Literatur zu findender Prognoseverfahren. Dabei wird erörtert, dass nicht alle Verfahren, welche im Theorieteil dieser Arbeit besprochen werden, zur Prognose der vorhandenen Datenmengen geeignet sind. Bei der Prognose wird die Änderung der gesamten aufsummierten geladenen Energiemenge erstellt, woraufhin durch Rückrechnung der jeweilige Tages- beziehungsweise Stundenenergiewert ermittelt wird.

Im Anschluss daran werden die beiden Modelle, bei denen verschiedene Parameter wie etwa das verwendete Prognoseverfahren variiert werden können, in MATLAB implementiert und die Ergebnisse dargestellt.

Es erfolgt eine Erläuterung darüber, dass zufriedenstellende Prognosen der Energiebedarfe von ganzen Tagen aufgestellt werden können. Des Weiteren ist es möglich Stundenprognosen zu erstellen, was allerdings nur dann Ergebnisse mit geringen Fehlern liefert, wenn Fahrzeuge regelmäßig benutzt werden. Ist dies nicht der Fall, so treten in den aufsummierten geladenen Energiemengen, welche bei der Prognoseerstellung als Datengrundlage dienen, vermehrt sprunghafte, unregelmäßige Änderungen auf. Dies führt zu größeren Prognoseabweichungen und somit zu höheren Prognosefehlern.

Zum Abschluss wird die Verwendung eines Reservierungssystems in Verbindung mit dienstlich genutzten Elektrofahrzeugen erläutert. Dabei werden der prinzipielle Aufbau und die Vorteile eines solchen Systems genauer betrachtet.

Abstract

An increasing use of electronically driven vehicles has led to a rise in the demand of electricity. This has caused increased peak loads in the supply network. A higher utilization as well as higher costs are an effect of these described changes, as more power plants are needed to cover this elevated power demand.

A constructive solution for this problem is the use of demand side management (DSM). With the help of DSM, a load transfer as well as reduction in load peaks of the supply network can be achieved. In order to be able to use DSM, it is necessary to know the required energy amounts in advance.

With the help of the software MATLAB, this paper develops two models for predicting the energy demand of privately as well as officially used electronic vehicles with regard to time and energy. The used data is provided by the model region Köstendorf in Salzburg and by the company VLOTTE, which is located in Vorarlberg. The developed forecast model shall allow a prediction of the energy amount of the current as well as the following day, for which the increment is determined as an hour.

First, the provided data will be analysed. This will show that record errors exist in both datasets. After that, adjustment and preparation of the data will enable the use of the data as basis for creating a forecast. In the course of this preparation the recorded energy amounts will be added to ensure constant progressions without significant jumps.

The adjusted data will serve as basis for examining various common forecasting methods, which are also found in specialist literature. It will be explained that not all procedures discussed in the first part of this paper are suitable for prognosis in relation with the provided data.

For creating the forecast, all loaded energy amounts will be added and adjusted. In a next step, the daily as well as the hourly energy value will be identified via back-calculation. Both mentioned models, which allow a varied use of the forecasting procedure's parameters, will be implemented in MATLAB and will thus allow a depiction of outcomes.

Following that, it will be explained that the most successful forecasts of energy demands can be done for whole days. Doing forecasts on an hourly basis is possible, but only leads to outcomes with low error rates if vehicles are used regularly. If this is not the case, the data base, which are the added loaded energy amounts, tend to show irregularities and changes. This leads to higher forecasting deviations and also to higher forecasting errors. As a final step, the use of a reservation system in relation to officially used electronic vehicles will be illustrated by giving an explanation of its basic structure and its advantages.

Inhaltsverzeichnis

1	Einleitung.....	1
1.1	Motivation und Zieldefinition	1
1.2	Demand Side Management	2
1.3	Gliederung der Arbeit.....	3
2	Lastprognose	4
2.1	Grundlagen der Lastprognose.....	4
2.2	Einteilung der Lastprognose	5
2.3	Einflussparameter der Lastprognose.....	6
3	Prognoseverfahren.....	7
3.1	Verfahren	7
3.1.1	Naive Prognose	8
3.1.2	Brown Verfahren.....	9
3.1.3	Holt - Winters Verfahren.....	11
3.1.4	Die optimale Prognose.....	14
3.1.4.1	BOX - JENKINS Ansatz.....	16
3.1.4.2	Die optimale Prognose eines ARIMAX-Prozesses	18
3.1.5	Kalman-Filter	21
3.1.6	Neuronale Netze	24
3.1.7	Vergleichstagverfahren	25
3.2	Fehlerberechnung	26
3.2.1	Mean Squared Error.....	26
3.2.2	Relativer Fehler	26
4	Privat genutzte Elektrofahrzeuge	28
4.1	Einleitung.....	28
4.2	Datengrundlage privat genutzter Elektrofahrzeuge	29
4.2.1	Datenanalyse und Aufbereitung	29
4.3	Lastprognosemodell privat genutzter Elektrofahrzeuge	46
4.3.1	Analyse der Prognoseverfahren.....	46
4.3.1.1	Tagesprognosen privat genutzter Elektrofahrzeuge.....	47
4.3.1.2	Stundenprognosen privat genutzter Elektrofahrzeuge.....	59
4.3.2	Realisierung.....	64
4.3.2.1	MATLAB - Programm.....	64
4.3.3	Ergebnisse und Schlussfolgerung.....	71
5	Dienstlich genutzte Elektrofahrzeuge	74
5.1	Einleitung.....	74
5.2	Datengrundlage dienstlich genutzter Elektrofahrzeuge.....	76
5.2.1	Datenanalyse.....	77
5.2.1.1	Fahrtantritte.....	77
5.2.1.2	Ladevorgänge.....	79
5.2.1.3	Zusammenhänge zwischen Fahrtantritten und Ladebeginnen.....	85

5.2.2	Datenaufbereitung	85
5.3	Lastprognosemodell dienstlich genutzer Elektrofahrzeuge	95
5.3.1	Analyse der Prognoseverfahren	95
5.3.1.1	Tagesprognosen dienstlich genutzter Elektrofahrzeuge	95
5.3.1.2	Stundenprognosen dienstlich genutzer Elektrofahrzeuge	100
5.3.2	Realisierung	104
5.3.2.1	MATLAB - Programm	104
5.3.3	Ergebnisse und Schlussfolgerung	110
5.4	Fiktives Reservierungssystem	114
6	Zusammenfassung	116
	Literaturverzeichnis	120
	Abkürzungsverzeichnis	122
	Abbildungsverzeichnis	123
	Tabellenverzeichnis	125

1 Einleitung

Im ersten Kapitel wird auf die Inhalte dieser Arbeit eingegangen, wobei zuerst über den Sinn und Zweck von Lastprognosemodellen in Zusammenhang mit rein elektrisch betriebenen Fahrzeugen und über die Zieldefinition dieser Arbeit gesprochen wird. Dabei werden der prinzipielle Hintergedanke von Lastprognosemodellen sowie die Vorteile von solchen Modellen erörtert.

Im nächsten Abschnitt wird der Begriff „Demand Side Management“ erläutert. Hierbei handelt es sich um eine Laststeuerung mit welcher eine Verringerung der Lastspitzen und somit eine Kostensenkung erreicht werden kann.

Zum Abschluss erfolgt eine Erörterung der Gliederung der Arbeit.

1.1 Motivation und Zieldefinition

Das Ziel dieser Arbeit ist die Erstellung von zwei Modellen zur zeitlichen und energetischen Prognose von Elektrofahrzeugen, wobei eine Vorhersage des Energiebedarfs mit einem Prognosehorizont von einem Tag und einer Schrittweite von einer Stunde erstellt werden soll.

Die steigende Anzahl von regenerativen Energieerzeugern, welche eine volatile Einspeisung aufweisen, führt dazu, dass immer mehr Kraftwerke zur Lieferung der Ausgleichsenergien in Spitzenlastzeiten benötigt werden. Da diese Kraftwerke nur in den Spitzenlastzeiten benötigt werden, müssen sie öfters hoch- beziehungsweise heruntergefahren werden, was zu zusätzlichen Kosten führt.

Mithilfe der im Zuge dieser Arbeit ermittelten Energieprognosen soll der Einsatz einer Laststeuerung ermöglicht werden, wodurch das Laden der E-Fahrzeuge in Spitzenlastzeiten verhindert werden kann. Durch diese Laststeuerung lassen sich die Ladevorgänge dorthin verschieben, wo weniger Energie durch andere Verbraucher benötigt wird, wodurch ein gleichmäßiger Lastgang mit geringeren Lastspitzen erreicht wird.

Weiters können die Ladevorgänge bei Besitz einer eigenen Photovoltaikanlage dann durchgeführt werden, wenn die Energie eigens produziert wird und somit nicht zugekauft werden muss.

Die Laststeuerung führt zu einer Entlastung des Versorgungsnetzes, zu einer Verminderung der Anzahl der benötigten Kraftwerke und dadurch zu einer Kostensenkung. (vgl. DSM, Kapitel 1.2)

Die beiden im Zuge dieser Arbeit zu erstellenden Modelle sollen zur Energieprognose für privat-beziehungsweise dienstlich genutzte Elektrofahrzeuge dienen.

Die Daten, welche zur Entwicklung der beiden Modelle verwendet werden, wurden von der Modellregion Köstendorf aus Salzburg sowie von der Firma VLOTTE aus Vorarlberg zur Verfügung gestellt. Dabei wurden in beiden Datenmengen die Ladeleistungen sowie die Ladezeiten protokolliert. Eine genaue Analyse und Charakterisierung der beiden Datenmengen erfolgt in den jeweiligen Kapiteln. (Kapitel 4, Kapitel 5)

Zum Abschluss der Arbeit wird auf die Verwendung eines Reservierungssystems in Verbindung mit dienstlich genutzten Elektrofahrzeugen eingegangen. Damit kann ermöglicht werden, dass die Elektrofahrzeuge eines Fahrzeugfuhrparks in Abhängigkeit der zurückzulegenden Fahrtstrecke an die MitarbeiterInnen zugeteilt werden. Dabei werden Fahrzeuge mit einem hohen Ladestand für längere Fahrtstrecken und solche mit einem geringen Ladestand für kurze Strecken verwendet. Dies hat den Vorteil, dass die Ladevorgänge in Spitzenlastzeiten verringert werden können.

1.2 Demand Side Management

Aufgrund der steigenden Anzahl erneuerbarer Energieerzeuger ist ein Ausbau des Stromnetzes sowie der Bau von Energiespeichern erforderlich. Um dies zu verhindern ist es sinnvoll, eine Laststeuerung („Demand Side Management“, kurz DSM) einzusetzen, wodurch eine Lastverschiebung erreicht werden kann. Dies führt zu einer Verringerung der Lastspitzen, was den Vorteil bringt, dass die Anzahl der benötigten Kraftwerke sowie der Ausbaubedarf des Versorgungsnetzes gesenkt werden kann. [10]

Laut [10] handelt es sich bei aDSM („aktives Demand Side Management“) um eine Weiterentwicklung von DSM. Dadurch soll man flexible elektrische Lastgänge erhalten, die der oftmals volatilen elektrischen Einspeisung regenerativer Erzeuger folgen.

Um aDSM einsetzen zu können, ist es erforderlich, dass die benötigte Energiemenge im Vorhinein bekannt ist. Dazu wird die Lastprognose eingesetzt, bei der zukünftige Werte mit Hilfe von Vergangenheitsinformationen prognostiziert werden.

Mithilfe von aDSM wird zum Beispiel geregelt, dass Warmwasserspeicher nur dann aufgeheizt oder Elektrofahrzeuge nur dann ganz geladen werden, wenn genug Energie verfügbar ist.

Diese Lastverschiebungen führen zu einer Verringerung der Lastspitzen und somit zu einer Senkung der Kosten.

1.3 Gliederung der Arbeit

Die Arbeit ist in sechs Kapiteln gegliedert. Im Ersten wird auf die Motivation dieser Arbeit und die Zieldefinition eingegangen. Weiters werden der Begriff „Demand Side Management“ sowie die Gliederung der Arbeit besprochen.

Im zweiten Kapitel folgt die Thematik der Lastprognose, wobei eine Erörterung der Grundlagen, der Einteilung sowie der Einflussparameter durchgeführt wird.

Kapitel 3, welches den Theorieteil dieser Arbeit abrundet, befasst sich mit verschiedenen gängigen, in der Literatur zu findenden, Prognoseverfahren. Am Ende des Kapitels werden Bewertungskriterien zur Überprüfung der Qualität von Prognoseverfahren erläutert.

Im nächsten Kapitel erfolgt die Erstellung des Prognosemodells für privat genutzte Elektrofahrzeuge. Dabei werden zuerst die von der Modellregion Köstendorf zur Verfügung gestellten Daten untersucht und aufbereitet. Im Anschluss daran wird das Lastprognosemodell erstellt, wobei zuerst auf die Prognoseverfahren und anschließend auf die Realisierung in MATLAB eingegangen wird. Zum Abschluss werden die Ergebnisse dargestellt sowie die Vor- und Nachteile des entwickelten Modells erörtert.

In Kapitel 5 wird ein Modell für dienstlich genutzte Elektrofahrzeuge entwickelt. Dabei werden wiederum die Daten, welche von der Firma VLOTTE stammen, analysiert und aufbereitet. Anschließend folgen ebenfalls die Modellerstellung, die Implementierung in MATLAB sowie ein kurzes Resümee über das erstellte Modell.

Am Ende des Kapitels werden die Vor- und Nachteile bei der Verwendung eines Reservierungssystems in Zusammenhang mit dienstlich genutzten Elektrofahrzeugen untersucht, woraufhin eine kurze Erläuterung der Implementierungsmöglichkeiten eines solchen Systems durchgeführt wird.

Das letzte Kapitel, die Zusammenfassung, dient dazu, einen Überblick über diese Arbeit zu liefern. Dabei werden die einzelnen Kapitel und deren Ergebnisse besprochen.

2 Lastprognose

Kapitel 2 befasst sich mit der Thematik der Lastprognose, wobei zuerst die Grundlagenbesprechung durchgeführt wird. Dabei erfolgt eine Erläuterung über die Bedeutung und die Einsatzgebiete der Lastprognose. Im nächsten Abschnitt wird erörtert, dass sich die Lastprognose in verschiedene Gruppen mit unterschiedlichem Zeithorizont einteilen lässt. Zum Abschluss werden einige Einflussparameter, welche für das Prognoseergebnis mitverantwortlich sind, beschrieben.

2.1 Grundlagen der Lastprognose

Laut [1] versteht man unter einer Prognose die Vorhersage von zukünftigen Ereignissen aufgrund der Vergangenheit. Dabei wird einem beobachteten Prozess ein Modell unterstellt, mit dessen Hilfe die Prognoseerstellung erfolgt. Ändert sich der Prozess, sodass das Modell nicht mehr zutrifft, verliert die Prognose ihre Gültigkeit und das Modell muss neu angepasst werden.

In Kapitel 1.2 wurde erwähnt, dass für den Einsatz von aDSM die Kenntnis der benötigten Energiemenge im Vorhinein bekannt sein muss. Dazu setzt man die Lastprognose ein, bei der zukünftige Werte mit Hilfe von Vergangenheitsinformation vorhergesagt werden.

Laut [12] wird der Strombedarf von tages- und jahreszeitlichen Schwankungen beeinflusst, weshalb eine möglichst genaue Vorhersage des Energieverbrauchs erforderlich ist. In [8] unterscheidet man zwischen Ultrakurz-, Kurz-, Mittel- und Langfristprognosen. Eine genaue Charakterisierung dazu folgt im nächsten Abschnitt.

Mit Hilfe der Lastprognosen werden Energiefahrpläne erstellt, welche den Energieverbrauch des Stromnetzes vorhersagen. Dies ist notwendig um ausreichend Energie bereitstellen zu können, was durch Regelung von Kraftwerken oder durch das Handeln mit Strom erreicht wird. [12]

In Zuge dieser Diplomarbeit werden die benötigten Energiemengen für Elektrofahrzeuge prognostiziert. Durch diese Vorhersagen soll das Laden von E-Fahrzeugen in Spitzenlastzeiten verhindert werden.

2.2 Einteilung der Lastprognose

Im letzten Abschnitt wurde bereits erwähnt, dass bei der Lastprognose zwischen Ultrakurz-, Kurz-, Mittel- und Langfristprognosen unterschieden wird. [8]

Bei **Ultrakurzfristprognosen** handelt es sich um Vorhersagen im Sekunden- bis Minutenbereich. Sie dienen zur Prognose bei der Regelung von Ausgleichsenergie. Dies kann durch Hoch- bzw. Herunterfahren von Kraftwerken oder durch Zu- bzw. Verkauf von Strom an der Strombörse erreicht werden. Aufgrund der steigenden Anzahl von regenerativen Stromerzeugern, welche eine volatile elektrische Einspeisung aufweisen, nimmt die Bedeutung dieser Prognoseart immer mehr zu.

Kurzfristprognosen weisen einen Zeithorizont von einigen Stunden bis hin zu einer Woche auf. Sie dienen für den Handel auf den Spotmärkten. Auf Spotmärkten wird Strom gehandelt, dessen Lieferung am nächsten Tag erfolgt. [13]

Im Zuge dieser Arbeit wird die Kurzfristprognose verwendet, um den Energiebedarf von E-Fahrzeugen zu prognostizieren. Kann man die benötigte Energie für den nächsten Tag vorhersagen, so ist es möglich, ein E-Fahrzeug in der Nacht nur so voll zu laden, dass der Ladezustand für die zu bewältigende Strecke ausreicht. Würde man das Elektrofahrzeug bei jedem Ladevorgang vollständig laden, so müsste mehr Strom zugekauft werden.

Der Einsatz einer Lastprognose führt zu einer Entlastung des Versorgungsnetzes, einer Reduzierung der zur Energieerzeugung eingesetzten Kraftwerke und somit zu einer Kostensenkung. Außerdem kann durch eine geschickte Ladesteuerung erreicht werden, dass die Energie zum Beispiel durch eine hauseigene Photovoltaikanlage selbst produziert wird. Dies wirkt sich wiederum auf die obig genannten Punkte aus.

Die **Mittelfristprognosen**, welche sich in einem Zeitraum von mehreren Wochen bis hin zu mehreren Jahren abspielen, werden hauptsächlich zum Handeln auf Terminmärkten eingesetzt. Laut [13] ist der Terminmarkt ein Marktsegment des Strommarktes für den Handel von längerfristigen Terminkontrakten. Dabei können die Lieferzeiträume einige Kalenderwochen bis hin zu sechs Jahren betragen.

Mit **Langfristprognosen**, für die umfassende Informationsmengen notwendig sind, werden Prognosen im Zeitbereich von Jahren bis hin zu Jahrzehnten aufgestellt. Sie dienen zum Treffen

von Investitionsentscheidungen wie zum Beispiel dem Aus- bzw. Neubau von Kraftwerken, dem Stromnetzausbau oder dem Ausbau der Ladeinfrastruktur.

2.3 Einflussparameter der Lastprognose

Der Energieverbrauch von Elektrofahrzeugen ist von verschiedenen Einflussparametern abhängig. Im folgenden Abschnitt werden die wichtigsten Größen genauer erläutert.

Einen Einflussparameter stellt das **Wetter** dar. Es ist davon auszugehen, dass bei niedrigen bzw. hohen Temperaturen mit einem höheren Energieverbrauch zu rechnen ist. Grund dafür ist die zusätzlich benötigte Energie, welche für die Heizung bzw. die Klimaanlage erforderlich ist. Außerdem ist beim Fahren bei Gegenwind mit einem höheren Verbrauch als bei Rückenwind zu rechnen, da ein erhöhter Kraftaufwand erforderlich ist.

Eine weitere relevante Größe stellen die **jahreszeitlichen Schwankungen** dar. Hierbei handelt es sich um saisonale Änderungen des Energieverbrauchs, was auf die unterschiedlichen Jahreszeiten zurückzuführen ist. Dabei kann man annehmen, dass im Winter bzw. im Sommer mehr Energie verbraucht wird, was wiederum auf den höheren Energieverbrauch aufgrund des Heizens beziehungsweise des Kühlens zurückgeführt werden kann.

Bei **wöchentlichen Schwankungen** muss zwischen den unterschiedlichen Tagen differenziert werden. An den Wochenenden wird ein anderes Fahrverhalten und somit ein anderer Energieverbrauch als an den Arbeitstagen zu beobachten sein. Des Weiteren unterscheidet sich der Verbrauch an Montagen und Freitagen aufgrund von Wochenpendlern, die zum Arbeiten in eine Stadt fahren und dort wohnen, von den anderen drei Arbeitstagen.

Neben den Jahres- und Wochenschwankungen treten **tageszeitliche Schwankungen** auf, was sich zum Beispiel durch den Berufsverkehr an Arbeitstagen erklären lässt. Hier ist morgens, mittags und abends mit einem erhöhten Energieverbrauch zu rechnen.

Zusätzlich zu den vorher genannten Einflussparametern wird langfristig ein **Trend** zu erkennen sein. Dies liegt daran, da sich aufgrund von Forschungen und Weiterentwicklungen im Sektor der

Elektromobilität Effizienzverbesserungen einstellen werden. Dadurch kann eine Abnahme der benötigten Energiemenge pro zurückgelegtem Kilometer erwartet werden.

Ein weiterer wichtiger Einflussparameter ist die Art der **Fahrtstrecke**. Der Energieverbrauch pro zurückgelegtem Kilometer ist auf einer Autobahn geringer als jener im Stadtverkehr.

3 Prognoseverfahren

Im folgenden Abschnitt wird zuerst die Thematik verschiedener gängiger, in der Literatur zu findender Prognoseverfahren erläutert. Im Anschluss folgt die Beschreibung zweier Qualitätsmerkmale, welche für den Vergleich der Ergebnisse der verschiedenen Verfahren verwendet werden können.

Die Auswahl der verwendeten Prognoseverfahren für privat- und dienstlich genutzte Elektrofahrzeuge wird in den entsprechenden Kapiteln 4 und 5 durchgeführt.

3.1 Verfahren

Die in diesem Kapitel untersuchten Prognoseverfahren finden bei der Prognose von Zeitreihen Verwendung. Laut [2] wird unter einer Zeitreihe eine Folge von Beobachtungen, die zu verschiedenen Zeitpunkten aufgezeichnet wurden, verstanden. Die Reihenfolge der beobachteten Werte ist nicht beliebig, was daran liegt, dass bei der Ermittlung der Werte nicht davon ausgegangen werden kann, dass die gleichen Voraussetzungen herrschen.

Bei der Prognoseerstellung wird versucht, aus den bisherigen Werten einer Zeitreihe die zukünftigen vorausszusagen. Dadurch soll zum Beispiel an der Börse der Kauf oder Verkauf von Aktien zum optimalen Zeitpunkt ermöglicht werden. [2]

Im Zuge der vorliegenden Arbeit erfolgt eine Untersuchung des Einsatzes von gängigen Prognoseverfahren im Sektor der Elektromobilität. Dabei soll der Energiebedarf von Elektrofahrzeugen prognostiziert werden, wodurch die Elektrofahrzeuge nicht immer vollständig geladen werden müssen. Das Ziel dieser Prognoseerstellung ist, dass die Ladevorgänge der E-Fahrzeuge hauptsächlich dann stattfinden, wenn ausreichend Strom vorhanden ist. Dieser kann etwa durch eine hauseigene Photovoltaikanlage produziert werden. Dadurch erspart man sich das

Zukaufen von Strom, wodurch es zu einer Kostensenkung und zu einer Entlastung des Stromversorgungsnetzes kommt. (vgl. Kapitel 1.2)

In Kapitel 4 bzw. 5 wird sich zeigen, dass die zu prognostizierenden Daten starken Schwankungen unterliegen. Deshalb werden sie dahingehend aufbereitet, dass eine Prognoseerstellung mithilfe der im Anschluss diskutierten Prognoseverfahren möglich ist.

Im folgenden Teil der Arbeit werden die Grundlagen, die Anwendungsgebiete sowie die Vor- und Nachteile gängiger Verfahren genauer besprochen.

3.1.1 Naive Prognose

Laut [9] handelt es sich bei der naiven Prognose um die einfachste aller Prognosearten, wobei man zwischen der No-Change-Prognose und der Same-Change-Prognose unterscheidet. Bei der Prognoseerstellung werden zukünftige Werte mit einfachen Rechenarten bestimmt.

Bei der No-Change-Prognose wird der aktuelle Wert als Prognosewert verwendet. Dabei wird davon ausgegangen, dass keine großen Veränderungen der Werte zwischen verschiedenen Beobachtungszeitpunkten auftreten. Aufgrund der Nichtberücksichtigung des Trends ist diese Prognoseart nicht für die Vorhersage des Energiebedarfs von Elektrofahrzeugen geeignet. Eine genauere Erörterung dazu erfolgt in Kapitel 4.3.1.1.

Die Same-Change-Prognose verwendet den aktuellen Wert in Kombination mit dem letzten Trend zur Prognoseerstellung. Aufgrund der Einbeziehung des letzten Trends wird vorausgesetzt, dass es sich um eine langfristige Entwicklung handelt. Da nur der letzte Trend Berücksichtigung findet, werden einmalige Schwankungen stark berücksichtigt. Dies kann bei der Vorhersage des Energiebedarfs von Elektrofahrzeugen dazu führen, dass Tage, an denen viel mehr Energie benötigt wird als dies an den meisten anderen Tagen der Fall ist, die Prognoseergebnisse verfälschen. Dadurch können sich höhere Prognosefehler ergeben.

Die naive Prognose lässt sich durch folgende Formeln bestimmen:

$$\text{No – Change – Prognose:} \quad f_{t+1} = f_t \quad (3.1)$$

$$\text{Same – Change – Prognose: } f_{t+1} = f_t + (f_t - f_{t-1}) \quad (3.2)$$

f_taktueller Wert

f_{t+1}zu prognostizierender Wert

f_{t-1}letzter Wert

Die Hauptanwendung für die naive Prognose ist die Beurteilung der Qualität von aufwendigeren Prognoseverfahren. Dabei wird untersucht ob der Mehraufwand eines komplizierteren Verfahrens ein besseres Ergebnis liefert als die einfache naive Prognose.

3.1.2 Brown Verfahren

Laut [14] wurde das Verfahren von Brown entwickelt, indem er zwei Überlegungen kombinierte:

- Das Gewicht der Zeitreihenwerte für die Prognose soll mit zunehmendem „Alter“ der Werte abnehmen.
- Der Prognosefehler (e_t) der Gegenwart wird bei den folgenden Prognosen berücksichtigt.

Brown hat aus diesen beiden Überlegungen das Verfahren der exponentiellen Glättung abgeleitet. Der Name exponentielle Glättung bezieht sich auf die Struktur der Gewichtung der Zeitreihenwerte. Eine Erläuterung dazu folgt später in diesem Kapitel.

Der Prognosewert für den nächsten Wert x_{t+1} wird nach folgender Formel berechnet.

$$\hat{x}_{t+1} = \hat{x}_t + \alpha e_t = \hat{x}_t + \alpha(x_t - \hat{x}_t) \quad (3.3)$$

x_t Wert zum Zeitpunkt t

$\hat{x}_t$ Prognosewert für x_t zum Zeitpunkt $t-1$

$\hat{x}_{t+1}$ Prognosewert für x_{t+1} zum Zeitpunkt t

α Glättungsparameter, mit $0 < \alpha \leq 1$

e_t Prognosefehler zum Gegenwartszeitpunkt t

Durch Umformung von Formel 3.3 erhält man die Formel der exponentiellen Glättung.

$$\hat{x}_{t+1} = \alpha x_t + (1 - \alpha)\hat{x}_t \quad (3.4)$$

Nach Formel 3.4 wird für die Bestimmung des Prognosewertes der vorhergehende Prognosewert, der letzte Zeitreihenwert und der Glättungsparameter α benötigt. Die Prognose liefert eine Schätzung für den auf x_t folgenden Wert x_{t+1} .

Der Glättungsparameter α ist aus den vorhandenen Werten der Zeitreihe zu bestimmen, indem die Summe der quadrierten Prognosefehler (engl. mean squared error, *MSE*) minimiert wird [2]. Dazu wird α solange im Bereich zwischen $0 < \alpha \leq 1$ variiert bis der Fehler sein Minimum erreicht hat. Der Glättungsparameter legt die Gewichte der einzelnen Zeitreihenwerte fest. [14] Dabei gewichtet ein großer Wert für α den letzten Zeitreihenwert gegenüber den früheren Werten sehr stark. Umgekehrt werden frühere Werte bei einem kleinen α höher gewichtet als der letzte Zeitreihenwert.

Laut [14] ist es nicht möglich ein optimales α für die Prognose einer Zeitreihe festzulegen. Deshalb ist es sinnvoll α dynamisch zu ändern und an die Entwicklung der Zeitreihe anzupassen.

Im Folgenden wird die Herkunft des Namens dieses Verfahrens erläutert.

Schreibt man Formel 3.4 für die Zeitpunkte $t-1$ und $t-2$, so erhält man:

$$\hat{x}_t = \alpha x_{t-1} + (1 - \alpha)\hat{x}_{t-1} \quad (3.5)$$

$$\hat{x}_{t-1} = \alpha x_{t-2} + (1 - \alpha)\hat{x}_{t-2} \quad (3.6)$$

Das Einsetzen von Formel 3.5 in Formel 3.4 ergibt die nachfolgende Gleichung.

$$\hat{x}_{t+1} = \alpha x_t + (1 - \alpha)(\alpha x_{t-1} + (1 - \alpha)\hat{x}_{t-1}) \quad (3.7)$$

Gleichung 3.6 und 3.7 ergeben zusammen:

$$\hat{x}_{t+1} = \alpha x_t + \alpha(1 - \alpha)x_{t-1} + \alpha(1 - \alpha)^2 x_{t-2} + (1 - \alpha)^3 \hat{x}_{t-2} \quad (3.8)$$

Blickt man auf die Struktur von Formel 3.8, so kann man eine exponentielle Abnahme der Gewichte mit zunehmendem Alter feststellen. Aufgrund dessen heißt dieses Verfahren exponentielle Glättung.

Die wesentlichen Vorteile dieses Verfahrens sind einerseits die formale Einfachheit und andererseits der geringe Speicherplatzbedarf, weshalb es insbesondere im ökonomischen Bereich Verwendung findet, wenn hunderte von Zeitreihen zugleich prognostiziert werden müssen und auf eine Modellierung verzichtet werden kann. Der Nachteil liegt darin, dass bei Reihen ohne systematische Änderungen der Mittelwert prognostiziert wird, was zu unbrauchbaren Ergebnissen führt. Verantwortlich hierfür ist das einfache Modell, welches der Berechnung zugrunde liegt. Außerdem werden nur geringe Abweichungen vom letzten beobachteten Wert prognostiziert, was sich in einer Phasenverschiebung zwischen Prognosewerten und beobachteten Werten widerspiegelt. In Kapitel vier wird sich zeigen, dass dieses Verfahren nicht für die Prognose der Zeitreihen, welche im Zuge dieser Arbeit untersucht werden, geeignet ist.

3.1.3 Holt - Winters Verfahren

Laut [1] haben Holt und Winters das exponentielle Glätten von Brown so verändert, dass Prognosen von Zeitreihen ohne systematische Änderungen möglich sind. Außerdem können Prognosen von Zeitreihen erstellt werden, die einen Trend- und einen Saisonanteil beinhalten.

Die Grundlage dieses Verfahrens bildet ein additives Komponentenmodell, welches sich aus einer Trend-, einer Saison- und einer Restkomponente zusammensetzt.

$$x_t = m_t + s_t + \varepsilon_t \quad (3.9)$$

x_t Zeitreihenwert zum Zeitpunkt t

m_t Trendkomponente

s_t Saisonkomponente

ε_t Restkomponente

Hierbei wird für m_t ein linearer Trend $m_t = a + bt$ angenommen. Dabei steht a für das Niveau und b für die Steigung des Trends. Unter dem Niveau wird der Ordinatenabschnitt, der Abstand auf der y-Achse, verstanden. Die Saisonkomponente beinhaltet die jahreszeitlich bedingten

Schwankungen und die Restkomponente fasst die nicht zu erklärenden Einflüsse beziehungsweise Störungen zusammen.

Am Beginn der Prognose werden die Schätzungen für die Trendkomponente m_t , den Anstieg b und die Saisonkomponente s_t gebildet. Die Schätzung für das Niveau der Zeitreihe wird durch die Rekursionsbeziehung 3.10 berechnet. [1]

$$\hat{m}_N = (1 - \alpha)x_N + (\hat{m}_{N-1} + \hat{b}_N) \quad (3.10)$$

$\hat{b}_N$ Schätzwert für den Anstieg zum Zeitpunkt N

$\hat{m}_N$ Schätzwert für das Niveau zum Zeitpunkt N

$\hat{m}_{N-1}$ Schätzwert für das Niveau zum Zeitpunkt $N-1$

x_N Zeitreihenwert zum Zeitpunkt N

α Glättungsparameter für das Niveau, mit $0 < \alpha \leq 1$

Laut [1] erfolgt eine rekursive Fortschreibung der Schätzung $\hat{b}_N$ für den Steigungsfaktor b . Dabei erhält man wegen

$$b = m_{t-1} - m_{t-2} \quad (3.11)$$

m_{t-1} Niveau zum Zeitpunkt $t-1$

m_{t-2} Niveau zum Zeitpunkt $t-2$

die nachfolgende Aufdatierungsformel.

$$\hat{b}_N = (1 - \beta)(\hat{m}_{N-1} - \hat{m}_{N-2}) + \beta\hat{b}_{N-1} \quad (3.12)$$

$\hat{b}_N$ Schätzwert für den Anstieg zum Zeitpunkt N

$\hat{b}_{N-1}$ Schätzwert für den Anstieg zum Zeitpunkt $N-1$

$\hat{m}_{N-1}$ Schätzwert für das Niveau zum Zeitpunkt $N-1$

$\hat{m}_{N-2}$ Schätzwert für das Niveau zum Zeitpunkt $N-2$

β Glättungsparameter für den Trend, mit $0 < \alpha \leq 1$

Bei Zeitreihen, welche keine Saisonkomponente beinhalten, lassen sich die h -Schritt-Prognosen für das Holt-Winters-Verfahren mithilfe der nachfolgenden Formel bestimmen. Unter der h -Schritt-Prognose wird die Vorhersage mit dem Prognosehorizont h verstanden.

$$\hat{x}_{N,h} = \hat{m}_N + h\hat{b}_N \quad (3.13)$$

$\hat{x}_{N,h}$ Schätzwert zum Zeitpunkt N mit dem Prognosehorizont h

h Prognosehorizont

Unterliegt die Zeitreihe dem Einfluss einer Saisonkomponente, so muss für diese eine geeignete Rekursionformel verwendet werden. Weiters muss die Schätzung für das Niveau angepasst werden. Aufgrund von $x_t = m_t + s_t$ führt dies zu den beiden nachfolgenden Gleichungen.

$$\hat{m}_N = (1 - \alpha)(x_N - \hat{s}_{N-s}) + \alpha(\hat{m}_{N-1} + \hat{b}_N) \quad (3.14)$$

$$\hat{s}_N = (1 - \delta)(x_N - \hat{m}_N) + \delta\hat{s}_{N-s} \quad (3.15)$$

$\hat{s}_N$ Schätzwert für die Saisonkomponente zum Zeitpunkt N

s Saisonperiode

$\hat{s}_{N-s}$ Schätzwert für die Saisonkomponente zum Zeitpunkt $N-s$

δ Glättungsparameter für die Saisonalität, mit $0 < \alpha \leq 1$

Die Glättungsparameter α, β und δ werden wie beim Verfahren von Brown bestimmt, indem die Summe der quadratischen Prognosefehler minimiert wird. Dabei werden die drei Parameter zwischen $0 < \alpha, \beta, \delta \leq 1$ variiert bis der Fehler sein Minimum erreicht.

Mithilfe der drei Rekursionsgleichungen 3.12, 3.14 und 3.15 ergibt sich für die h -Schritt-Prognose folgende Funktion:

$$\hat{x}_{N,h} = \hat{m}_N + h\hat{b}_N + \hat{s}_{N+h-s} \quad \text{mit } h = 1, \dots, s \quad (3.16)$$

Um die Startwerte bestimmen zu können, müssen mindestens $s = \max(h)$ Beobachtungen vorliegen. Mögliche Startwerte ergeben sich zu:

$$\hat{m}_s = \hat{x}_s = \frac{1}{s} \sum_{t=1}^s x_t \quad (3.17)$$

$$\hat{s}_t = x_t - \hat{x}_t \quad \text{mit} \quad t = 1, \dots, s \quad (3.18)$$

$$\hat{b}_s = 0 \quad (3.19)$$

x_t Zeitreihenwert zum Zeitpunkt t

$\hat{m}_s = \hat{x}_s$ Startwert für das Niveau m

$\hat{s}_t$ Startwert für den Saisonfaktor s

$\hat{b}_s$ Startwert für den Anstieg b

Formel 3.17 besagt, dass das Niveau m gleich dem arithmetischen Mittel aller bisherigen Beobachtungen ist, 3.18 definiert die Saison s als die Differenz zwischen realem Wert und Geschätztem und 3.19 ist dadurch zu begründen, dass am Anfang kein Trend vorliegt.

Die Vorteile des Verfahrens von Holt und Winters sind, wie beim Verfahren von Brown, die Einfachheit und der geringe Speicherplatzbedarf. Weiters können beim Holt-Winters-Verfahren auch Reihen ohne systematische Änderungen prognostiziert werden. In den Kapiteln 4 und 5 wird zu sehen sein, dass der Datenaufzeichnungszeitraum zu kurz für die Bestimmung einer Saisonkomponente ist. Deshalb setzt sich die Prognose aus einer Trend- und einer Restkomponente zusammen.

3.1.4 Die optimale Prognose

In [1] wird die optimale Prognose als eine auf einer Zeitreihe (x_t) basierenden Schätzung $\hat{x}_{N,h}$ des Wertes X_{N+h} beschrieben. Dabei ist zu beachten, dass es sich bei $(x_t)_{t=1,\dots,N}$ um einen Ausschnitt einer Realisierung eines stochastischen Prozesses $(X_t)_{t \in \mathbb{Z}}$ handelt. Unter einem stochastischen Prozess versteht man die mathematische Beschreibung von zufälligen, zeitlich geordneten Vorgängen [1].

Mit den im Vorhinein getroffenen Annahmen lässt sich die Prognose als eine Realisation $\hat{x}_{N,h}$ der Prognosefunktion $\hat{X}_{N,h}$ darstellen.

$$\hat{X}_{N,h} = \hat{X}_{N,h}(X_1, X_2, \dots, X_N) \quad (3.20)$$

Dabei ist $\hat{X}_{N,h}$ eine Zufallsvariable mit dem Prognosehorizont h , welche von den jeweiligen Realisierungen $x_1, x_2, \dots, x_N$ der Zufallsvariablen $X_1, X_2, \dots, X_N$ abhängt.

Als Gütemaß wird die mittlere quadratische Abweichung (engl. mean squared error, *MSE*) verwendet.

$$MSE[\hat{X}_{N,h}] = E[(X_{N+h} - \hat{X}_{N,h})^2] \quad (3.21)$$

Die Prognose ist optimal, wenn die mittlere quadratische Abweichung (*MSE*) minimal ist.

Laut [1] handelt es sich bei der optimalen Prognose von X_{N+h} durch eine Funktion $\hat{X}_{N,h}$ um den bedingten Erwartungswert.

$$\hat{X}_{N,h}(X_1, X_2, \dots, X_N) = E[X_{N+h} | X_1, X_2, \dots, X_N] \quad (3.22)$$

Die optimale Prognose liefert jenen Wert, der aufgrund der realisierten Zufallsvariablen X_t zu erwarten ist.

Die optimale Lösung für nichtlineare Prognosefunktionen ist meistens sehr schwierig, da für die Berechnung der bedingten Erwartungswerte die gemeinsame Verteilung der Prozessvariablen bekannt sein muss. Deshalb beschränkt man sich in der Praxis auf lineare Prognosefunktionen, das heißt auf Prognosefunktionen mit der folgenden Gestalt:

$$\hat{X}_{N,h}(X_1, X_2, \dots, X_N) = a_{N-1}X_1 + a_{N-2}X_2 + \dots + a_0X_N \quad (3.23)$$

Gleichung 3.23 besteht aus einer Linearkombination vergangener Zufallsvariablen, wobei die Gewichte $a_0, \dots, a_{N-1}$ so zu bestimmen sind, dass der *MSE* minimal ist. In Kapitel 3.1.4.2 wird ein Anwendungsfall der optimalen Prognose erläutert.

3.1.4.1 BOX - JENKINS Ansatz

Nach [1] haben Box und Jenkins einen Ansatz entwickelt, der zu einer gegebenen Zeitreihe eine Modellschätzung durchführt. Diese Schätzung liefert einen **ARIMA[p, d, q]-Prozess**. Bei einem solchen Prozess handelt es sich um einen **Autoregressiven-Integrierten-Moving-Average Prozess**. Dieser setzt sich aus einem **Moving-Average Prozess**, kurz **MA[q]-Prozess**, und aus einem **Autoregressiven-Integrierten Prozess**, kurz **AR[p]-Prozess** zusammen, welche mit einem **Integralanteil** überlagert sind. Eine genauere Spezifikation der einzelnen Prozesse erfolgt im nächsten Kapitel.

Bei p, q und d handelt es sich um Ordnungszahlen, welche die beiden Teilprozesse und den Integralanteil charakterisieren. Ein hoher Wert von p beziehungsweise q drückt aus, dass der Prognosewert von vielen vergangenen Werten abhängig ist. Beträgt der Wert dieser Ordnungen eins, so werden nur die letzten Werte zur Prognoseerstellung verwendet.

Der Wert von d beschreibt die Ordnung des Integralanteils. Bei einem Wert von d = 1 liegt ein linearer Trend vor. Aufgrund dieses Trends handelt es sich um einen nicht-stationären stochastischen Prozess. Laut [1] ist der Erwartungswert eines nicht-stationären Prozesses nicht zu allen Zeitpunkten konstant.

Der Box-Jenkins Ansatz wird dazu verwendet, um in der sogenannten Modellspezifikation die Ordnungen p und q des Prozesses zu bestimmen. Da dieser Ansatz nur für stationäre stochastische Prozesse geeignet ist, müssen nicht-stationäre stochastische Prozesse durch Differenzenbildung in stationären Prozess umgewandelt werden. Dabei drückt die Ordnung d aus, wie oft differenziert werden muss.

Im nachfolgenden Abschnitt wird nun die Vorgehensweise bei der Modellspezifikation mithilfe des Box-Jenkins Ansatzes erläutert. Laut [1] erfolgt im ersten Schritt eine Überprüfung, ob es sich um einen nicht-stationären stochastischen Prozess handelt. Ist dies der Fall, so wird dieser durch Differenzenbildung in einen stationären stochastischen Prozess überführt. Nach dieser Umwandlung liegt ein ARMA[p, q]-Prozess vor, da der Integralanteil eliminiert wurde. Im nächsten Schritt ist nun die Ordnung [p, q] dieses Prozesses zu bestimmen. Laut Box und Jenkins sind dafür die zwei folgenden Funktionen der vorliegenden Zeitreihe zu berechnen:

1. Autokorrelationsfunktion ($\hat{\rho}_\tau$), kurz *ACF*
2. partielle Autokorrelationsfunktion ($\hat{\pi}_\tau$), kurz *PACF*

Laut [1] beschreibt die Autokorrelationsfunktion ($\hat{\rho}_\tau$), wie stark die Korrelation zweier Zufallsvariablen X_t und $X_{t-\tau}$ ist, die im Abstand von τ zueinander liegen. Mithilfe der Korrelation wird die Beziehung zwischen den beiden Zufallsvariablen beschrieben. Die Korrelation kann im Intervall zwischen -1 und +1 liegen. Bei einem Wert von zum Beispiel +1 besteht ein vollkommener, gleichgerichteter Zusammenhang. Bei 0 besteht kein und bei -1 vollkommen entgegengesetzter Zusammenhang. Bei der *ACF* ist zu beachten, dass die Werte, die zwischen den beiden untersuchten Zufallsvariablen liegen, das Ergebnis beeinflussen.

Unter der *PACF* versteht man die Korrelation der beiden Zufallsvariablen X_t und $X_{t-\tau}$ unter Konstanthaltung der dazwischenliegenden Zufallsvariablen. [1] Durch diese Konstanthaltung wird der Einfluss der zwischen den beiden zu untersuchenden Zufallsvariablen liegenden Werte eliminiert.

Die *ACF* und die *PACF* in ARMA[p, q]-Prozessen weisen bestimmte Muster auf, die sich in den beiden Korrelationsfunktionen wiederfinden lassen, wodurch ein Rückschluss auf die Ordnung [p, q] möglich ist. [1]

Laut [1] handelt es sich genau dann um einen MA[q]-Prozess, wenn für die Autokorrelation gilt: $\hat{\rho}_q \neq 0$ und $\hat{\rho}_\tau = 0$ für $\tau > q$. Dies drückt aus, dass die Autokorrelation für $\tau > q$ verschwindet. Aufgrund dessen ist die *ACF* besonders dafür geeignet, um die Ordnung reiner MA-Prozesse ($\text{MA}[q] = \text{ARMA}[0, q]$) zu bestimmen.

Die *PACF* wird verwendet, um eine Aussage für reine AR[p]-Prozesse ($\text{AR}[p] = \text{ARMA}[p, 0]$) zu formulieren. Ein reiner AR[p]-Prozess liegt vor, wenn für die partiellen Autokorrelationen $\hat{\pi}_p \neq 0$ und $\hat{\pi}_\tau = 0$ für $\tau > p$ gilt. Hier verschwindet die partielle Autokorrelation für $\tau > p$.

Um die Ordnung eines ARMA[p,q]-Prozesses zu bestimmen, werden die beiden Vorgehensweisen zur Ermittlung der Ordnungen eines reinen MA[q]- und eines reinen AR[p]-Prozesses kombiniert.

Aufgrund der *ACF* lässt sich sagen, dass sich der ARMA[p, q]-Prozess ab $\tau > q$ wie ein AR[p]-Prozess verhält. Dies liegt daran, dass für diesen Fall der Moving-Average-Anteil wegfällt.

Weiters drückt die *PACF* ein Verschwinden des AR[p]-Anteils für $\tau > p$ aus. Es liegt nur mehr ein MA[q]-Anteil vor. [1]

Mithilfe dieser beiden Aussagen lässt sich die Ordnung [p, q] des Prozesses bestimmen. In MATLAB steht für diese Ordnungsbestimmung eine eigene Funktion zur Verfügung, welche im Zuge der Kapitel 4 und 5 verwendet wird.

Nach der Bestimmung der Ordnung kann mit dem geschätzten Modell eine Prognose aufgestellt werden.

3.1.4.2 Die optimale Prognose eines ARIMAX-Prozesses

Im folgenden Abschnitt wird die optimale Prognose für einen **ARIMAX-Prozess** erläutert.

Laut [1] steht der Begriff **ARIMAX** für **Autoregressiver-Integrierter-Moving-Average-Prozess mit exogenen Variablen**. Die Ausgangslage dieses Prozesses bildet der ARMA Prozess, welcher sich aus einem Moving-Average (MA) Prozess und einem Autoregressiven (AR) Prozess zusammensetzt. Da es für das Verständnis des ARIMAX-Prozesses notwendig ist, die Grundlagen des **MA**-, **AR**- und **ARMA Prozesses** zu verstehen, wird im folgenden Abschnitt kurz darauf eingegangen.

In [1] wird ein stochastischer Prozess (X_t) als **Moving-Average-Prozess** der Ordnung q , kurz **MA[q]-Prozess**, bezeichnet, wenn er sich in folgender Form darstellen lässt:

$$X_t = \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q} \quad (3.24)$$

ε_t Zufallsprozess mit Erwartungswert $E[\varepsilon_t] = 0$

β Moving-Average-Parameter

Die Gleichung 3.24 besagt, dass sich der beobachtete Wert X_t aus einem gewichteten Mittel aus gegenwärtigen und vorangegangenen Zufallsvariablen zusammensetzt. Dabei ist zu beachten, dass bei dieser Formel ein Mittelwert von null angenommen wird. Da in der Praxis häufig Mittelwerte vorkommen, welche von null abweichen, verwendet man häufig die nachfolgende Definitionsgleichung [1].

$$X_t = \mu + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q} \quad (3.25)$$

μ Mittelwert

Laut [1] wird ein stochastischer Prozess (X_t) als **Autoregressiver-Prozess** der Ordnung p , kurz **AR[p]-Prozess**, folgendermaßen definiert:

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \varepsilon_t \quad (3.26)$$

$X_{t-N} \dots$ Vergangenheitswerte von X_t

$\alpha \dots$ Autoregressive-Parameter

Gleichung 3.26 entspricht einer multiplen Regression, wobei die Variablen nicht unabhängig sind. Dies liegt daran, dass die erklärenden Variablen Vergangenheitswerte von X_t sind. Aufgrund der Unvorhersagbarkeit der Zufallsvariablen ε_t ist die Prognosefunktion eines AR-Prozesses optimal, wenn der Fehler nur von ε_t abhängig ist.

Bei α und β handelt es sich um Wichtungsfaktoren. Sie geben an, wie stark Vergangenheitswerte in die Bestimmung der aktuellen Werte miteinbezogen werden.

Mithilfe der im vorigen Abschnitt erklärten Prozesse (**MA[q]** und **AR[p]**) lässt sich aufgrund von [1] nun der folgende Prozess definieren:

Ein stochastischer Prozess (X_t) wird **Autoregressiver-Moving-Average-Prozess** der Ordnung $[p, q]$, kurz **ARMA[p, q]-Prozess**, genannt, wenn er die nachstehende Gleichung erfüllt.

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q} \quad (3.27)$$

In Gleichung 3.27 ist zu erkennen, dass sich die optimale Prognose eines **ARMA[p, q]-Prozesses** aus einer Kombination zwischen einem **AR-** (Gleichung 3.24) und einem **MA-Prozess** (Gleichung 3.26) zusammensetzt.

Dabei werden für realisierte Werte von X_t die Beobachtungen verwendet und für nicht realisierte rekursiv die optimalen Prognosen eingesetzt. Weiters werden unbekannte Werte von ε_t durch ihren Erwartungswert $E[\varepsilon_t] = 0$ ersetzt.

Gleichung 3.28 zeigt die h -Schritt-Prognosefunktion des **ARMA[p, q]-Prozesses**.

$$X_{t,h} = \alpha_1 X_{t+h-1} + \dots + \alpha_p X_{t+h-p} + \varepsilon_{t+h} - \beta_1 \varepsilon_{t+h-1} - \dots - \beta_q \varepsilon_{t+h-q} \quad (3.28)$$

$h \dots$ Prognosehorizont

Dabei ist zu beachten, dass der **MA[q]** Teil für Prognosen mit einer Schrittweite $h > q$ verschwindet, wodurch Gleichung (3.28) nur mehr einen **AR[p]**-Anteil enthält. Dies wurde bereits in Kapitel 3.1.4.1 erläutert.

Da Zeitreihen oft einem Trend folgen und dieser mit dem **ARMA-Prozess** nicht beschrieben werden kann, wurde der Prozess nach [1] zum sogenannten **Autoregressiven-Integrierten-Moving-Average-Prozess (ARIMA-Prozess)** weiterentwickelt. Dieser Prozess, der aufgrund des Trends nicht-stationär ist, lässt sich durch Differenzenbildung in einen stationären **ARMA-Prozess** überführen, wodurch der Trend eliminiert werden kann.

Ein **ARIMA[p, d, q]-Prozess** lässt sich mit Gleichung 3.29 definieren:

$$\alpha(B)(1 - B)^d X_t = \beta(B)\varepsilon_t \quad (3.29)$$

α Autoregressive-Parameter

β Moving-Average-Parameter

ε_t Zufallsprozess mit Erwartungswert $E[\varepsilon_t] = 0$

X_t Zeitreihenwert X_t

d Differenzenbildungsanzahl bis ARIMA-Prozess in ARMA-Prozess überführt ist

B Backshift Operator

Der Backshift-Operator, auch Lag-Operator genannt, wird dazu verwendet, um aus einem Element x_t einer Zeitreihe das vorhergehende Element x_{t-1} zu erhalten.

Wenn von einem **ARIMA-Prozess** (X_t) eine Prognose erstellt werden soll, so muss dieser durch d -maliges differenzieren in einen **ARMA-Prozess** (Y_t) überführt werden.

Nach der Differenzenbildung wird die Prognose für den vorliegenden **ARMA-Prozess** (Y_t) erstellt und anschließend wird (Y_t) durch d -maliges summieren auf den ursprünglichen **ARIMA-Prozess** (X_t) zurücküberführt.

Laut [3] ist der **Autoregressive-Integrierte-Moving-Average-Prozess** mit **exogenen Variablen**, kurz **ARIMAX-Prozess** eine Erweiterung des **ARIMA-Prozesses**. Der Vorteil dieses Prozesses liegt darin, dass externe Variablen miteinbezogen werden können, wodurch sich der

Prognosefehler verkleinern lässt. Allerdings muss man einen höheren Realisierungsaufwand in Kauf nehmen.

Bei diesen externen Variablen kann es sich bei Elektrofahrzeugen zum Beispiel um das Wetter, die Temperatur oder die Art der Fahrtstrecke handeln. Dabei kann man davon ausgehen, dass sich bei niedrigen Temperaturen ein höherer Energiebedarf aufgrund der Heizung zeigt. Weiters wird der Energiebedarf auf Bergstraßen höher sein als auf Autobahnen.

Im Zuge der Prognoseerstellung in Kapitel 4 und 5 wird auf diese zusätzlichen Parameter verzichtet. Dies liegt daran, dass diese nicht in den vorliegenden Datenmengen protokolliert wurden. Außerdem werden diese Einflussparameter ohnehin indirekt in den geladenen Energiemengen miteinbezogen.

3.1.5 Kalman-Filter

Der Kalman-Filter ist ein Filter zum Erstellen von Prognosen, welcher zur Schätzung des Zustandes x_t ein Zustandsraummodell verwendet wird, weshalb im folgenden Abschnitt zuerst eine Erläuterung der Theorie der Zustandsraummodelle erfolgt. Anschließend wird die Theorie des Kalman-Filters betrachtet.

Zustandsraummodell

Laut [15] wird unter einem Zustandsraum die Menge aller Zustände verstanden, die ein System annehmen kann. Bei einem Zustandsraummodell werden die Eingangs-, Ausgangsgrößen und die Beziehungen der Zustandsgrößen durch Matrizen und Vektoren dargestellt.

In [1] wird ein Zustandsraummodell durch die Systemgleichung 3.30 und die Beobachtungsgleichung 3.31 definiert:

$$x_{t+1} = A_t x_t + B_t \varepsilon_{t+1}, \quad t \geq 0 \quad (3.30)$$

$$y_t = C_t x_t + \eta_t, \quad t \geq 0 \quad (3.31)$$

A_t, B_t, C_t System-, Eingangs-, Ausgangsmatrix zum Zeitpunkt t

ε_t, η_t Folgen unabhängiger Zufallsvektoren mit Erwartungswert null

Gleichung 3.30 erfasst die zeitliche Dynamik des Zustandes x_t . Dabei ist zu beachten, dass ein Zustand nicht direkt erkennbar ist, da er von Rauschen überlagert wird. Die Beobachtungsgleichung 3.31 definiert den beobachteten Wert y_t .

Der Vorteil des oben dargestellten Ansatzes liegt darin, dass die Schätzung für x_t rekursiv aus der Schätzung für x_{t-1} und der letzten Beobachtung y_t bestimmt werden kann. Damit erhält man für jedes Modell, das sich in Zustandsraumform darstellen lässt, ein einheitliches Prognoseverfahren.

Funktion des Kalman-Filters

Laut [1] setzt sich der diskrete Kalman-Filter aus einem Prädiktionsschritt, welcher auch Vorhersageschritt genannt wird, und einem Korrekturschritt zusammen. (vgl. Abbildung 3.1) Er kann für alle Systeme eingesetzt werden, die sich durch eine Zustandsraummodell darstellen lassen.

Zuerst wird aus den bisher beobachteten Werten eine Schätzung $\hat{x}_t$ für x_t aufgestellt. Diese Schätzung repräsentiert die beste lineare Approximation $\tilde{x}_t$, die zu diesem Zeitpunkt erstellt werden kann. Unbekannte Störungen werden durch den Erwartungswert 0 ersetzt, wodurch sich für den Prädiktionsschritt die folgende Gleichung ergibt:

$$\tilde{x}_t = A_{t-1} \hat{x}_{t-1} \quad (3.32)$$

$\hat{x}_{t-1}$ Schätzwert zum Zeitpunkt $t-1$

Mit Gleichung 3.32 ergibt sich die lineare Approximation $\tilde{y}_t$ für die zu erwartende neue Beobachtung:

$$\tilde{y}_t = C_t \tilde{x}_t \quad (3.33)$$

Der Prognosefehler $\tilde{P}_t$ für den berechneten Wert wird mit der folgenden Formel berechnet:

$$\tilde{P}_t = A_{t-1} P_{t-1} A'_{t-1} + B_{t-1} Q_{t-1} B'_{t-1} \quad (3.34)$$

A'_{t-1}, B'_{t-1} Transponierte System- bzw. Eingangsmatrix zum Zeitpunkt $t-1$

P_{t-1} Prognosefehler der vorherigen Berechnung zum Zeitpunkt $t-1$

$Q_{t-1} = \text{VAR}[\varepsilon_{t-1}]$... Varianz der Störungen der Systemgleichung zum Zeitpunkt $t-1$

Unter der Varianz versteht man eine Maßzahl für die Streuung einer Variablen. [1]

Alle bisherigen Betrachtungen finden vor der Beobachtung von y_t statt.

Nach dem Beobachtungsschritt folgt der Korrekturschritt, bei dem der geschätzte Wert $\tilde{x}_t$ durch Korrekturberechnungen verbessert wird. Als Erstes muss die sogenannte Kalman'sche Verstärkung (Kalman-Gain) K_t derart bestimmt werden, dass zwischen $x_t - \tilde{x}_t$ und $y_t, y_{t-1}, \dots, y_1$ Unkorreliertheit eintritt.

Mithilfe der oben genannten Kalman'schen Verstärkungsmatrix

$$K_t = \tilde{P}_t C'_t (C_t \tilde{P}_t C'_t + R_t)^{-1} \quad (3.35)$$

C'_t Transponierte Ausgangsmatrix zum Zeitpunkt t

$R_t = \text{VAR}[\eta_t]$ Varianz der Störungen der Beobachtungsgleichung zum Zeitpunkt $t-1$

ergibt sich der Korrekturschritt der Kalman-Rekursion zu:

$$\hat{x}_t = \tilde{x}_t + K_t (y_t - \tilde{y}_t) \quad (3.36)$$

Der Prognosefehler kann mit Gleichung 3.37 bestimmt werden:

$$P_t = \tilde{P}_t - K_t C_t \tilde{P}_t \quad (3.37)$$




Abbildung 3.1: Diskreter Kalman - Filter

Beim Kalman-Filter besteht ebenfalls die Möglichkeit eine Prognose mit einem Prognosehorizont von h aufzustellen. Dazu wird der Prädiktionsschritt h -mal ausgeführt, ohne den Korrekturschritt anzuwenden. Der wesentliche Nachteil dieses Verfahrens liegt darin, dass ein vorliegendes Modell zuerst in ein Zustandsraummodell überführt werden muss.

Der Kalman-Filter liefert die gleichen Ergebnisse als der ARIMAX-Prozess, was daran liegt, dass beiden Verfahren das gleiche Modell zugrunde liegt. Deshalb wird auf eine Realisierung in den Kapiteln 4 und 5 verzichtet.

3.1.6 Neuronale Netze

Laut [1] wird mit künstlichen neuronalen Netzen versucht, das natürliche Nervensystem nachzubilden. Dabei soll das künstliche neuronale Netz das Problem schneller lösen, als es eine konventionelle Herangehensweise lösen würde. Diese Netze bestehen aus einfachen, miteinander verbundenen, funktionalen Einheiten, welche Neuronen genannt werden.

Im folgenden Abschnitt soll nun ein Feedforward-Netz betrachtet werden. Ein solches Netz besteht aus einer Schicht von Eingabeneuronen, einer Schicht von verborgenen Neuronen und einer Ausgabeschicht mit den Ausgabeneuronen (vgl. Abbildung 3.2). Die Neuronen werden durch Funktionen miteinander verbunden.




Abbildung 3.2: Schema eines Feedforward - Netzes mit drei Schichten

Bei einem neuronalen Netz wird der Eingabeschicht ein Ausschnitt der Zeitreihe übergeben, woraufhin die Ausgabeschicht die Prognose liefern soll. Dabei arbeitet das Netz laut [1] in zwei Modi, dem Abbildungsmodus und dem Lern- oder Trainingsmodus.

Zuerst erfolgt die Ausführung des Lern- oder Trainingsmodus. Dabei wird dem Netz ein Ausschnitt der Zeitreihe übergeben, wobei der gesuchte Output bekannt ist. Anschließend werden die Parameter der Funktionen, welche die einzelnen Neuronen verknüpfen, so eingestellt, dass der Fehler minimal wird.

Nach dem Training können im Abbildungsmodus Prognosen für unbekannte Zeitreihen erstellt werden.

Im MATLAB-Programm, welches zur Prognoseerstellung verwendet wird, sind eigene Funktionen für neuronale Netze implementiert. Diese werden in Kapitel 4 und 5 zur Prognose verwendet.

3.1.7 Vergleichstagverfahren

Beim Erstellen einer Prognose ist zu beachten, dass die in den vorherigen Abschnitten skizzierten Prognoseverfahren für spezielle Tage, wie zum Beispiel für die Weihnachtszeit, keine zufriedenstellenden Resultate liefern. Deshalb wird für diese Tage laut [7] das sogenannte Vergleichstagverfahren verwendet. Dabei werden die um den Trend bereinigten Daten mit einem passenden Tag eines kalendarisch entsprechenden Jahres verglichen. Es ist zu beachten, dass sich die Lage der Feiertage innerhalb der Woche alle 5 bis 10 Jahre wiederholt. Da die Aufzeichnungszeiträume der in Kapitel 4 und 5 verwendeten Datenmengen zu kurz für dieses Verfahren sind, wird es im Zuge dieser Arbeit nicht näher untersucht.

3.2 Fehlerberechnung

Um die Prognoseergebnisse der verschiedenen Verfahren miteinander vergleichen zu können, werden die Fehlerberechnungsmethoden der nächsten beiden Unterkapitel verwendet.

Zuerst wird auf den mean squared error, kurz *MSE*, eingegangen. Der *MSE* entspricht der mittleren quadratischen Abweichung der Prognosewerte von den tatsächlichen Werten. Im Anschluss daran folgt die Erläuterung des relativen Fehlers.

3.2.1 Mean Squared Error

Laut [1] wird die mittlere quadratische Abweichung (engl. mean squared error, *MSE*) durch die Formel 3.38 bestimmt. Beim *MSE* handelt es sich um den Mittelwert der Quadrate der Abweichungen der Prognosewerte von den tatsächlichen Werten. Die Bildung der mittleren quadratischen Abweichung wird dazu verwendet, dass sich positive und negative Fehler gegenseitig nicht aufheben, was bei einfacher Mittelwertbildung der Fall wäre.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - x)^2 \quad (3.38)$$

MSE mittlere quadratische Abweichung (engl. mean squared error)

n Anzahl der Elemente

i Laufvariable

x_i Prognosewert

x tatsächlicher Wert

3.2.2 Relativer Fehler

Der relative Fehler lässt sich mithilfe von Formel 3.39 bestimmen, wobei als Bezugswert x_{Bezug} meist der tatsächliche Wert x_{soll} verwendet wird [1]. In Kapitel 4.3.1 wird sich jedoch zeigen, dass es im Zuge dieser Arbeit aufgrund der vorliegenden Datenmengen nicht möglich ist, den tatsächlichen Wert x_{soll} als Bezugswert zur Fehlerberechnung zu verwenden.

$$relE_{\%} = \frac{x_{ist} - x_{soll}}{x_{Bezug}} * 100\% \quad (3.39)$$

$relE_{\%}$ relativer Fehler in Prozent

x_{ist} aktueller Wert (Prognosewert)

x_{soll} tatsächlicher Wert

x_{Bezug} Bezugswert zur Bestimmung des relativen Fehlers

4 Privat genutzte Elektrofahrzeuge

Kapitel 4 beschreibt die Entwicklung eines Prognosemodells für privat genutzte Elektrofahrzeuge. Dabei werden die Energiebedarfe für den aktuellen sowie den folgenden Tag mit einer Prognoseschrittweite von einer Stunde ermittelt.

Am Beginn werden die Grundlagen besprochen und die zugrundeliegenden Daten analysiert und aufbereitet.

Im Anschluss folgt eine Untersuchung der im Theorieteil erläuterten Prognoseverfahren. Zuerst wird auf die Prognose des Tagesenergiebedarfs eingegangen, woraufhin die Verfahren, die zur Lösung der Problemstellung verwendbar sind, ausgewählt werden.

Im nächsten Unterkapitel wird auf die Ergebnisse der Stundenprognose eingegangen.

Zum Abschluss des Kapitels folgen die Realisierung in MATLAB sowie eine Schlussfolgerung.

4.1 Einleitung

Der Einsatz von „Demand Side Management“ führt zu einer Entlastung des Stromnetzes sowie zu einer Verminderung der Anzahl der benötigten Kraftwerke. (vgl. Kapitel 1.2) Dazu ist eine Lastvorhersage erforderlich. Deshalb soll mithilfe eines Prognosemodells eine Vorhersage für den Ladeenergiebedarf von Elektrofahrzeugen erfolgen, was eine bedarfsorientierte Ladesteuerung ermöglicht.

Bei Verwendung eines Modells zur Vorhersage der benötigten Energie in Verbindung mit Elektrofahrzeugen müssen diese nicht immer vollständig geladen werden.

Weiters können die Elektrofahrzeuge bei Besitz einer hauseigenen Photovoltaikanlage zum Beispiel dann geladen werden, wenn der Energiebedarf durch die eigene Photovoltaikanlage gedeckt wird. Dies hat den Vorteil einer Stromkostensenkung und einer Versorgungsnetzentlastung.

Zur Erstellung des Prognosemodells steht ein Datenpool zur Verfügung, welcher sich aus 26 Elektrofahrzeugen zusammensetzt. Die Daten stammen von der Modellregion Köstendorf in Salzburg, wobei die Ladeleistungen der einzelnen Fahrzeuge mit einer Schrittweite von fünf Minuten über einen Zeitraum von einem Jahr aufgezeichnet wurden. Im Zuge der vorliegenden Arbeit wird ein Prognosemodell zur Ladeenergievorhersage der einzelnen Fahrzeuges sowie des gesamten Fahrzeugpools erstellt.

4.2 Datengrundlage privat genutzter Elektrofahrzeuge

Die zur Prognoseerstellung verwendeten Daten stammen von der Modellregion Köstendorf in Salzburg. (vgl. Kapitel 4.1) Dabei wurden von 26 Elektrofahrzeugen innerhalb des Zeitraumes 01.09.2013 bis 31.08.2014 die Ladeleistungen der einzelnen Fahrzeuge an der Ladestation mit einer Schrittweite von fünf Minuten aufgezeichnet. Mithilfe dieser protokollierten Daten können die geladenen Energiemengen berechnet werden.

Die geladenen Energien werden zu Stundenwerten zusammengefasst, da für den Prognosehorizont die ausstehenden Stunden des aktuellen Tages zuzüglich des gesamten nächsten Tages mit einer Schrittweite von einer Stunde gewählt werden.

Die aufgezeichneten Daten der 26 E-Fahrzeuge unterscheiden sich nur durch die Ladeenergiemengen und die Ladezeitpunkte. Daher wird für die Erläuterungen der nachfolgenden Abschnitte ein Elektrofahrzeug, das Fahrzeug 1, verwendet. Diese Auswahl lässt sich dadurch begründen, dass die geladenen Energiemengen von Fahrzeug 1 dem Mittelwert der Ladeenergien aller E-Fahrzeuge nahekommt.

Außerdem werden alle Fahrzeuge zu einem Pool zusammengefasst und Gemeinsamkeiten sowie Abweichungen zwischen den Prognoseergebnissen von Fahrzeug 1 und dem gesamten Fahrzeugpool besprochen.

4.2.1 Datenanalyse und Aufbereitung

Bei der Analyse der Daten, welche mit einer Schrittweite von fünf Minuten vorliegen, tritt in seltenen Fällen eine sehr hohe Ladeleistung auf. Betrachtet man Fahrzeug 1, so bemerkt man im Betrachtungszeitraum lediglich eine geringe Anzahl von Ladeleistungswerten, welche zwischen $3,68\text{ kW}$ und $3,8\text{ kW}$ liegen. Außerdem ist ein Spitzenwert mit einer Höhe von 34 kW zu erkennen, wobei es sich hierbei mit hoher Wahrscheinlichkeit um einen Aufzeichnungsfehler handelt. Da der Großteil der Ladeleistungen der Elektrofahrzeuge kleiner als $3,68\text{ kW}$ ist, wird im Zuge dieser Arbeit angenommen, dass der maximale Ladestrom 16 A betrug. Dadurch ergibt sich eine maximale Ladeleistung von $P = 230\text{ V} * 16\text{ A} = 3,68\text{ kW}$. Aufgrund dessen werden alle Ladeleistungen, welche größer als $3,68\text{ kW}$ sind, durch die vorangegangenen Leistungen ersetzt. Diese Vorgehensweise wird gewählt, da die hohen Ladeleistungen hauptsächlich dann auftraten, wenn das Elektrofahrzeug über einen längeren Zeitraum geladen wurde. Dabei

erscheint es unwahrscheinlich, dass die Ladeleistung für den kurzen Zeitraum von fünf Minuten viel größer als in der Zeit davor beziehungsweise danach war.

Weiters lassen sich in den Datenreihen häufig kurze Ladevorgänge mit kleinen Leistungen, welche unter 150 W liegen, feststellen. Durch diese geringen Ladeleistungen ergeben sich Ladeenergien unter $12,5\text{ Wh}$.

Damit Ladevorgänge, bei denen es sich höchst wahrscheinlich nicht um Aufladungen aufgrund von Ausfahrten handelt, die Prognoseergebnisse nicht verfälschen, werden kleine Leistungen ebenfalls aus den Datenreihen gestrichen. Im Zuge dieses Kapitels wird jeder Wert der kleiner als 300 W ist, nicht berücksichtigt. Die bereinigten Daten werden zu Stunden- und in weiterer Folge zu Tageswerten zusammengefasst.

Damit es zu keinen Verfälschungen der Prognoseergebnisse durch Tage mit sehr hohen beziehungsweise sehr geringen Ladeenergiemengen kommt, erfolgt eine Eliminierung aller Tagesenergiwerte, die nicht zu jenen 90 % gehören, welche um den Mittelwert aller geladenen Energiemengen angeordnet sind. Danach werden für diese bereinigten Daten eine Tages- und eine Stundenprognose erstellt. Mithilfe dieser beiden Prognosen lässt sich ein Ladeprofil für den gewünschten Tag bestimmen.

Abbildung 4.1 zeigt die bereinigten Werte der Ladeenergien von Fahrzeug 1. Eine Auswertung der Daten von Fahrzeug 1 ergibt, dass an 167 Ladetagen insgesamt 196 Ladevorgänge stattfanden. Dadurch erhält man durchschnittlich knapp $1,2$ Ladevorgänge pro Ladetag.

Fahrzeug 1 wurde an den meisten Ladetagen durchschnittlich einmal und an jedem fünften Tag ein zweites Mal geladen. Die insgesamt geladene Energiemenge innerhalb des Datenerfassungszeitraums betrug in etwa $1,3\text{ MWh}$. Dies ergibt für die durchschnittlich geladene Energiemenge pro Ladetag ungefähr $7,8\text{ kWh}$.

In der Grafik sticht das Fehlen der Energiewerte zwischen Tag 26 und 110 ins Auge. Weiters sind weitere Tage ohne geladene Energien ersichtlich. Der Grund dafür könnte zum Beispiel darin liegen, dass das Elektrofahrzeug nicht benutzt wurde, weshalb keine Energie geladen wurde. Weiters wäre es möglich, dass der Ladevorgang nicht an der die Ladeenergie protokollierenden Ladestation stattfand.

Bei einer genaueren Analyse der nachfolgenden Abbildung lassen sich keine regelmäßigen oder systematischen Änderungen erkennen, weshalb keine zufriedenstellende Prognose für den nächsten Wert möglich ist. Eine Prognoseerstellung mit Verwendung dieser Daten als

Prognosegrundlage würde in etwa den Mittelwert liefern. Um eine zufriedenstellende Prognose zu erhalten, werden die Werte aus Abbildung 4.1 aufsummiert, wodurch ein wesentlich glatterer Verlauf (vgl. Abbildung 4.2) ohne große Sprünge entsteht.




Abbildung 4.1: Ladeenergien von Fahrzeug 1

Mithilfe der aufsummierten Ladeenergien kann nun eine Prognose erstellt werden, wobei die Änderung der aufsummierten Energiemenge vorhergesagt wird. Daraufhin lässt sich durch Rückrechnung die Energiemenge des Tages bestimmen. Allerdings ist bei dieser Vorgehensweise zu beachten, dass einige der Prognoseverfahren, welche in Kapitel 3 besprochen wurden, nicht dafür geeignet sind. Eine genaue Auswahl und Charakterisierung der einzelnen Verfahren folgt in Kapitel 4.3.




Abbildung 4.2: Aufsummierte Ladeenergien von Fahrzeug 1, alle Wochentage

Unterteilt man die Ladeenergien von Fahrzeug 1 aus Abbildung 4.1 in die einzelnen Wochentage und summiert diese getrennt auf, so ergibt sich Abbildung 4.3. Hierbei handelt es sich jedoch nicht mehr um eine zeitlich, kontinuierliche Darstellung.

Bei Betrachtung der einzelnen Tagesverläufe stellt man an einigen Tagen deutlich höhere aufsummierte Ladeenergien als an anderen fest. Dies ist auf die unterschiedlichen Energieverbräuche von Fahrzeug 1 an den einzelnen Tagen zurückzuführen.

Beim Anblick der verschiedenen Verläufe kann man dienstags und samstags ungefähr dreimal so große aufsummierte Ladeenergien feststellen als am Mittwoch. Hierfür könnte verantwortlich sein, dass an diesen Tagen längere Ausfahrten stattfanden und somit größere Energiemengen benötigt wurden.

Aufgrund der unterschiedlichen Energieverbräuche an den verschiedenen Wochentagen ist es sinnvoll, die Prognose aufgrund der einzelnen Tage zu ermitteln, da dadurch eine genauere Vorhersage ermöglicht wird.




Abbildung 4.3: Aufsummierte Ladeenergien von Fahrzeug 1, einzelne Wochentage

In Abbildung 4.4 sind die bereinigten Werte der Ladeenergien des gesamten Fahrzeugpools, welcher sich aus allen 26 Fahrzeugen zusammensetzt, dargestellt. In der Grafik sind an den meisten Tagen Ladevorgänge zu erkennen. Dies liegt daran, dass an jedem Tag mit hoher Wahrscheinlichkeit zumindest ein Elektrofahrzeug geladen wurde. Bei einer Auswertung der Daten stellt man an 327 Tagen Ladevorgänge von mindestens einem E-Fahrzeug fest, wobei insgesamt 4133 Ladevorgänge stattfanden. Damit erhält man einen durchschnittlich Wert von 12,6 Ladevorgängen pro Ladetag. Weiters bemerkt man bei der Analyse der Daten, dass an

Ladetagen im Durchschnitt 11 Elektrofahrzeuge geladen wurden. Die geladene Energiemenge aller Ladetage beträgt ungefähr 31,6 *MWh*. Dadurch erhält man für die durchschnittlich geladene Energie pro Ladetag in etwa 96,6 *kWh*. Mithilfe der durchschnittlichen Werte für die Anzahl der geladenen Fahrzeuge pro Ladetag und der geladenen Energie pro Ladetag lässt sich die durchschnittlich geladene Energie pro Ladetag und Fahrzeug ermitteln. Bei der Berechnung ergibt sich eine geladene Energie pro Ladetag und Fahrzeug von ungefähr 8,8 *kWh*. Dieser Wert kann nun mit jenem von Fahrzeug 1, welcher bei 7,8 *kWh* liegt, verglichen werden. Die geladene Energiemenge pro Ladetag von Fahrzeug 1 liegt demnach Nahe dem Durchschnittswert des gesamten Fahrzeugpools. Dies bestätigt die in Kapitel 4.2 getroffene Auswahl von Fahrzeug 1 zur Datenanalyse und zur Untersuchung der Prognoseverfahren.

Wie es schon bei der Analyse von Fahrzeug 1 der Fall war, lassen sich auch beim Fahrzeugpool keine regelmäßigen oder systematischen Änderungen der Ladeenergien erkennen. Dadurch ist keine zufriedenstellende Prognose möglich. Es wird lediglich ein Mittelwert vorhergesagt. Deshalb werden auch die Daten des Fahrzeugpools aufsummiert, wodurch sich der Verlauf in Abbildung 4.5 ergibt.




Abbildung 4.4: Ladeenergien des Fahrzeugpools

In der nachfolgenden Grafik ist ein wesentlich glatterer und gleichmäßigerer Anstieg der aufsummierten Ladeenergien als bei Fahrzeug 1 in Abbildung 4.2 zu erkennen. Dies liegt daran,

dass es sich um einen Fahrzeugpool mit mehreren Fahrzeugen handelt, wodurch an fast allen Tagen Energie geladen wurde. Dadurch treten wesentlich weniger sprunghafte Änderungen auf.




Abbildung 4.5: Aufsummierte Ladeenergien des Fahrzeugpools, alle Wochentage

Abbildung 4.6 zeigt die Werte der aufsummierten Ladeenergien des Fahrzeugpools der einzelnen Wochentage. Aufgrund der unterschiedlich schnellen Anstiege ist es auch hier sinnvoll, die Prognose aufgrund der einzelnen Wochentage zu erstellen, wodurch ein genaueres Prognoseergebnis erzielt werden kann.

Ein Vergleich der Werte der geladenen aufsummierten Energien von Fahrzeug 1 (Abbildung 4.3) mit jenen des gesamten Fahrzeugpools (Abbildung 4.6) zeigt, dass die Maximalwerte an unterschiedlichen Tagen auftreten. Bei Fahrzeug 1 wurde die meiste Energie an Samstagen und beim gesamten Fahrzeugpool donnerstags geladen. Dies könnte daran liegen, dass mit Fahrzeug 1 samstags häufig längere Ausfahrten stattfanden, weshalb größere Energiemengen als bei den anderen Fahrzeugen benötigt wurden. Eine weitere Abweichung ist mittwochs zu erkennen. An diesen Tagen weist die aufsummierte geladene Energiemenge von Fahrzeug 1 den geringsten Wert auf. Beim Fahrzeugpool hingegen wurde montags und sonntags am wenigsten Energie geladen. Daraus lässt sich schließen, dass die geladenen Energiemengen von Fahrzeug 1 mittwochs unter dem Durchschnitt des gesamten Fahrzeugpools lagen.




Abbildung 4.6: Aufsummierte Ladeenergien des Fahrzeugpools, einzelne Wochentage

Abbildung 4.7 zeigt die durchschnittlichen Ladeleistungen von Fahrzeug 1 pro Ladetag, wobei die Auflösung zur Darstellung eine Stunde beträgt. Bei der Berechnung wurde die Anzahl der Tage, an denen mindestens ein Ladevorgang stattfand, zur Durchschnittsbildung verwendet. Ein Wert, der zu einer bestimmten Uhrzeit dargestellt wird, entspricht dabei der durchschnittlichen Ladeleistung der nachfolgenden Stunde. Dabei entspricht zum Beispiel ein um 00:00 Uhr dargestellter Wert der durchschnittlichen Ladeleistung der ersten Stunde des Tages.

Bei einer Analyse der Verläufe kann man feststellen, dass an den meisten Wochentagen die durchschnittliche Ladeleistung in den späten Nachmittags- bis Abendstunden am höchsten war. Dies lässt sich dadurch begründen, dass das Fahrzeug am Tag aufgrund von Ausfahrten nicht mit der Ladestation verbunden war und somit nicht geladen wurde. Gründe für diese Ausfahrten könnten zum Beispiel die Fahrt zum Arbeitsplatz oder ein Tagesausflug mit der Familie sein. Da das E-Fahrzeug während der Vormittags- und frühen Nachmittagsstunden nicht zum Laden angeschlossen war, musste es am Abend und in den Nachtstunden geladen werden. Dies ist an der höheren durchschnittlichen Ladeleistung zu dieser Zeit erkennbar.

Bei den durchschnittlichen Ladeleistungen ist ein unterschiedliches Ladeverhalten an den unterschiedlichen Wochentagen ersichtlich.

Die durchschnittliche Ladeleistung am Montag erreichte bereits um 14:00 Uhr ihren Höchstwert. Ein Grund hierfür könnte zum Beispiel sein, dass das Fahrzeug von einer Person genutzt wurde,

welche an Montagen nur vormittags arbeitete. Deshalb erfolgte die Verbindungsherstellung des Fahrzeuges mit der Ladestation bereits in den Mittagsstunden. Weiters bemerkt man eine deutlich geringere durchschnittliche Ladeleistung als an den meisten Wochentagen, was sich durch einen geringeren Energiebedarf an diesem Tag erklären lässt.

An den Wochenenden treten die Maximalwerte ebenfalls früher auf als an den meisten anderen Tagen. Die einzige Ausnahme ist der Montag, dessen Gegebenheiten vorhin bereits erläutert wurden. Der Grund für die früheren maximalen Werte an den Wochenenden liegt am anderen Fahrverhalten an diesen Tagen. Da es sich hierbei um keine Arbeitstage handelt, unterscheidet sich das Fahr- und somit das Ladeverhalten. Dabei kann das Elektrofahrzeug zum Beispiel im Zuge eines Familienausfluges verwendet worden sein, von welchem die Rückkehr bereits in den frühen Nachmittags- und nicht erst in den Abendstunden erfolgte. Dadurch wurde das E-Fahrzeug früher an die Ladestation angeschlossen, weshalb die durchschnittliche Ladeleistung an den Wochenenden früher ihre Maximalwerte erreichte.

Weiters sind die höchsten durchschnittlichen Ladeleistungen in der Grafik am Donnerstag zu erkennen. Hierbei erkennt man um 21:00 Uhr einen Spitzenwert von über 1300 W. Dies lässt sich durch den erhöhten Energiebedarf an diesem Tag begründen. Die durchschnittliche Ladeleistung ist in den Morgenstunden sehr gering. Um 07:00 Uhr beträgt sie 0 W, was daran liegt, dass donnerstags in dieser Zeit nie ein Ladevorgang stattfand.

Verfolgt man den Verlauf der gesamten Woche, welcher sich aus den einzelnen Tagen zusammensetzt, so sieht man um 07:00 Uhr eine minimale durchschnittliche Ladeleistung von in etwa 100 W. Der Grund dafür liegt darin, dass das E-Fahrzeug nicht sehr oft zu dieser Zeit geladen wurde. Mit voranschreitender Tagesuhrzeit steigt diese durchschnittliche Ladeleistung solange an, bis sie um 18:00 Uhr den Maximalwert von ungefähr 725 W erreicht. Dieser Höchstwert in den Abendstunden ist darauf zurückzuführen, dass das E-Fahrzeug in den Abendstunden am häufigsten geladen wurde, weshalb sich die größten durchschnittlichen Ladeleistungen zu dieser Tageszeit ergeben.




Abbildung 4.7: Durchschnittliche Ladeleistungen von Fahrzeug 1

In der nachfolgenden Abbildung sind die durchschnittlichen Ladeenergien des gesamten Fahrzeugpools in Bezug auf die Anzahl der Ladetage dargestellt. Hierbei erkennt man wesentlich glattere Verläufe als bei Fahrzeug 1, was sich wiederum durch die Aufsummierung der einzelnen Fahrzeuge begründen lässt.

Bei Betrachtung der Grafik bemerkt man, dass montags und sonntags mit einer deutlich geringeren durchschnittlichen Ladeleistung geladen wurde, was dadurch begründet werden kann, dass die Ladeenergiemenge an diesen Tagen geringer war.

An Montagen traten die geringsten durchschnittlichen Ladeleistungen auf, was daran liegt, dass an diesem Tag am wenigsten Energie benötigt und somit am wenigsten geladen wurde. Außerdem kann man erkennen, dass der Spitzenwert dieses Tages ebenfalls in den frühen Nachmittagsstunden stattfand. Dies ist auf die Mehrheit der Ladevorgänge zu dieser Zeit zurückzuführen. (vgl. Fahrzeug 1) Der Maximalwert der durchschnittlichen Ladeleistungen könnte dem Fahrverhalten der E-FahrzeugbenutzerInnen geschuldet sein. Wenn zum Beispiel die Mehrheit der FahrerInnen der Elektrofahrzeuge montags nur am Vormittag arbeitete und zu Mittag vom Arbeitsplatz nachhause kam, schlossen diese ihr Fahrzeug früher an die Ladestation an. Dadurch wurden die meisten E-Fahrzeuge in den frühen Nachmittagsstunden geladen, weshalb sich der Maximalwert zu dieser Zeit ergibt.

In der Abbildung 4.8 bemerkt man, dass die Spitzenwerte der durchschnittlichen Ladeleistungen des Fahrzeugpools an den Wochenenden um die Mittagszeit auftreten. Dies kann wiederum auf das, im Vergleich zu den Arbeitstagen, abweichende Fahrverhalten zurückgeführt werden. Das

Elektrofahrzeug war oftmals nur am Vormittag unterwegs, weshalb sich die beiden Maximalwerte um 12:00 Uhr am Sonntag beziehungsweise 13:00 Uhr am Samstag ausbilden.

Der Verlauf des Freitags ähnelt jenem des Montags. Die durchschnittliche Ladeleistung war zwar höher, jedoch wurde ebenfalls in den frühen Nachmittagsstunden mit der höchsten durchschnittlichen Ladeleistung geladen. Dies weist ebenfalls darauf hin, dass die Mehrheit der FahrzeugbenutzerInnen freitags nur am Vormittag arbeitete, weshalb sie in den Mittagsstunden nach Hause kam. Deshalb wurden die meisten Elektrofahrzeuge zu dieser Zeit mit der Ladestation verbunden, wodurch sich der Höchstwert am frühen Nachmittag ergibt.

Bei einem Blick auf die Wochentage Dienstag, Mittwoch und Donnerstag bemerkt man in den Abendstunden die höchsten durchschnittlichen Ladeleistungen. Diese entspricht dem erwarteten Verlauf, da die Elektrofahrzeuge an diesen Tagen am Abend nach dem nach Hause kommen mit der Ladestation verbunden wurden.

Bei der Analyse des Verlaufs der gesamten Woche, welcher sich aus den einzelnen Tagen zusammensetzt, sind zwei Spitzenwerte zu erkennen. Der Erste tritt um die Mittagszeit auf, was sich dadurch erklären lässt, dass an den Wochenenden, Montagen und Freitagen die Mehrheit der E-Fahrzeuge mittags mit der Ladestation verbunden wurde. Der zweite Spitzenwert tritt am frühen Abend auf, was daran liegt, dass an Dienstagen, Mittwochen und Donnerstagen die meisten Ladevorgänge zu dieser Zeit begonnen wurden.




Abbildung 4.8: Durchschnittliche Ladeleistungen des Fahrzeugpools

Bei einem Vergleich der durchschnittlichen Ladeleistungen von Fahrzeug 1 (Abbildung 4.7) mit jenen des Fahrzeugpools (Abbildung 4.8) stellt man fest, dass das Fahrzeug 1 ungefähr dem Durchschnitt des gesamten Pools entspricht. Sowohl bei Fahrzeug 1 als auch beim gesamten Fahrzeugpool treten die Maximalwerte der durchschnittlichen Ladeleistungen an den Wochenenden und montags in den frühen Nachmittagsstunden auf. Weiters ist zu erkennen, dass in beiden Abbildungen die höchsten Werte am Donnerstag auftreten. Eine Abweichung, die bei Betrachtung der beiden Darstellungen zu erkennen ist, sind die Verläufe des Freitags. Hierbei tritt der Spitzenwert beim Fahrzeug 1 deutlich später auf als beim gesamten Pool. Dies könnte daran liegen, dass mit dem Fahrzeug 1 an Freitagen meist den ganzen Tag gefahren wurde, weshalb die Verbindungsherstellung mit der Ladestation erst am Abend erfolgte. Die FahrerInnen der Mehrheit der E-Fahrzeuge arbeiteten hingegen nur bis Mittag, weshalb die Elektrofahrzeuge in den frühen Nachmittagsstunden mit der Ladestation verbunden wurden.

Eine weitere Abweichung der beiden Grafiken zeigt sich am Mittwoch. Hierbei treten bei Fahrzeug 1 im Verhältnis zu den anderen Tagen deutlich geringere durchschnittliche Ladeleistungen als beim gesamten Fahrzeugpool auf. Dies ergibt sich aufgrund der im Vergleich zu den anderen Elektrofahrzeugen geringeren geladenen Energiemenge von Fahrzeug 1.

In der nachfolgenden Abbildung sind die durchschnittlichen Ladeleistungen pro Ladevorgang dargestellt. Vergleicht man den Verlauf des Fahrzeugpools mit jenem von Fahrzeug 1, so bemerkt man annähernd gleiche Verläufe und in etwa gleich große Spitzenwerte. Diese liegen bei knapp über 600 W. Allerdings bemerkt man eine Phasenverschiebung zwischen den beiden Verläufen. Bei genauerer Betrachtung ist zu erkennen, dass die niedrigsten beziehungsweise höchsten durchschnittlichen Ladeleistungen bei Fahrzeug 1 später auftraten als beim gesamten Fahrzeugpool. Fahrzeug 1 wurde an den meisten Tagen später geladen als die Mehrheit der anderen Fahrzeuge.




Abbildung 4.9: Durchschnittliche Ladeleistungen pro Ladevorgang privat genutzter E-Fahrzeuge

Abbildung 4.10 zeigt die Ladebeginne von Fahrzeug 1, wobei 167 Ladevorgänge stattfanden. Dabei ist zu erkennen, dass über den ganzen Tag verteilt Ladestarts stattgefunden haben. Allerdings wurden in den späten Vormittags-, in den Nachmittags- und in den frühen Abendstunden mehr Ladevorgänge begonnen, als am Morgen und in der Nacht. Vergleicht man den Verlauf der durchschnittlichen Ladeleistung von Fahrzeug 1 aus Abbildung 4.9 mit Abbildung 4.10 so lassen sich Zusammenhänge feststellen. In der vorherigen Grafik erkennt man dann einen hohen Wert der durchschnittlichen Ladeleistung von Fahrzeug 1, wenn viele Ladestarts (vgl. Abbildung 4.10) stattfinden. Außerdem kann man erkennen, dass das Minimum der durchschnittlichen Ladeleistung bei wenigen Ladebeginn auftritt. Allerdings ist zwischen den Verläufen aus Abbildung 4.9 und Abbildung 4.10 eine Phasenverschiebung bemerkbar. Die Höchstwerte der Ladestarts treten früher auf als jene der durchschnittlichen Ladeleistungen. Dies liegt daran, dass ein Ladestart, der zum Beispiel zwischen 16:00 Uhr und 17:00 Uhr erfolgt, im Balken zwischen diesen beiden Zeitpunkten miteinbezogen ist. Findet nun ein Ladevorgang um 16:55 statt, so wird in dieser Stunde nicht mehr viel Energie geladen, sondern erst in den darauffolgenden Stunden. Deshalb verschiebt sich der Verlauf der durchschnittlichen Ladeleistung von Fahrzeug 1. Dies ist auch beim gesamten Fahrzeugpool zu bemerken.




Abbildung 4.10: Ladebeginne von Fahrzeug 1

Die nachfolgende Grafik zeigt die Ladebeginne des gesamten Fahrzeugpools. Hierbei stellt man in den Nachtstunden nur wenige Ladestarts fest. Die Mehrzahl der Ladevorgänge wurde in den Vormittags- und Nachmittagsstunden begonnen. Weiters fanden die meisten Ladestarts zwischen 11:00 Uhr und 12:00 Uhr statt. Diese Mehrheit ergibt sich aufgrund der Wochenenden, Montage und Freitage. An diesen Tagen wurden zwischen 11:00 Uhr und 12:00 Uhr am häufigsten Ladevorgänge begonnen. Aufgrund der vielen Ladestarts treten die Spitzenwerte der durchschnittlichen Ladeleistungen an diesen Tagen um die Mittagszeit auf. (vgl. Abbildung 4.9)




Abbildung 4.11: Ladebeginne des Fahrzeugpools

Es wurde bereits erläutert, dass es sinnvoll ist, die Prognose aufgrund der einzelnen Wochentage aufzustellen. Da sich die einzelnen Wochentage nur durch die geladenen Energiemengen sowie die Ladezeitpunkte unterscheiden, wird für die folgenden Abschnitte ein Wochentag verwendet. Dazu wird der Sonntag gewählt, da an diesem Tag die Werte der aufsummierten Ladeenergien sowohl für Fahrzeug 1 als auch für den gesamten Fahrzeugpool nahe dem Durchschnitt liegen.

In der nachfolgenden Grafik sind die Anzahlen der Ladetage der einzelnen Fahrzeuge des Wochentages Sonntag dargestellt. Hierbei ist zu beachten, dass es sich bei der zur Analyse verwendeten Datengrundlage bereits um die bereinigten Daten handelt.

Laut Abbildung 4.12 sind die Häufigkeiten der Ladetage der einzelnen Elektrofahrzeuge sehr verschieden. Die Anzahl der Ladetage ist bei Fahrzeug 5 am höchsten. Bei diesem Fahrzeug fanden an 40 Tagen Ladevorgänge statt. Die Fahrzeuge mit den geringsten Anzahlen an Ladetagen sind die Fahrzeuge 7 und 9. Diese wurden nur an einem beziehungsweise zwei Tagen geladen. Damit diese beiden selten benutzten Fahrzeuge die weiteren Ergebnisse nicht verfälschen, werden sie für die nächsten Betrachtungen nicht herangezogen.

Nach der Eliminierung dieser beiden Fahrzeuge erhält man für die Anzahl der Ladetage des gesamten Fahrzeugpools 431. Dieser Wert ergibt sich durch die Aufsummierung der Ladetage der einzelnen Fahrzeuge. Damit ergibt sich für die durchschnittlichen Ladetage pro Elektrofahrzeug 18. Bei einem Vergleich dieses Wertes mit der Anzahl der Ladetage von Fahrzeug 1 stellt man fest, dass die Anzahl der Ladetage von Fahrzeug 1 um drei höher ist als der Durchschnitt. Lediglich ein Elektrofahrzeug, das Fahrzeug 15, liegt näher am Durchschnittswert. Diese Tatsache bestätigt die Wahl von Fahrzeug 1 zur Untersuchung der Prognoseverfahren.

Bei der Analyse der Ladeenergien der einzelnen Stunden der verschiedenen Elektrofahrzeuge stellt man fest, dass manche E-Fahrzeuge an einigen Tagen über einen langen Zeitraum mit der gleich großen Leistung geladen wurden. Bei Fahrzeug 5 betrug diese Leistung über einen Zeitraum von 3 Tagen durchgehend 569,3 W. Dadurch würde sich eine geladene Energiemenge von ungefähr 41 kWh ergeben. Dies trat bei drei weiteren Fahrzeugen auf. Da es sich hierbei höchst wahrscheinlich um Aufzeichnungsfehler handelt, werden diese Tage aus den Daten gestrichen.




Abbildung 4.12: Anzahl der Tage, an denen die privat genutzten E-Fahrzeuge geladen wurden

Abbildung 4.13 zeigt die Anzahl der Ladestunden der Elektrofahrzeuge. Dieser Wert ist bei Fahrzeug 5 am höchsten. Dies erscheint logisch, da dieses E-Fahrzeug die meisten Ladetage aufweist. Weiters sind viele Ladestunden bei Fahrzeug 10 und Fahrzeug 21 zu erkennen, was sich ebenfalls aufgrund der hohen Ladetageanzahl ergibt. (vgl. Abbildung 4.12) Die Anzahl der Ladestunden aller Fahrzeuge betrug 2035. Dadurch ergibt sich die durchschnittliche Anzahl der Ladestunden pro E-Fahrzeug zu 85.

Wie bereits bei den Ladetagen liegen auch die durchschnittlichen Ladestunden der untersuchten Elektrofahrzeuge nahe dem Wert von Fahrzeug 1, welches im Zuge dieses Kapitels genauer untersucht wird.




Abbildung 4.13: Anzahl der Ladestunden der privat genutzten E-Fahrzeuge

Mithilfe der in Abbildung 4.12 und 4.13 dargestellten Ergebnisse können die durchschnittlichen Ladestunden pro Ladetag und Fahrzeug ermittelt und dargestellt werden. Die Ergebnisse sind in der nachfolgenden Grafik dargestellt. Die Durchschnittswerte liegen ungefähr zwischen drei und sieben Ladestunden pro Ladetag. Dabei treten wiederum bei Fahrzeug 5 und 21 die Spitzenwerte auf. Dies ergibt sich aufgrund der hohen Anzahl der Ladestunden dieser Elektrofahrzeuge. In der Grafik erkennt man, dass das Fahrzeug 1 an Ladetagen im Durchschnitt 4,3 Stunden lang geladen wurde. Weiters lässt sich mit der Gesamtanzahlen der Ladestunden und Ladetage der Durchschnittswert des gesamten Fahrzeugpools berechnen. Dieser beträgt in etwa 4,7 Ladestunden pro Ladetag.

Die Ladedauer pro Ladetag von Fahrzeug 1 war im Durchschnitt um eine halbe Stunde kürzer als dies im Durchschnitt beim Fahrzeugpool der Fall war.




Abbildung 4.14: Durchschnittliche Ladestunden pro Ladetag der privat genutzten E-Fahrzeuge

Wie bereits früher in diesem Kapitel erläutert wurde, betragen die durchschnittlich geladenen Energiemengen aller Wochentage für Fahrzeug 1 7,8 kWh und für ein durchschnittliches Fahrzeug des gesamten Fahrzeugpools 8,8 kWh.

Da im Zuge der Prognoseverfahrensuntersuchung nur der Wochentag Sonntag verwendet wird, werden für die nachfolgenden Betrachtungen die Durchschnittswerte dieses Wochentages benötigt.

Die geladenen Energiemengen betragen:

- Fahrzeug 1:
 - geladene Energiemenge: 126,4 *kWh*
- Fahrzeugpool:
 - geladene Energiemenge: 3,224 *MWh*
 - durchschnittliche geladene Energiemenge pro Fahrzeug: 134,3 *kWh*

Der Vergleich der Werte der geladenen Energiemengen von Fahrzeug 1 mit der durchschnittlich geladenen Energiemenge pro Fahrzeug des Pools zeigt, dass diese annähernd gleich groß sind. Dies bestätigt wiederum die Wahl von Fahrzeug 1 zur Analysedurchführung.

Mithilfe der geladenen Energiemengen und der Anzahlen der Ladetage können die Werte der durchschnittlich geladenen Energiemengen pro Ladetag des Wochentags Sonntag bestimmt werden.

- Fahrzeug 1:
 - geladene Energiemenge pro Ladetag: 6,02 *kWh*
- Fahrzeugpool:
 - geladene Energiemenge pro Ladetag: 7,5 *kWh*

Aufgrund der bisher ermittelten Energiemengen und der durchschnittlichen Ladestunden pro Ladetag erhält man für die Durchschnittswerte der geladenen Energiemengen pro Stunde:

- Fahrzeug 1:
 - geladene Energiemenge pro Stunde: 1,4 *kWh*
- Fahrzeugpool:
 - geladene Energiemenge pro Stunde: 1,6 *kWh*

Weiters lässt sich bei der Analyse der Daten feststellen, dass an Sonntagen durchschnittlich ungefähr neun Elektrofahrzeuge geladen wurden. Dieser Wert ist um zwei geringer als der Durchschnitt aller Wochentage.

Diese Ergebnisse werden im nächsten Kapitel zur Berechnung der absoluten Fehler der Prognoseverfahren, welche zur Prognoseerstellung der vorliegenden, aufbereiteten Daten verwendet werden können, herangezogen.

4.3 Lastprognosemodell privat genutzter Elektrofahrzeuge

In diesem Teil der Arbeit wird das Lastprognosemodell für privat genutzte Elektrofahrzeuge erstellt.

Zuerst werden die einzelnen Prognoseverfahren, welche im Theorieteil erläutert wurden, mit den Daten von Fahrzeug 1 und dem gesamten Fahrzeugpool untersucht. Im nächsten Abschnitt folgt eine Darstellung der Prognoseergebnisse der Tagesprognose, woraufhin die Ergebnisse der Stundenprognose erörtert werden.

Im Anschluss wird die Realisierung in MATLAB besprochen. Dabei wird auf die Erklärung der einzelnen Funktionen verzichtet, da dies den Umfang dieser Arbeit sprengen würde.

Zum Abschluss werden die Ergebnisse dargestellt und erläutert.

4.3.1 Analyse der Prognoseverfahren

Als Datengrundlage zur Analyse der im Theorieteil erläuterten Prognoseverfahren dienen die Daten, welche im vorherigen Abschnitt aufbereitet und analysiert wurden. Im folgenden Teil werden die einzelnen Verfahren dargestellt und analysiert.

Dabei wird zur Charakterisierung der Verfahren der Mittelwert der relativen Fehlerbeträge herangezogen. Dieser wird ab dem fünften Tag berechnet, da die ersten paar Tage für Initialisierungsschritte benötigt werden.

Bei den untersuchten Datenreihen handelt es sich um aufsummierte Energiewerte, welche miteinander verglichen werden sollen. Deshalb kann zur Bestimmung der relativen Fehler nicht der aktuelle Wert als Bezugswert verwendet werden. Der Grund hierfür liegt darin, dass dieser Bezugswert mit jedem zusätzlichen Tag an dem etwas geladen wurde anwächst, wodurch der relative Fehler immer kleiner wird.

Um die relativen Fehler der einzelnen Tage miteinander vergleichen zu können, wird anstelle des aktuellen Wertes die maximale aufsummierte Energiemenge verwendet, was bei den einzelnen Fahrzeugen sowie dem Fahrzeugpool der gesamten aufsummierten Ladeenergie entspricht.

Laut Kapitel 3.2.2 kann der relative Fehler mithilfe der Formel 3.39 berechnet werden.

Als Auswahlkriterium für das verwendete Prognoseverfahren dient der in Gleichung 4.1 dargestellte Mittelwert der relativen Fehlerbeträge.

$$\overline{|relE_{\%}|} = \frac{1}{n} * \sum_{i=1}^n |relE_{\%}(i)| \quad (4.1)$$

$\overline{|relE_{\%}|}$ Mittelwert der relativen Fehlerbeträge

$|relE_{\%}(i)|$ Betrag des relativen Fehlers von Tag i

n Anzahl der Tage

i Laufvariable

4.3.1.1 Tagesprognosen privat genutzter Elektrofahrzeuge

In Kapitel 3.1.1 wurde erläutert, dass man bei der naiven Prognose zwischen zwei Typen unterscheidet. Dabei wird beim ersten Typ der aktuelle Wert und beim zweiten der aktuelle Wert in Kombination mit dem letzten Trend zur Prognosewertbestimmung verwendet.

Da es sich bei den Datenmengen um aufsummierte Energien handelt, kann der erste Prognosetyp, welcher den aktuellen Wert als Prognosewert annimmt, nicht verwendet werden. Der Grund liegt an der vorhergesagten konstanten aufsummierten Energiemenge. Dies würde bedeuten, dass keine Energie mehr geladen wird, was nur dann der Fall ist, wenn keine Ladevorgänge stattfinden.

Die nachfolgende Abbildung zeigt die Ergebnisse der naiven Prognose bei Annahme des aktuellen Wertes als Prognosewert für das Fahrzeug 1. In der Grafik sind bis zu Tag 16 keine Fehler zu erkennen. Der Grund liegt daran, dass das Fahrzeug von Tag 4 bis 15 an Sonntagen nicht geladen wurde (vgl. Abbildung 4.3) und der Fehler erst ab dem fünften Tag bestimmt wird. Aufgrund des Nichtladens und des verwendeten Prognoseverfahrens stimmt der Prognosewert mit dem tatsächlichen Wert überein, wodurch der Fehler verschwindet.

Außerdem sind an einigen weiteren Tagen relative Fehler von 0% zu erkennen, was ebenfalls dadurch begründet werden kann, dass an diesen Tagen keine Ladevorgänge stattfanden.

Der Mittelwert der relativen Fehlerbeträge ergibt sich zu 2%.




Abbildung 4.15: Naive Prognose mit aktuellem Wert, Fahrzeug 1, Sonntag

Die im Anschluss dargestellte Grafik zeigt die Ergebnisse dieses Prognoseverfahrens bei Verwendung des gesamten Fahrzeugpools als Datengrundlage. Hierbei lassen sich an allen prognostizierten Tagen relative Fehler feststellen. Dies liegt daran, dass an jedem Tag mindestens ein Fahrzeug geladen wurde. Dadurch unterscheiden sich die tatsächlichen Werte von den Prognosewerten, weshalb sich an jedem Tag Fehler ergeben. Der Mittelwert der relativen Fehlerbeträge beträgt 2%.




Abbildung 4.16: Naive Prognose mit aktuellem Wert, Fahrzeugpool, Sonntag

In Abbildung 4.17 sind die relativen Fehler der naiven Prognose bei Verwendung des aktuellen Wertes in Kombination mit dem letzten Trend dargestellt. Hierbei sind an einigen Tagen ebenfalls Fehler von 0% zu erkennen. (vgl. Abbildung 4.15) Dies lässt sich wiederum mithilfe des verwendeten Prognoseverfahrens erklären. Wird das E-Fahrzeug nicht geladen, so liegt kein letzter Trend vor. Dies führt dazu, dass als Prognosewert der aktuelle Wert vorhergesagt wird. Tritt nun erneut ein Tag ohne einen Ladevorgang auf, so stimmt der Prognosewert mit dem tatsächlichen Wert überein und der Fehler liegt bei 0%.

Der Mittelwert der relativen Fehlerbeträge ergibt bei diesem Verfahren 2,39%.




Abbildung 4.17: Naive Prognose mit letztem Trend, Fahrzeug 1, Sonntag

Die nachfolgende Grafik zeigt den relativen Fehler für dieses Prognoseverfahren bei Verwendung des gesamten Fahrzeugpools als Datengrundlage. In der Grafik ist ersichtlich, dass sich die relativen Fehler im Bereich zwischen -2% und +2% befinden. Die Berechnung des Mittelwertes der relativen Fehlerbeträge führt beim Fahrzeugpool zu 0,69%.




Abbildung 4.18: Naive Prognose mit letztem Trend, Fahrzeugpool, Sonntag

Wie es bereits bei der naiven Prognose mit Annahme eines konstanten Wertes als Prognosewert (vgl. Abbildung 4.15 und Abbildung 4.16) der Fall war, ist das in den nächsten beiden Abbildungen dargestellte Brown Verfahren ebenfalls nicht für die Prognose von aufsummierten Datenreihen geeignet. Laut Kapitel 3.1.2 werden bei diesem Verfahren nur geringe Abweichungen vom aktuellen Wert vorausgesagt. Weiters liegen die Prognosewerte im Bereich der bisherigen Werte. Dies bedeutet, dass bei einem aktuellen Energiewert, der an der oberen

Grenze des Bereiches liegt, ein geringerer Wert vorhergesagt wird. Dadurch würde es bei der vorliegenden Datenmenge zu einer Verringerung der aufsummierten gesamten Energiemenge kommen, was jedoch nicht möglich ist. Deshalb kann dieses Verfahren nicht verwendet werden.

Die Berechnung der Mittelwerte der relativen Fehlerbeträge führt bei der Prognose mithilfe dieses Verfahrens sowohl bei Fahrzeug 1 als auch beim gesamten Fahrzeugpool zu 2,2%.




Abbildung 4.19: Brown Verfahren, Fahrzeug 1, Sonntag




Abbildung 4.20: Brown Verfahren, Fahrzeugpool, Sonntag

Das Holt und Winters Prognoseverfahren setzt sich aus den drei Komponenten Trend, Saison und Rest zusammensetzt. (vgl. Kapitel 3.1.3) Dabei wird für die Trendkomponente ein linearer Trend angenommen, welcher aus einem Niveauanteil, der dem arithmetischen Mittel aller bisherigen Werte entspricht, und einem Trendanteil besteht. Aufgrund des kurzen Aufzeichnungszeitraums kann bei der Analyse der Daten kein Einfluss eines Saisonanteils auf die Prognoseergebnisse festgestellt werden.

In der Abbildung 4.21 treten zwischen Tag 10 und 15 relative Fehler von 0% auf. Dies liegt wiederum daran, dass mit dem Elektrofahrzeug von Tag 4 bis 15 nicht gefahren und somit keine

Energie geladen wurde. Die relativen Fehler werden von Tag fünf bis neun immer geringer, da das Prognoseverfahren auf die konstant bleibende Energiemenge reagiert. Ab dem Tag 10 prognostiziert das Verfahren einen konstanten Wert, der mit dem tatsächlichen Wert übereinstimmt, wodurch sich der relative Fehler von 0% ergibt.

Bei der Prognose der aufsummierten geladenen Energiemengen des Fahrzeugpools treten an den meisten Tagen relative Fehler, welche ungleich 0% sind, auf. Dies liegt daran, dass an fast allen Tagen zumindest ein Elektrofahrzeug geladen wurde. Aufgrund dessen unterscheiden sich die Prognosewerte von den tatsächlichen Werten, weshalb sich die besagten relativen Fehler ergeben.

Die Mittelwerte der relativen Fehlerbeträge ergeben sich bei diesem Verfahren zu 2,35% bei Fahrzeug 1 und 0,73% beim gesamten Fahrzeugpool.




Abbildung 4.21: Holt-Winters Verfahren, Fahrzeug 1, Sonntag




Abbildung 4.22: Holt-Winters Verfahren, Fahrzeugpool, Sonntag

Ein ARIMA[p, d, q]-Prozess setzt sich aus einem Autoregressiven- und einem Moving-Average - Prozess sowie einem Integrationsteil zusammen. (vgl. Kapitel 3.1.4.2) Für die vorliegenden Datenreihen wird ein ARIMA[p, d, q]-Prozess mit der Ordnung $p = q = d = 1$ gewählt, da dieser die besten Prognoseergebnisse mit dem geringsten Fehler liefert.

Die Mittelwerte der relativen Fehlerbeträge betragen 2,45% bei Verwendung von Fahrzeug 1 als Datengrundlage und 0,74% beim gesamten Fahrzeugpool.




Abbildung 4.23: ARIMA Verfahren, Fahrzeug 1, Sonntag




Abbildung 4.24: ARIMA Verfahren, Fahrzeugpool, Sonntag

Bei neuronalen Netzen versucht man das natürliche Nervensystem nachzubilden, wobei das künstliche Netz aus einer Vielzahl von Neuronen besteht. (vgl. Kapitel 3.1.6) Bei der Prognose wird zuerst der Trainingsmodus ausgeführt. Dabei werden dem Netz feste Eingangs- und die dazugehörigen Ausgangselemente übergeben. Anschließend werden mithilfe des Prinzips der Fehlerminimierung die Parameter der Datenreihe ermittelt.

Danach folgt der sogenannte Abbildungsmodus, bei dem die Vorhersage der unbekannten Ausgangsgrößen durchgeführt wird.

Bei der Prognose mithilfe dieses Verfahrens ist zu beachten, dass eine Prognose nicht reproduzierbar ist. Der Grund liegt daran, dass die Parameter bei jedem Simulationsvorgang neu gelernt werden.

Wie es bereits beim Brown Verfahren und bei der naiven Prognose mit Annahme eines konstanten Wertes als Prognosewert der Fall war, kann es auch hier vorkommen, dass geringere Werte als die aktuellen aufsummierten Energien prognostiziert werden, was jedoch nicht möglich ist, da die Gesamtmenge der geladenen Energie nicht abnehmen kann. Dieses Problem lässt sich lösen, indem man die Prognose mehrmals durchführt bis ein größerer Wert als die gesamt geladene Energiemenge vorhergesagt wird.

Der Berechnung der Mittelwerte der relativen Fehlerbeträge liefert für Fahrzeug 1 2,78% und für den gesamten Fahrzeugpool 1,26%.




Abbildung 4.25: Neuronale Netze Verfahren, Fahrzeug 1, Sonntag




Abbildung 4.26: Neuronale Netze Verfahren, Fahrzeugpool, Sonntag

Laut [1] ist nicht jedes Prognoseverfahren zur Prognoseerstellung jeder beliebigen Datenreihe geeignet. Bei der Analyse der im Theorieteil erläuterten Verfahren mit den vorliegenden Datenmengen hat sich gezeigt, dass die naive Prognose mit Annahme eines konstanten Werts als Prognosewert und das Brown Verfahren im Zuge dieser Arbeit nicht zur Vorhersage des Energiebedarfs von Elektrofahrzeugen verwendet werden können.

Aufgrund der vorangegangenen Erkenntnisse eignen sich die folgenden vier Verfahren zur Prognose der Ladeenergiemengen von Elektrofahrzeugen.

- Naive Prognose mit Verwendung des aktuellen Wertes und des letzten Trends
- Holt–Winters Verfahren
- ARIMA Verfahren
- Neuronale Netze

In Tabelle 4.1 sind die Mittelwerte der relativen Fehlerbeträge dieser Verfahren für den gesamten Fahrzeugpool sowie für Fahrzeug 1 abgebildet. Bei einem Vergleich der Fehler der verschiedenen Verfahren kann man feststellen, dass die beiden einfacheren Prognoseverfahren naive Prognose und das Holt–Winters Verfahren bessere Ergebnisse liefern als die beiden komplizierteren Verfahren ARIMA und künstlich neuronale Netze. In [1] wird erläutert, dass kein bestimmtes Prognoseverfahren für alle Datenreihen die besten Ergebnisse liefert. Es kann vorkommen, dass ein einfacher zu realisierendes Verfahren bessere Ergebnisse liefert als ein kompliziertes. Dies ist möglich, wenn ein Prognoseverfahren dessen Vorteile nicht ausnutzen kann.

Beim ARIMA Verfahren ist es zum Beispiel möglich, externe Einflussgrößen wie etwa die Temperatur miteinzubeziehen. Dadurch kann ein besseres Prognoseergebnis erreicht werden. In den vorliegenden Datenmengen, welche im Zuge dieser Arbeit verwendet wurden, erfolgten lediglich die Aufzeichnung der geladenen Energiemengen und die Ladungszeitpunkte. Jedoch stehen keine Daten weiterer Einflussgrößen zur Verfügung, weshalb die Vorteile dieses Verfahrens nicht verwendet werden können. Deshalb liefern die einfacheren Prognoseverfahren bessere Ergebnisse.

Ähnliche Gegebenheiten zeigen sich bei der Prognose mithilfe von neuronalen Netzen. Bei diesem Verfahren werden dem Netz im Lernmodus Eingangsgrößen und die dazugehörigen bekannten Ausgangsgrößen übergeben, woraufhin es selbstständig die Einflussparameter lernt. Nach dem Lernen der Einflussparameter werden dem Netz im sogenannten Abbildungsmodus Eingangsgrößen übergeben deren zugehörige Ausgangsgrößen mit den erlernten Parametern berechnet werden. (vgl. Kapitel 3.1.6) Ändern sich nun zum Beispiel die Eingangsgrößen derart,

dass die im Lernmodus ermittelten Parameter nicht mehr korrekt sind, dann kommt es zu Prognoseabweichungen. Diese zeigen sich in einem erhöhten Prognosefehler.

Vergleicht man Fahrzeug 1 mit dem Fahrzeugpool so stellt man fest, dass die Mittelwerte der relativen Fehlerbeträge beim Pool geringer sind. Dies lässt sich durch den wesentlich glatteren Verlauf des Fahrzeugpools sowie den höheren Bezugswert bei der Fehlerbestimmung, welcher sich aufgrund der gesamten aufsummierten Energie ergibt, erklären.

Bei der Implementierung des Prognosemodells ist es sinnvoll, bei jeder Prognoseerstellung jeden Wochentag mit den einzelnen Prognoseverfahren zu analysieren und anschließend das Verfahren mit dem geringsten Fehler auszuwählen. Es ist denkbar, dass ein Prognoseverfahren, welches für einen bestimmten Wochentag und ein bestimmtes Fahrzeug am geeignetsten ist, nicht immer das Verfahren mit dem geringsten Fehler sein wird. Es ist möglich, dass sich die benötigten Ladeenergiemengen ändern, was zum Beispiel durch eine Effizienzsteigerung im Sektor der Elektromobilität oder durch eine Änderung des Fahrverhaltens erfolgen kann. Dadurch ändern sich die zur Prognose verwendeten Daten, weshalb das bisher verwendete Prognoseverfahren nicht mehr die geringsten Fehler liefert. Außerdem könnte man weitere Parameter wie etwa die Temperatur oder die Art der Fahrtstrecke erfassen und in die Prognose miteinbeziehen. Dadurch würden sich etwa die Ergebnisse des ARIMA-Verfahrens, welches diese Parameter berücksichtigt, verbessern.

	Fahrzeugpool	Fahrzeug 1
Naive Prognose	0,69%	2,39%
Holt - Winters Verfahren	0,73%	2,35%
ARIMA Verfahren	0,74%	2,45%
Neuronale Netze	1,26%	2,78%

Tabelle 4.1: Mittelwerte der relativen Fehlerbeträge der Tagesprognose, Wochentag: Sonntag

Mithilfe der durchschnittlichen geladenen Energiemengen pro Ladetag, welche im Zuge der Datenaufbereitung in Kapitel 4.2.1 ermittelt wurden, und der in Tabelle 4.1 dargestellten Ergebnisse können die absoluten Fehler der geladenen Energiemengen berechnet werden.

Die gerundeten durchschnittlich geladenen Energiemengen pro Ladetag betragen:

- Fahrzeugpool, Durchschnitt pro Fahrzeug: 7,5 kWh
- Fahrzeug 1: 6 kWh

Aufgrund der durchschnittlich geladenen Energiemenge pro Fahrzeug des Fahrzeugpools und der Anzahl der durchschnittlich geladenen Fahrzeuge pro Sonntag, welche neun beträgt, ergibt sich die gesamte geladene Energie des Fahrzeugpools an Sonntagen zu $67,5 \text{ kWh}$.

In der nachfolgenden Tabelle sind die Mittelwerte der absoluten Fehler vom Wochentag Sonntag dargestellt. Die mittleren absoluten Prognosefehler der geladenen Energiemengen pro Tag liegen beim gesamten Fahrzeugpool zwischen 466 Wh und 851 Wh.

Die durchschnittlichen absoluten Fehler eines durchschnittlichen Fahrzeuges des Fahrzeugpools liegen zwischen 52 Wh und 95 Wh. Vergleicht man diese Ergebnisse mit jenen von Fahrzeug 1, so stellt man bei Fahrzeug 1 ungefähr zwei- bis dreimal höhere absolute Fehler fest. Dies liegt an den unterschiedlichen Datenmengen. Wie bereits früher erläutert wurde, weisen die Daten des Fahrzeugpools einen glatteren Verlauf als jene von Fahrzeug 1 auf. Außerdem ist der Bezugswert, welcher zur Bestimmung der relativen Fehler verwendet wird, beim Fahrzeugpool viel größer. Deshalb ergeben sich geringere relative Fehler. (vgl. Tabelle 4.1) Aufgrund dieser Umstände werden bei der Prognoseerstellung des Datenpools bessere Ergebnisse mit geringeren Fehlern erzielt.

	Fahrzeugpool		Fahrzeug 1
	gesamter Pool	Durchschnitt pro Fahrzeug	
Naive Prognose	466 Wh	52 Wh	143 Wh
Holt – Winters Verfahren	493 Wh	55 Wh	141 Wh
ARIMA Verfahren	500 Wh	56 Wh	147Wh
Neuronale Netze	851 Wh	95 Wh	167 Wh

Tabelle 4.2: Mittelwerte der absoluten Fehler pro Tag der Tagesprognose, Wochentag: Sonntag

In den nächsten beiden Tabellen und Abbildungen sind einige ausgewählte Quantile der relativen Fehlerbeträge von Fahrzeug 1 beziehungsweise vom gesamten Fahrzeugpool dargestellt. Laut [16] stellt ein Quantil einen Schwellenwert dar, wobei ein bestimmter Anteil der Werte kleiner als dieser Schwellenwert ist und der Rest größer. Beim 50%-Quantil handelt es sich zum Beispiel um jenen Referenzwert, für den gilt, dass 50% aller Werte kleiner sind als der Referenzwert. Dieses Quantil wird auch als Median bezeichnet. In Tabelle 4.3 stellt man bei der naiven Prognose fest, dass das 25%-Quantil bei 0% liegt. 25% aller Werte sind also kleiner gleich 0%. Dies ergibt sich dadurch, dass die naive Prognose von Fahrzeug 1 an vielen Tagen einen relativen Fehler von 0% aufweist. (vgl. Abbildung 4.17) Die Gründe dafür wurden bereits in Kapitel 4.3.1 erörtert.

Vergleicht man die Werte der 100%-Quantile der untersuchten Prognoseverfahren, so erkennt man annähernd gleich große Werte. Die relativen Fehlerbeträge liegen maximal 1,43% auseinander. Weiters weist das 100%-Quantil bei der naiven Prognose den höchsten Wert auf, was daran liegt, dass bei diesem Prognoseverfahren die größte Prognoseabweichung auftritt.

In Abbildung 4.27 ist ersichtlich, dass der Bereich der einzelnen Quantile mit zunehmender Quantilgröße größer wird. So liegen zum Beispiel die Werte der 100%-Quantile der einzelnen Prognoseverfahren deutlich weiter auseinander als die der 50%-Quantile. Dies liegt an der wachsenden Schwankungsbreite mit zunehmender Anzahl von Werten.

	Fahrzeug 1				
	25%-Quantil	50%-Quantil	75%-Quantil	90%-Quantil	100%-Quantil
Naive Prognose	0,00%	0,81%	4,42%	7,53%	11,29%
Holt – Winters Verfahren	0,29%	1,20%	3,83%	5,89%	10,91%
ARIMA Verfahren	0,59%	1,56%	4,13%	6,23%	10,29%
Neuronale Netze	0,60%	1,69%	3,96%	7,21%	9,86%

Tabelle 4.3: Quantile von Fahrzeug 1, Wochentag: Sonntag




Abbildung 4.27: Darstellung der Quantile von Fahrzeug 1, Wochentag: Sonntag

In Tabelle 4.4 sind die Quantile des gesamten Fahrzeugpools aufgelistet. Bei einem Vergleich mit Tabelle 4.3 stellt man deutlich kleinere Quantilwerte als bei Fahrzeug 1 fest. Dies liegt an den kleineren Prognosefehlern des Fahrzeugpools.

Bei einer Gegenüberstellung der beiden 25% Quantile von Fahrzeug 1 mit dem Fahrzeugpool erkennt man annähernd gleich große Werte. Eine Ausnahme tritt bei der naiven Prognose auf. Hier liegt das 25%-Quantil bei 0,29% und nicht bei 0% wie dies bei Fahrzeug 1 der Fall ist. Der Grund hierfür liegt an den Ladetagen des Fahrzeugpools. Beim gesamten Pool wurden an fast allen Tagen Ladevorgänge durchgeführt. Dadurch ist der letzte Trend, welcher bei diesem Prognoseverfahren verwendet wird, nur sehr selten null. (vgl. Abbildung 4.18) Aufgrund dessen gibt es an den meisten Tagen eine Abweichung des Prognosewertes vom tatsächlich geladenen Wert, wodurch sich an allen Ladetagen relative Fehler ergeben.

Vergleicht man die 100%-Quantile der vier Prognoseverfahren, so kann man große Unterschiede feststellen. Die Werte des ARIMA Verfahrens und der neuronalen Netze sind in etwa doppelt so groß wie jene der beiden anderen Verfahren. Allerdings stellt man bei genauerer Betrachtung des 90%-Quantils beim ARIMA-Verfahren ähnlich große Werte als beim Holt-Winters Verfahren und bei der naiven Prognose fest. Daraus lässt sich schließen, dass sich die deutlich höheren Werte beim 100%-Quantil beim ARIMA Verfahren in Bezug auf das Holt-Winters Verfahren und der naiven Prognose aufgrund von wenigen Ausreißern ergeben.

Dies ist bei neuronalen Netzen nicht zu erkennen. Bei einem Vergleich mit den anderen Verfahren stellt man bei den neuronalen Netzen bei allen Quantilen ungefähr doppelt so große Werte fest. Einzige Ausnahme bildet, wie eben erläutert, das 100%-Quantil des ARIMA Verfahrens.

	Fahrzeugpool				
	25%-Quantil	50%-Quantil	75%-Quantil	90%-Quantil	100%-Quantil
Naive Prognose	0,29%	0,69%	1,00%	1,23%	1,95%
Holt – Winters Verfahren	0,39%	0,74%	0,98%	1,27%	2,33%
ARIMA Verfahren	0,35%	0,56%	1,00%	1,30%	4,48%
Neuronale Netze	0,66%	1,19%	1,86%	2,41%	4,48%

Tabelle 4.4: Quantile des gesamten Fahrzeugpools, Wochentag: Sonntag




Abbildung 4.28: Darstellung der Quantile des gesamten Fahrzeugpools, Wochentag: Sonntag

4.3.1.2 Stundenprognosen privat genutzter Elektrofahrzeuge

Die in Kapitel 4.3.1.1 dargestellte Tagesprognose ermöglicht die Vorhersage des Energiebedarfs eines ganzen Tages. Da im Zuge dieser Arbeit eine Prognoseschrittweite von einer Stunde gewählt wurde, ist es zusätzlich erforderlich, eine Stundenprognose für den zu prognostizierenden Tag aufzustellen. Wie schon bei der Tagesprognose wird auch zur Analyse der Stundenprognose das Fahrzeug 1 sowie der gesamte Fahrzeugpool gewählt. Dabei werden wiederum die Daten des Sonntages verwendet.

Bei einer Prognose mit einer Prognoseschrittweite von einer Stunde wird für jede einzelne Stunde eine Vorhersage getroffen, wobei als Datengrundlage dieselbe Stunde der bisherigen Tage dient. Die Erstellung der Stundenprognose erfolgt ebenfalls mithilfe der aufsummierten Datenreihen, woraufhin eine Rückrechnung auf die jeweiligen Stundenwerte des gewünschten Tages durchgeführt wird. Außerdem muss beachtet werden, dass der Prognosewert einer bestimmten Stunde von den bisherigen Stundenwerten des aktuellen Tages abhängig ist.

Auf eine Untersuchung des Brown Verfahrens und der Naiven Prognose mit Annahme eines konstanten Wertes als Prognosewert wird verzichtet, da diese Verfahren für aufsummierte

Datenreihen nicht verwendet werden können. Dies wurde im vorangegangenen Kapitel bereits erläutert.

In Tabelle 4.5 sind die Ergebnisse der Stundenprognose für die zur Lösung der Problemstellung verwendbaren Prognoseverfahren abgebildet, wobei die Mittelwerte der relativen Fehlerbeträge für die einzelnen Stunden sowie für den gesamten Tag berechnet wurden. Auf eine Darstellung der Fehlerdiagramme der einzelnen Verfahren wird hier verzichtet.

Blickt man auf die Ergebnisse so stellt man fest, dass die beiden komplizierteren Verfahren ARIMA und neuronale Netze auch für die Stundenprognose schlechtere Ergebnisse erzielen als die einfacheren beiden Prognoseverfahren. Außerdem sind die Mittelwerte der relativen Fehlerbeträge beim Fahrzeugpool geringer als bei Fahrzeug 1. Dies lässt sich einerseits wiederum durch die höhere aufsummierte Energiemenge, welche als Bezugswert zur Fehlerbestimmung verwendet wird, begründen. Andererseits stehen beim Fahrzeugpool mehr Werte zur Prognosebestimmung zur Verfügung, wodurch bessere Ergebnisse erreicht werden.

Vergleicht man die Prognosefehler der verschiedenen Verfahren in den einzelnen Stunden so kann man feststellen, dass das Holt-Winters Prognoseverfahren für den Fahrzeugpool am Wochentag Sonntag für alle Stunden den geringsten Fehler aufweist.

Bei der Analyse der Ergebnisse von Fahrzeug 1 stellt man bei keinem Verfahren für alle Stunden das beste Prognoseresultat fest. Deshalb ist es sinnvoll, alle Stunden mit den einzelnen Verfahren zu prognostizieren und anschließend für jede Stunde jenes auszuwählen, welches den geringsten Fehler aufweist.

In der Tabelle ist zu erkennen, dass die Prognose mithilfe der neuronalen Netze sowohl für den Fahrzeugpool als auch für Fahrzeug 1 die schlechtesten Ergebnisse liefert. Da bei diesem Verfahren die größten Fehler auftreten und die Prognoseergebnisse der anderen drei Verfahren nur geringe Fehlerunterschiede aufweisen, wird im Zuge dieser Arbeit sowohl für den Fahrzeugpool als auch für das Fahrzeug 1 das Holt-Winters Verfahren zur Erstellung der Stundenprognose verwendet. Dadurch kann die Berechnungszeit der Prognose niedrig gehalten werden.

Verfahren: Stunde:	Fahrzeugpool				Fahrzeug 1			
	Naive Prognose	Holt Winters	ARIMA	Neuronale Netze	Naive Prognose	Holt Winters	ARIMA	Neuronale Netze
00:00 - 01:00	1,3%	1,3%	1,5%	2,7%	3,1%	2,6%	4,1%	9,3%
01:00 - 02:00	1,9%	1,3%	1,9%	3,2%	3,6%	2,9%	4,5%	6,2%
02:00 - 03:00	2,0%	1,5%	2,2%	4,5%	3,7%	2,6%	3,2%	5,4%
03:00 - 04:00	2,3%	1,8%	2,9%	6,2%	3,0%	2,8%	3,0%	7,0%
04:00 - 05:00	2,3%	1,8%	3,1%	6,1%	3,6%	2,5%	2,8%	5,2%
05:00 - 06:00	2,5%	1,9%	3,3%	5,3%	3,9%	2,6%	3,0%	7,1%
06:00 - 07:00	2,8%	1,9%	3,0%	6,0%	3,2%	3,1%	2,9%	7,0%
07:00 - 08:00	1,9%	1,8%	2,1%	3,8%	3,4%	2,6%	3,0%	3,7%
08:00 - 09:00	1,8%	1,4%	1,8%	2,4%	2,8%	3,5%	4,3%	2,9%
09:00 - 10:00	1,5%	1,3%	1,4%	2,0%	2,4%	3,0%	3,4%	4,0%
10:00 - 11:00	1,4%	1,2%	1,2%	1,8%	2,9%	2,9%	2,6%	3,8%
11:00 - 12:00	1,1%	1,0%	1,2%	1,4%	2,8%	2,7%	3,9%	6,7%
12:00 - 13:00	0,9%	0,9%	1,1%	1,2%	2,8%	2,6%	3,4%	10,0%
13:00 - 14:00	0,9%	0,9%	1,1%	1,3%	2,9%	2,7%	3,0%	4,7%
14:00 - 15:00	1,1%	1,0%	1,3%	1,5%	2,9%	2,8%	3,2%	5,4%
15:00 - 16:00	1,2%	1,1%	1,3%	1,6%	3,3%	2,8%	3,3%	6,5%
16:00 - 17:00	1,1%	1,0%	1,2%	1,4%	2,9%	2,6%	3,2%	7,2%
17:00 - 18:00	1,2%	0,9%	1,4%	1,9%	3,1%	2,7%	3,0%	7,2%
18:00 - 19:00	1,4%	0,9%	1,5%	2,0%	3,5%	2,8%	3,6%	6,7%
19:00 - 20:00	1,5%	1,0%	1,6%	2,1%	3,3%	2,7%	3,6%	6,6%
21:00 - 22:00	1,2%	1,0%	1,4%	2,4%	3,3%	2,9%	3,8%	6,5%
20:00 - 21:00	1,3%	1,2%	1,6%	2,5%	3,5%	2,7%	3,2%	9,6%
22:00 - 23:00	1,5%	1,3%	1,6%	2,5%	3,8%	2,7%	3,7%	6,8%
23:00 - 24:00	1,6%	1,3%	1,7%	2,8%	3,6%	2,8%	3,7%	5,0%
mittlerer Fehler:	1,6%	1,3%	1,8%	2,9%	3,2%	2,8%	3,4%	6,3%

Tabelle 4.5: Mittelwerte der relativen Fehlerbeträge der Stundenprognose

Im Zuge der Datenanalyse wurden die durchschnittlich geladenen Energiemengen pro Stunde und Fahrzeug sowie die Ladestunden pro Ladetag und Fahrzeug ermittelt. Diese betragen:

- Fahrzeug 1:
 - 1,4 kWh / Stunde
 - 4,3 Ladestunden / Ladetag
- Fahrzeugpool, Durchschnitt pro Fahrzeug:
 - 1,6 kWh / Stunde und Fahrzeug
 - 4,7 Ladestunden / Ladetag

Mithilfe dieser Werte lassen sich nun die absoluten Fehler der Stundenprognose berechnen.

In der nachfolgenden Tabelle sind die durchschnittlichen absoluten Prognosefehler der Stundenprognose pro Stunde dargestellt. Die Ergebnisse zeigen, dass die absoluten Fehler pro Stunde der Stundenprognose eines durchschnittlichen Fahrzeuges des Fahrzeugpools zwischen 21 Wh und 46 Wh liegen. Die absoluten Fehler von Fahrzeug 1 befinden sich im Intervall zwischen 39 Wh und 88 Wh. Bei Vernachlässigung des Verfahrens der neuronalen Netze, welches einen viel höheren Prognosefehler als die anderen drei Verfahren hat, erkennt man nur geringe Abweichungen. Die absoluten Fehler eines Fahrzeuges des Fahrzeugpools unterscheiden

sich um maximal 8 Wh und die von Fahrzeug 1 um höchstens 9 Wh. Diese geringen Unterschiede bestätigen die, im Zuge dieses Kapitels vorgenommene Auswahl eines Verfahrens zur Erstellung der Stundenprognose. Hierfür wurde das Holt-Winters Verfahren gewählt.

	Fahrzeugpool, ein Fahrzeug	Fahrzeug 1
Naive Prognose	26 Wh	45 Wh
Holt – Winters Verfahren	21 Wh	39 Wh
ARIMA Verfahren	29 Wh	48 Wh
Neuronale Netze	46 Wh	88 Wh

Tabelle 4.6: Mittelwerte der absoluten Fehler der Stundenprognose pro Stunde

Mit den Werten aus Tabelle 4.6 können die durchschnittlichen absoluten Fehler pro Ladetag aufgrund der absoluten Fehler der Stundenprognose ermittelt werden. Dazu werden die Ergebnisse aus der vorhergehenden Tabelle mit der Anzahl der durchschnittlichen Ladestunden pro Ladetag multipliziert.

	Fahrzeugpool, ein Fahrzeug	Fahrzeug 1
Naive Prognose	122 Wh	194 Wh
Holt – Winters Verfahren	99 Wh	168 Wh
ARIMA Verfahren	136 Wh	206 Wh
Neuronale Netze	216 Wh	378 Wh

Tabelle 4.7: Mittelwerte der absoluten Fehler der Stundenprognose pro Tag

Vergleicht man die Ergebnisse der durchschnittlichen absoluten Prognosefehler des Tages, welche aufgrund der Stundenprognose (vgl. Tabelle 4.7) ermittelt wurden, mit jenen der Tagesprognose (vgl. Tabelle 4.2), so stellt man fest, dass sich diese unterscheiden. Die absoluten Tagesprognosefehler in Tabelle 4.7 sind größer als jene in Tabelle 4.2. Die Werte von Fahrzeug 1 unterscheiden sich um den Faktor 1,2 – 2,3. Der Hauptgrund für diese Abweichungen ergibt sich aus den Ergebnissen der Stundenprognose. Das Fahrzeug 1 wurde an 21 Tagen insgesamt 90 Stunden geladen. Aufgrund dieser geringen Stundenanzahl, welche als Datengrundlage zur Prognose aller 24 Stunden des Tages dient, stehen nur wenige Werte für die Prognoseerstellung der einzelnen Stunden zur Verfügung. Deshalb treten bei der Prognose größere Abweichungen und damit höhere Prognosefehler auf.

Bei der Gegenüberstellung der absoluten Tagesprognosefehler der Tagesprognose eines durchschnittlichen Fahrzeuges des Pools (vgl. Tabelle 4.2) mit jenen auf Grundlage der

Stundenprognose (vgl. Tabelle 4.7) bemerkt man ebenfalls Abweichungen. Hierbei unterscheiden sich die Werte um den Faktor 1,8 – 2,4. Dies liegt wiederum an der geringen Anzahl der Werte, die als Datengrundlage für die Stundenprognose zur Verfügung stehen.

Vergleicht man die Werte aus Tabelle 4.7 eines durchschnittlichen Fahrzeuges des Pools mit jenen von Fahrzeug 1, so bemerkt man bei Fahrzeug 1 höhere absolute Prognosefehler. Dies liegt daran, dass beim Fahrzeugpool mehr Stunden zur Prognoseerstellung zur Verfügung stehen, wodurch bessere Prognoseergebnisse erreicht werden. Außerdem wurden beim Fahrzeugpool höhere Energiemengen geladen, wodurch sich eine größere gesamt geladene Energie ergibt. Da diese als Bezugswert zur Fehlerbestimmung verwendet wird, sind die relativen Fehler (vgl. Tabelle 4.5) und somit die absoluten Abweichungen des Fahrzeugpools geringer.

4.3.2 Realisierung

Ziel dieses Unterkapitels ist die Erstellung eines MATLAB-Programms, welches eine Prognose der benötigten Ladeenergiemenge von privat genutzten Elektrofahrzeugen liefert. Dabei werden der Aufbau des MATLAB-Programms, das grafische User Interface und die Ergebnisse näher erläutert.

4.3.2.1 MATLAB - Programm

Die nachfolgende Abbildung zeigt das Strukturbild des MATLAB-Programms. Als Eingangsparameter für das Modell dient der von der Modellregion Köstendorf zur Verfügung gestellte Datenpool, welcher sich aus 26 Fahrzeugen zusammensetzt. Von den Fahrzeugen wurden die Ladeleistungen sowie deren Ladezeiten protokolliert.

Beim entwickelten MATLAB Modell kann zwischen 2 verschiedenen Modi gewählt werden.

Im Modus 1 können die Prognoseergebnisse der verschiedenen Verfahren für die vorhandenen Datenreihen der einzelnen Fahrzeuge sowie des gesamten Fahrzeugpools dargestellt werden.

Modus 2 wird dazu verwendet um eine Prognose der benötigten Energiemengen des aktuellen sowie des folgenden Tages mit einer Prognoseschrittweite von einer Stunde aufzustellen. Eine genauere Erläuterung der beiden Modi erfolgt im nächsten Abschnitt.




Abbildung 4.29: privat genutzte E-Fahrzeuge, MATLAB-Modell

Beim Ausführen des MATLAB-Programms erscheint das in Abbildung 4.30 dargestellte grafische User Interface. Dabei kann zwischen den beiden Modi

- Modus 1: Daten darstellen und
- Modus 2: Prognose

gewählt werden.




Abbildung 4.30: privat genutzte E-Fahrzeuge, Modus Auswahl

Modus 1 dient zur Darstellung der in Kapitel 4.3.1.1 untersuchten Prognoseverfahren, wobei als Prognoseschrittweite ein Tag verwendet wird. Bei der Wahl dieses Modus erscheint die in der folgenden Abbildung dargestellte Eingabemaske, wobei drei Parameter variiert werden können.




Abbildung 4.31: privat genutzte E-Fahrzeuge, Modus 1, Eingabemaske

Im Auswahlfeld Fahrzeug(e) wird festgelegt, von welchen Fahrzeugen die Ergebnisse der Prognose dargestellt werden. Hierbei ist eine Unterscheidung zwischen den einzelnen Fahrzeugen beziehungsweise dem gesamten Fahrzeugpool möglich.

Nach Wahl des gewünschten Fahrzeuges beziehungsweise des Fahrzeugpools folgt die Auswahl des gewünschten Tages, wobei zwischen den einzelnen Wochentagen und der gesamten Woche unterschieden werden kann. Bei Wahl eines bestimmten Wochentages wird als Datengrundlage zur Prognoseerstellung der gewählte Wochentag verwendet. Wählt man hingegen die gesamte Woche, so dienen als Datengrundlage alle aufgezeichneten Tage.

Als letzter Parameter wird das verwendete Prognoseverfahren bestimmt. Dabei kann zwischen den folgenden Prognoseverfahren, welche in Kapitel 3 analysiert wurden, selektiert werden:

1. Naive Prognose mit Annahme eines konstanten Wertes als Prognosewert
2. Naive Prognose mit Annahme eines konstanten Wertes zuzüglich des letzten Trends als Prognosewert
3. Brown Verfahren
4. Holt-Winters Verfahren
5. ARIMA Verfahren
6. Neuronale Netze

In Kapitel 4.3.1.1 wurde festgestellt, dass die Verfahren 1 und 3 nicht für die Prognose der vorliegenden Datenreihen geeignet sind, weshalb diese bei Auswahl von Modus 2 keine Berücksichtigung finden.

Nachdem die Parameter gewählt wurden, können die Ergebnisse berechnet werden.

In Abbildung 4.32 und 4.33 sind die Prognoseergebnisse für Fahrzeug 1 beziehungsweise für den gesamten Fahrzeugpool dargestellt, wobei als Tag der Sonntag und als Prognoseverfahren die naive Prognose mit Annahme eines konstanten Wertes zuzüglich des letzten Trends verwendet wird.

Blickt man auf die Abbildungen so kann man jeweils 2 Verläufe erkennen. Bei den linken Grafiken handelt es sich um die Differenz zwischen den prognostizierten und den tatsächlichen aufsummierten geladenen Energien und bei den rechten um die relativen Prognosefehler. Weiters erfolgt eine Bestimmung der Mittelwerte der relativen Fehlerbeträge, wodurch sich die Ergebnisse der einzelnen Prognoseverfahren miteinander vergleichen lassen.

Der Vergleich von Fahrzeug 1 mit dem Fahrzeugpool zeigt, dass die Prognosen des Pools bessere Ergebnisse liefern. Dies ist einerseits auf den höheren Bezugswert bei der Fehlerbestimmung zurückzuführen. Weiters weisen die Daten einen gleichmäßigeren Verlauf auf, weshalb ebenfalls bessere Prognoseergebnisse erreicht werden.

In Abbildung 4.32 ist zu erkennen, dass der relative Fehler dann die höchsten Werte aufweist, wenn sich die aufsummierte Energie vor einem größeren Anstieg einige Tage nicht beziehungsweise nur gering geändert hat. Der Grund hierfür liegt darin, dass das Prognoseverfahren bei den vorliegenden aufsummierten Energiemengen bei gleichbleibenden

4 Privat genutzte Elektrofahrzeuge

Werten über einige Tage keine Änderung mehr vorhersagen. Dadurch führt eine Änderung der tatsächlich geladenen Energie zu einem hohen Fehler, da das Prognoseverfahren erst auf die Änderung reagieren muss.




Abbildung 4.32: privat genutzte E-Fahrzeuge, Modus 1, Fahrzeug 1, Sonntag




Abbildung 4.33: privat genutzte E-Fahrzeuge, Modus 1, Fahrzeugpool, Sonntag

Bei Auswahl von Modus 2 erscheint das in der folgenden Abbildung dargestellte Eingabefenster. Hierbei kann neben dem Fahrzeug beziehungsweise dem Fahrzeugpool und dem Prognoseverfahren ein Datum und eine aktuelle Stunde eingegeben werden, wobei das angegebene Datum dem untersuchten Tag und die Stunde der Tagesuhrzeit entspricht. Bei einer Wahl der Parameter wie in Abbildung 4.26 bedeutet dies, dass die Prognose für den 11.8.2014 ab 12:00 Uhr erstellt wird. Außerdem erfolgt eine Prognose der Energiemenge des nächsten Tages. Für die nachfolgenden Betrachtungen dieses Kapitels wird die Annahme getroffen, dass das ausgewählte Datum nicht dem letzten Ladetag der aufgezeichneten Daten entspricht. Dadurch können die Prognosewerte mit den tatsächlichen Werten der geladenen Energien verglichen werden.



Abbildung 4.34: privat genutzte E-Fahrzeuge, Modus 2, Eingabemaske

Nach Auswahl der Parameter kann die Berechnung der Prognose durchgeführt werden. In den nächsten beiden Abbildungen sind die Ergebnisse von Fahrzeug 1 beziehungsweise vom gesamten Fahrzeugpool dargestellt. Dabei werden als Datengrundlage zur Erstellung der Prognosen jeweils die bisherigen Energien des ausgewählten Wochentages verwendet. Dies bedeutet für die ausgewählten Parameter, dass für den aktuellen Tag alle bisherigen Montage und für den folgenden Tag alle bisherigen Dienstage als Datengrundlage zur Prognoseerstellung dienen.

Bei der Vorhersage des Energiebedarfes des aktuellen Tages wird zuerst die benötigte Energie des gesamten Tages bestimmt. Anschließend erfolgt nach der Ermittlung der Energie, welche bereits geladen wurde, eine Rückrechnung auf die laut Prognose noch zu ladende Energiemenge.

Um die Ergebnisse der Prognose beurteilen zu können erfolgt zum Abschluss eine Ermittlung der tatsächlich geladenen Energiemenge des aktuellen Tages. Neben den Energiemengen wird der Prognosefehler für den aktuellen Tag berechnet.

Nach der Ermittlung dieser Größen wird der relative Fehler dargestellt und der Mittelwert der Fehlerbeträge bestimmt, anhand dessen die Qualität der einzelnen Prognoseverfahren miteinander verglichen werden kann.

Im Anschluss erfolgt die Ermittlung und Darstellung der Ladeverteilung der einzelnen Stunden. Dabei werden zuerst die bereits geladenen Energien der bisherigen Stunden des Tages ermittelt und abgebildet, woraufhin die Stundenprognose des restlichen Tages berechnet und dargestellt wird. Dabei ist zu beachten, dass als Verfahren für die Prognose der einzelnen Stundenwerte das Holt-Winters Verfahren gewählt wurde, was sich dadurch begründen lässt, dass sich die Prognosefehler der einzelnen Verfahren nur gering unterscheiden. Deshalb ist es im Zuge der vorliegenden Arbeit sinnvoll, ein einfacheres Verfahren zu wählen, um die Berechnungszeit gering zu halten. (vgl. Kapitel 4.3.1.2)

Zum Abschluss wird die Vorhersage für den nächsten Ladetag getroffen. Dabei werden ebenfalls die Energieprognose, die tatsächlich geladene Energie sowie der Prognosefehler berechnet. Anschließend erfolgt die Darstellung des relativen Fehlers sowie der Ladeverteilung, wobei als Prognoseverfahren für die Stundenladungen wiederum das Holt- Winters Verfahren verwendet wird.




Abbildung 4.35: privat genutzte E-Fahrzeuge, Modus 2, Fahrzeug 1

4 Privat genutzte Elektrofahrzeuge




Abbildung 4.36: privat genutzte E-Fahrzeuge, Modus 2, Fahrzeugpool

4.3.3 Ergebnisse und Schlussfolgerung

Im Zuge dieses Kapitels wird ein Lastprognosemodell für privat genutzte Elektrofahrzeuge erstellt, wobei der Energiebedarf für den aktuellen sowie den folgenden Tag mit einer Prognoseschrittweite von einer Stunde ermittelt wird. Die verwendeten Daten stammen von der Modellregion Köstendorf aus Salzburg. Dabei wurden von 26 Fahrzeugen im Zeitrahmen eines Jahres die Ladeleistungen und die Ladezeitpunkte aufgezeichnet.

Bei der Datenanalyse wird festgestellt, dass die Fahrzeuge an einigen Tagen mit sehr hohen beziehungsweise sehr geringen Leistungen geladen wurden. Da in der Datenbank nur ein paar Ladeleistungen auftreten, die größer als $3,68\text{ kW}$ sind, wird dieser Wert als maximale Ladeleistung angenommen. Deshalb werden alle Werte, welche größer als $3,68\text{ kW}$ sind, aus den Datenmengen eliminiert. Damit die Prognoseergebnisse nicht von Ladevorgängen mit geringen Ladeleistungen verfälscht werden, finden alle Werte, die kleiner als 300 W sind, keine Berücksichtigung.

Aufgrund der Tatsache, dass sich die einzelnen Elektrofahrzeuge nur durch die geladenen Energiemengen sowie den Ladezeitpunkten unterscheiden, wird für die Analyse der im Theorieteil analysierten Prognoseverfahren ein E-Fahrzeug verwendet. Hierbei wird Fahrzeug 1 gewählt, da die geladenen Energiemengen dem Mittelwert aller Elektrofahrzeuge nahekommen. Weiters werden die einzelnen E-Fahrzeuge zu einem Pool zusammengefasst, welcher ebenfalls genauer betrachtet wird.

Da in den beiden Datenmengen viele sprunghafte Änderungen auftreten, würde eine Prognoseerstellung lediglich den Mittelwert liefern. Deshalb erfolgt eine Aufbereitung der Daten, sodass akzeptable Prognoseergebnisse ermöglicht werden. Dies wird durch aufsummieren der geladenen Energiemengen erreicht, wodurch regelmäßige, glatte Verläufe ohne große Sprünge entstehen. Anschließend wird bei der Prognoseerstellung die Änderung der gesamt geladenen Energiemenge vorhergesagt, woraufhin eine Rückrechnung auf den tatsächlichen Wert erfolgt.

Eine Analyse der durchschnittlichen Ladeleistungen von Fahrzeug 1 und vom gesamten Fahrzeugpool zeigt, dass sich diese an den verschiedenen Wochentagen unterscheiden. Dies ist auf das unterschiedliche Fahrverhalten an den einzelnen Tagen zurückzuführen.

Betrachtet man die bereinigten Daten so stellt man fest, dass an den einzelnen Wochentagen unterschiedlich viel Energie geladen wurde.

Deshalb ist es sinnvoll, die Prognoseerstellung aufgrund der einzelnen Wochentage vorzunehmen. Da die Werte des Wochentages Sonntag im Durchschnitt aller Tage liegen, wird zur Analyse der Prognoseverfahren dieser Tag gewählt.

Nach der Datenaufbereitung kann die Untersuchung der im Theorieteil behandelten Prognoseverfahren erfolgen, wobei zur Bewertung der Qualität der Mittelwert der relativen Fehlerbeträge Verwendung findet. Es wird gezeigt, dass nicht alle Verfahren zur Prognose der vorliegenden aufsummierten Datenreihen geeignet sind. Der Grund liegt daran, dass bestimmte Prognoseverfahren eine kleiner werdende, aufsummierte Energiemenge vorhersagen, was allerdings nicht möglich ist.

Im Zuge der Verfahrensuntersuchung wird zuerst auf die Tagesprognose und anschließend auf die Stundenprognose des Energiebedarfes eingegangen. Vergleicht man die Ergebnisse von Fahrzeug 1 mit jenen des gesamten Fahrzeugpools so stellt man fest, dass die Prognose von mehreren Fahrzeugen ein besseres Resultat liefert. Dies liegt einerseits daran, dass die aufsummierte geladene Energiemenge des Fahrzeugpools einen glatteren und regelmäßigeren Verlauf aufweist, wodurch genauere Prognoseergebnisse möglich sind. Außerdem unterscheiden sich die Bezugswerte, welche zur Fehlerberechnung verwendet werden. Sowohl bei Fahrzeug 1 als auch beim gesamten Fahrzeugpool wird die gesamt geladene Energiemenge zur Fehlerbestimmung als Bezugswert verwendet. Da beim Fahrzeugpool jedoch deutlich mehr Energie geladen wurde, sind die Mittelwerte der relativen Fehlerbeträge um einiges geringer.

Bei der Tagesprognose von Fahrzeug 1 betragen die absoluten Fehler der untersuchten Prognoseverfahren zwischen 143 *Wh* und 167 *Wh*. Beim Fahrzeugpool hingegen liegen die absoluten Fehler eines durchschnittlichen Fahrzeuges zwischen 52 *Wh* und 95 *Wh*. Die Unterschiede der absoluten Fehler sind wiederum auf die verschiedenen Mittelwerte der relativen Fehlerbeträge zurückzuführen.

Bei der Stundenprognose wird festgestellt, dass die absoluten Fehler pro Tag, welche mit Hilfe der absoluten Fehler der Stundenprognose und der durchschnittlichen Ladestunden pro Ladetag ermittelt werden, um einiges höher sind. Die absoluten Fehler der Stundenprognose pro Tag sind beim Fahrzeug 1 um den Faktor 1,2 – 2,3 größer als bei der Tagesprognose. Ebenso unterscheiden sich die Fehler beim gesamten Fahrzeugpool um das 1,8 – 2,4-fache. Der Hauptgrund für diese Unterschiede liegt daran, dass bei der Stundenprognose nur wenige Werte

zur Prognose der einzelnen Stunde zur Verfügung stehen. Deshalb treten bei der Prognose größere Abweichungen und damit höhere Prognosefehler auf.

In der Abbildung 4.32 (Fahrzeug 1, Sonntag) kann man hohe Fehler erkennen, wenn das Fahrverhalten und somit das Ladeverhalten vom generellen Verhalten abweicht. Diese Charakteristik lässt sich dadurch erklären, dass das Prognoseverfahren erst auf die unregelmäßige Änderung reagieren muss, was sich durch einen höheren Fehler bemerkbar macht.

5 Dienstlich genutzte Elektrofahrzeuge

Das Ziel dieses Kapitels ist die Entwicklung und Erstellung eines Prognosemodells zur zeitlichen und energetischen Vorhersage des Energieverbrauches von dienstlich genutzten Elektrofahrzeugen. Die Daten stammen von der Firma VLOTTE und wurden im Zuge einer früheren Bachelorarbeit [10] aufbereitet.

Im ersten Unterpunkt werden die Grundlagen besprochen, wobei hier im speziellen auf den Sinn und Zweck eines solchen Prognosemodells in Verbindung mit dienstlich genutzten Elektrofahrzeugen eingegangen wird. Weiters werden die Eigenschaften des Fahrzeugs, welches die vorhandenen Daten liefert, erörtert.

Anschließend werden die vorhandenen Daten aufbereitet und die Vorgehensweise beim Aufzeichnen der Daten von der Ladestation genauer erläutert. Danach folgt eine Analyse, wobei im speziellen auf die Ladezeitpunkte, auf die Fahrtrittszeiten und auf die Ladeleistungen eingegangen wird.

Der nächste Punkt behandelt die Modellerstellung. Dabei werden zuerst die verwendeten Prognoseverfahren ausgewählt und deren Eigenschaften erörtert (vgl. Kapitel 4.3.1.1).

Daraufhin wird die Implementierung in MATLAB untersucht, woraufhin die Darstellung der Ergebnisse folgt.

Zum Abschluss werden die Vor- und Nachteile bei der Verwendung eines Reservierungssystems in Zusammenhang mit Elektrofahrzeugen behandelt.

5.1 Einleitung

Die Verwendung von Prognosemodellen in Verbindung mit dienstlich genutzten Elektrofahrzeugen soll den Vorteil bringen, dass die Ladevorgänge von E-Fahrzeugen hauptsächlich dann stattfinden, wenn der dafür benötigte Strom nicht zugekauft werden muss. Dies ist bei der Firma VLOTTE zum Beispiel möglich, indem der Strom durch eine betriebseigene Photovoltaikanlage erzeugt wird. Dadurch kann eine Kostensenkung sowie eine Entlastung des Versorgungsnetzes erreicht werden. (vgl. Kapitel 4.1)

Außerdem ermöglicht die Verwendung einer Lastprognose in Verbindung mit einem Elektrofahrzeugfuhrpark eine effiziente Zuordnung von Fahrzeugen zu MitarbeiterInnen. Dies kann zum Beispiel so aussehen, dass man einem Angestellten, der am nächsten Tag eine geringe

Fahrtstrecke zurückzulegen hat, ein Fahrzeug mit einem geringen Ladestand zuordnen kann, weshalb dieses über Nacht nicht vollständig geladen werden muss. Dadurch ist es nicht erforderlich Strom zu kaufen und Fahrzeuge mit einem hohen Ladestand bleiben für andere Angestellte verfügbar. Im Zuge dieser Arbeit wird für die Nacht der Zeitraum zwischen 23:00 Uhr abends und 05:00 Uhr morgens angesehen.

Wie bereits vorhin erwähnt wurde, steht der Firma VLOTTE zur Energieerzeugung eine Photovoltaikanlage zu Verfügung, welche eine Spitzenleistung von $62,15 \text{ kWp}$ aufweist. Außerdem ist die Firma im Besitz eines Elektrofahrzeugfuhrparks, wobei jedem Fahrzeug eine eigene Ladestation zugeordnet ist. Diese Ladestationen, welche die zur Prognose benötigten Daten aufzeichnen, werden Wallboxen genannt. Für das zu erstellende Prognosemodell dieses Kapitels ist die sogenannte Wallbox 1 von Bedeutung. Die Daten dieser Ladestation stammen von einem Elektrofahrzeug des Typs Renault Kangoo, welches die folgenden Eigenschaften hat:

- minimaler Ladestrom, wenn das Fahrzeug angeschlossen und nicht vollgeladen ist: 6 A
- maximaler Ladestrom: $I = 16 \text{ A}$
- 1 – phasiger Ladevorgang
- maximale Ladeleistung: $230 \text{ V} * 16 \text{ A} = 3,68 \text{ kW}$
- Batteriekapazität: 22 kWh
- Batterietyp: ZEBRA-Batterie

Da sich die Eigenschaften der ZEBRA-Batterie in Kapitel 5.2 bemerkbar machen werden, wird im folgenden Abschnitt kurz darauf eingegangen.

Laut [11] handelt es sich bei der ZEBRA (Zero Emission Battery Research Activity) Batterie um eine $\{\text{Na}/\text{NiCl}_2\}$ Batterie.

Dabei wird die positive Elektrode von Nickelchlorid und die negative Elektrode von Natrium gebildet. Für die Reaktion wird ein leitfähiger Natrium-Ionen-Elektrolyt benötigt. Hierfür ist keramisches β'' -Aluminiumoxid (Al_2O_3) am besten geeignet. Aufgrund der benötigten Temperatur von 300°C und dem festen Aggregatzustand des Elektrolyts bei dieser Temperatur wird zur Gewährleistung der Leitfähigkeit ein zweiter, bei diesen Temperaturen flüssiger, Elektrolyt benötigt. Hierfür wird NaAlCl_4 verwendet, welcher die ZEBRA-Batterie außerdem gegen Über- und Tiefentladung robust macht.

Die wesentliche Eigenschaft, die diese ZEBRA-Batterie von anderen Batterietypen unterscheidet, ist die hohe Betriebstemperatur von 280-350°C [11]. Aufgrund des hohen Temperaturbereichs im Betrieb ist es notwendig, diese Batterie mit einem eigenen Kühlungs- und Erwärmungssystem auszustatten. Da das System durch zyklisch durchgeführte Ladevorgänge auf dieser hohen Betriebstemperatur gehalten werden muss, fallen Verluste an. Dabei kann man davon ausgehen, dass eine Heizleistung von rund 5 W pro kWh Speichervermögen benötigt wird [11]. Falls eine ZEBRA-Batterie abkühlt, so muss man mit einer Wiederaufheizzeit von bis zu 48 Stunden rechnen [11].

5.2 Datengrundlage dienstlich genutzer Elektrofahrzeuge

Die Daten, welche zur Prognoseerstellung verwendet werden, stammen von der Firma VLOTTE. (vgl. Kapitel 5.1) Sie wurden im Zuge einer früheren Bachelorarbeit [10] aufbereitet und stehen als CSV - Datei zur Verfügung.

In Tabelle 5.1 ist der Aufbau dieser Datenbank dargestellt. Die Daten, die mit einer Schrittweite von einer Minute vorliegen, wurden vom 13.11.2013 bis zum 16.3.2015 aufgezeichnet. Dies entspricht einem Aufzeichnungszeitraum von 488 Tagen.

Im Anschluss an das Bild werden die Bedeutungen der einzelnen Spalten erläutert.

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungsfehler	Abspeicherfehler
91715	16.01.2014 09:10	3727	0	8000	7	1746320	16000	0	0	0
91716	16.01.2014 09:11	3796	0	8000	7	1760738	16000	0	0	0
91717	16.01.2014 09:12	4115	0	10000	7	1760738	16000	1	0	0
91718	16.01.2014 09:13	4387	0	10000	7	2215098	16000	0	0	0
91719	16.01.2014 09:14	4693	0	10000	7	2215098	16000	1	0	0

Tabelle 5.1: Wallbox 1, Aufbau der Datenbank

- **ID:** Hierbei handelt es sich um die Zeilennummer der CSV Datei.
- **Zeitstempel:** Gibt das jeweilige Datum mit der zugehörigen Uhrzeit an.
- **P_PV** entspricht der momentan von der Photovoltaik Anlage erzeugten Leistung in W.
- **Komm.-fehler mit PV:** Dieser Wert gibt Auskunft über die Kommunikationsverbindung mit der Photovoltaik Anlage. Wenn diese Zahl 1 ist, so liegt ein Kommunikationsfehler vor und der Wert von P_PV ist ungültig. Bei 0 liegt kein Fehler vor.
- **Befehl_LS current in mA:** In dieser Spalte steht der vorgegebene Ladestrom für die Wallbox 1 in der Einheit mA.

- **Plugwert LS** beschreibt den Verbindungszustand der Ladestation mit dem Fahrzeug
 - 0 – An der Ladestation ist nichts angeschlossen.
 - 1 – Das Ladekabel ist nur auf der Wallbox 1 angeschlossen.
 - 7 – Das Fahrzeug ist mit der Ladestation mithilfe des Ladekabels verbunden.
 - Laut [10] gibt es noch andere Plugwerte. Diese sind für diese Arbeit jedoch nicht relevant.
- **P_LS in mW** gibt die an das Fahrzeug abgegebene Leistung in mW an.
- **Max möglicher I_LS in mA:** Entspricht dem maximalen möglichen Ladestrom mit dem das Fahrzeug geladen wird.
- **Komm.-fehler mit LS:** Ist der Wert 1 so liegt ein Kommunikationsfehler zwischen Fahrzeug und Ladestation vor. Bei 0 ist alles in Ordnung. In der Abbildung 5.1 kann man 2 Kommunikationsfehler mit der Ladestation erkennen. Beim Auftreten eines Fehlers wird die Ladeleistung gleich der Vorherigen angenommen, wodurch es zu minimalen Abweichungen von der tatsächlichen Ladeleistung kommen kann.
- **Ladesteuerungsfehler:** Gibt an, ob ein Steuerungsfehler an der Ladestation auftritt.
- **Abspeicherfehler:** Hier kann man erkennen, ob die Daten korrekt in die CSV-Datei geschrieben wurden. Dieser Wert kann bei der Erstellung des Prognosemodells nicht verwendet werden, da er nur bis 14.4.2014 dokumentiert ist.

5.2.1 Datenanalyse

In diesem Unterkapitel wird gezeigt was sich in der CSV-Datenbank ändert, wenn eine Fahrt oder ein Ladevorgang begonnen wird. Außerdem werden die Fahrtantrittszeiten bzw. die Ladebeginne dargestellt, analysiert und miteinander verglichen, wodurch Rückschlüsse auf das Fahr- bzw. Ladeverhalten möglich sind.

5.2.1.1 Fahrtantritte

Bei der Analyse der Daten der Ladestation kann man im Datenaufzeichnungszeitraum 147 Ausfahrten feststellen. Dies entspricht einer Fahrt an im Durchschnitt jedem 3. bis 3,5. Tag. Dabei bemerkt man an den Wochenenden lediglich drei Ausfahrten, was durchaus logisch

erscheint, da es sich um ein dienstlich genutztes E-Fahrzeug handelte, welches hauptsächlich an Werktagen genutzt wurde. Die Berechnung der Fahrtantritte der Arbeitstage ergibt, dass an jedem 2. bis 2,5. Tag ein Fahrtbeginn stattfand.

In der folgenden Tabelle ist ein Beispiel eines Fahrtantritts dargestellt. Dabei kann man am 4.12.2013 um 7:37 Uhr eine Plugwert LS Änderung von 7 auf 0 beobachten, was durch das abschließen des Fahrzeuges von der Wallbox 1 erreicht wurde. Allerdings lässt sich aufgrund dieser Plugwertänderung nicht unterscheiden, ob mit dem Fahrzeug tatsächlich eine Fahrt begonnen oder ob es nur von der Ladestation getrennt wurde. Da keine weiteren Daten über den Fahrzustand des Elektrofahrzeuges vorliegen, wird im Zuge dieser Arbeit angenommen, dass eine solche Wertänderung gleichbedeutend mit einem Fahrtantritt ist.

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungsfehler
31138	04.12.2013 07:33	0	0	6000	7	0	16000	0	0
31139	04.12.2013 07:34	0	0	6000	7	0	16000	0	0
31140	04.12.2013 07:35	0	0	6000	7	0	16000	0	0
31141	04.12.2013 07:36	0	0	6000	7	0	16000	0	0
31142	04.12.2013 07:37	0	0	6000	0	0	6000	0	0
31143	04.12.2013 07:38	0	0	6000	0	0	6000	0	0
31144	04.12.2013 07:39	0	0	6000	0	0	6000	0	0

Tabelle 5.2: Wallbox 1, Plugwertänderung bei Fahrtantritt

Abbildung 5.1 zeigt die Verteilung der Fahrtantritte. In der Grafik ist zu erkennen, dass die Mehrheit der Fahrtantritte vormittags zwischen 07:00 und 12:00 Uhr und nachmittags zwischen 15:00 und 18:00 Uhr stattfand. Dabei erscheinen die vielen Fahrtantritte am Vormittag als logisch, allerdings fallen die vielen Ausfahrten am späten Nachmittag zwischen 16:00 und 18:00 Uhr auf. Man könnte annehmen, dass es sich bei dienstlich genutzten Elektrofahrzeugen um Solche handelt, die tagsüber von den Angestellten genutzt werden und am Abend beziehungsweise in der Nacht in der Firma zum Laden an der Ladestation angeschlossen sind. Diese Annahme wird in Kapitel 5.2.2 genauer geprüft.

Bei Betrachtung des Verlaufs ist eine Ausfahrt kurz nach Mitternacht zu erkennen. Bei einer genaueren Untersuchung der Daten der Ladestation fällt auf, dass es sich bei diesem einen Fahrtantritt um einen Aufzeichnungsfehler handeln könnte.

In Tabelle 5.3 ist ein Fehlen der Aufzeichnungen zwischen 14. und 26.8.2014 in der Datenbank zu erkennen. Es ist zwar theoretisch möglich, dass diese Ausfahrt zu der dort angegebenen Uhrzeit begonnen wurde, jedoch ist ein früherer Fahrtantritt an einem der Vortage wahrscheinlicher.




Abbildung 5.1: Wahlbox 1, Anzahl der Fahrtantritte

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungsfehler
391678	14.08.2014 23:57	0	0	6000	7	0	16000	0	0
391679	14.08.2014 23:58	0	0	6000	7	0	16000	0	0
391680	14.08.2014 23:59	0	0	6000	7	0	16000	0	0
391681	26.08.2014 00:00	0	0	6000	0	0	6000	0	0
391682	26.08.2014 00:01	0	0	6000	0	0	6000	0	0
391683	26.08.2014 00:02	0	0	6000	0	0	6000	0	0

Tabelle 5.3: Wallbox 1: Aufzeichnungsfehler in der Datenbank, einige Tage fehlen

5.2.1.2 Ladevorgänge

Laut [10] wird das Elektrofahrzeug entsprechend eines Regelalgorithmus (Tabelle 5.4) mit einem von der Erzeugungsleistung der Photovoltaikanlage abhängigen Strom geladen. Dadurch kommt es zu einer effizienteren Nutzung des eigenen produzierten Stroms, weshalb weniger Strom zugekauft werden muss.

Bei den Fahrzeugeigenschaften wurde bereits erwähnt, dass der minimale Ladestrom bei angeschlossenem und nicht vollständig geladenem Fahrzeug 6 A beträgt. Dieser Ladestrom erhöht sich in Abhängigkeit von der momentanen Photovoltaikerzeugungsleistung bis zu einem Maximalwert von 16 A [10].

PV – Erzeugungsleistung [kW]	Ladestrom [A]
0 - 2	6
2 - 4	8
4 - 6	10
6 - 8	12
8 - 10	14
über 10	16

Tabelle 5.4: Wallbox 1, Ladestrom in Abhängigkeit der Erzeugungsleistung

Bei der Analyse der Daten kann man feststellen, dass im Datenerfassungszeitraum 148 Ladebeginne stattfanden, was im Durchschnitt einem Ladevorgang an jedem 3. bis 3,5. Tag entspricht. Wie bereits bei den Fahrtantritten finden auch bei den Ladestarts lediglich drei an den Wochenenden statt. Nach der Eliminierung der Wochenenden ergibt sich für die Arbeitstage ein Ladebeginn an jedem 2. bis 2,5. Tag.

Vergleicht man die Anzahl der Ladebeginne mit jenen der Fahrtantritte, so stellt man annähernd gleich große Werte fest. Dies lässt sich dadurch erklären, dass ein Ladevorgang mit einem Fahrtantritt verknüpft ist. Der Beginn einer Fahrt kann nur dann in der Datenbank dokumentiert werden, wenn das Fahrzeug an der Ladestation angeschlossen ist. Dazu muss es zu einem früheren Zeitpunkt mit der Ladestation verbunden und somit geladen worden sein. Die Differenz von eins zwischen der Anzahl der Ladebeginne und der Fahrtantritte ergibt sich dadurch, dass das Elektrofahrzeug am Beginn der Datenaufzeichnung unterwegs und am Ende mit der Ladestation verbunden war. Wäre es am Ende der Datenbank nicht mit der Ladestation verbunden gewesen, so wäre die Anzahl der Ladebeginne gleich groß als die Anzahl der Fahrtbeginne.

Die Abbildung 5.2 zeigt die maximalen Ladeleistungen für die vier Jahreszeiten, wobei diese in Stundenschritten abgebildet sind. Dabei wurden die in Minutenschritten protokollierten Ladeleistungen zu Stundenwerten zusammengefasst. Anschließend erfolgte die Ermittlung und Darstellung der maximalen Stundenladungsleistungen für die einzelnen Jahreszeiten. Ein Wert, der um 02:00 Uhr dargestellt ist, repräsentiert die Leistung der nachfolgenden Stunde von 02:00 bis 03:00 Uhr.

Bei einem Vergleich der Verläufe der einzelnen Jahreszeiten sticht die kürzere Zeitspanne der maximalen Leistung im Winter ins Auge. Der Grund hierfür liegt an der, in den Wintermonaten, kürzeren Zeitdauer der Sonneneinstrahlung, welche sich aufgrund der kürzeren Tage ergibt. Deshalb wird der Ladestrom früher als bei den anderen Jahreszeiten heruntergeregelt.

Weiters ist im Diagramm zu erkennen, dass bei drei der vier Jahreszeiten zwischen 20 Uhr abends und 05 Uhr morgens in etwa mit dem minimalen Ladestrom von 6 A geladen wurde. Dies entspricht einer Ladeleistung von $6\text{ A} \cdot 230\text{ V} = 1,38\text{ kW}$.

Eine Ausnahme bilden die Wintermonate, bei denen ein starker Rückgang der Leistung nach Mitternacht zu beobachten ist. Zwischen 02:00 und 04:00 Uhr wird die Ladeleistung zu 0, was daran liegt, dass im Aufzeichnungszeitraum der Datenbank in den Wintermonaten zu diesen Zeiten nie ein Ladevorgang stattfand.

Des Weiteren kann man um 01:00 Uhr eine Ladeleistung von etwa 0,75 kW feststellen, welche kleiner als die minimale Leistung beim Laden ist. Hierfür ist die Tatsache verantwortlich, dass am Vortag mit dem Laden begonnen wurde und nach Mitternacht nur noch fertig geladen werden musste, was nicht die ganze Stunde lang dauerte. Die gleiche Gegebenheit ist im Frühling am späten Nachmittag zu erkennen. Dort wurde ebenfalls nicht die komplette Stunde geladen, weshalb ein Einbruch bemerkbar ist.

In der Abbildung kann man im Winter eine weitere geringe Ladeleistung feststellen, welche um 04:00 Uhr auftritt und weniger als 0,5 kW beträgt. Der Grund hierfür liegt an den Eigenschaften des verwendeten Elektrofahrzeuges. Eine genauere Erläuterung eines Ladevorgangs mit einer solchen geringen Energiemenge folgt später in diesem Kapitel.




Abbildung 5.2: Wallbox 1, Darstellung der maximalen Ladeleistung

In Abbildung 5.2 lässt sich eine weitere Abweichung von den Erwartungswerten feststellen. Beim Verlauf der maximalen Ladeleistung ist im Sommer eine Reduzierung der Ladeleistung und somit

ein kurzer Einbruch der Kurve erkennbar. Bei einer genaueren Analyse der Daten bemerkt man, dass in den Sommermonaten die maximale Ladeleistung über die Mittagszeit nur an 2 Tagen knapp über 3 kW lag.

Die Verläufe dieser beiden Tage sind in Abbildung 5.3 dargestellt. Es wurde zwar mit einer hohen Ladeleistung geladen, jedoch konnte der Maximalwert von 3,68 kW nicht erreicht werden. Der Grund hierfür liegt in der niedrigeren Erzeugungsleistung der Photovoltaik Anlage, was durch eine geringere Sonneneinstrahlung hervorgerufen wurde.

Durch diese Leistungsverminderung ergibt sich ein geringerer Ladestrom und somit eine geringere Ladeleistung.




Abbildung 5.3: Wallbox 1, Darstellung der maximalen Ladeleistung im Sommer

Bei Betrachtung von Abbildung 5.2 kann man zwei weitere Abweichungen vom erwarteten Verlauf der maximalen Ladeleistung erkennen. Im Frühling und im Herbst traten nachmittags maximale Ladeleistungen auf, welche ungefähr 4,5 kW betrugen. Um diese Leistungen erreichen zu können, wäre es notwendig, dass das Elektrofahrzeug mit knapp 20 A geladen werden würde. Dies ist jedoch nicht möglich, da der Ladestrom mit maximal 16 A begrenzt ist.

Betrachtet man die Datenbank, so kann man zwei Aufzeichnungsfehler feststellen. Die Gegebenheit bei diesen beiden Protokollierungsfehlern ist in der Tabelle 5.5 dargestellt. Dort ist ersichtlich, dass mehrmals die gleichen Minutenwerte abgespeichert wurden, wodurch sich eine höhere Ladeleistung ergibt.

5 Dienstlich genutzte Elektrofahrzeuge

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungsfehler
238558	30.04.2014 15:44	8459	0	14000	7	3181485	16000	0	0
238559	30.04.2014 15:44	8352	0	14000	7	3183660	16000	0	0
238560	30.04.2014 15:44	8367	0	14000	7	3183660	16000	1	0
238561	30.04.2014 15:45	8277	0	14000	7	3182814	16000	0	0
238562	30.04.2014 15:46	8170	0	14000	7	3183815	16000	0	0
238563	30.04.2014 15:46	8334	0	14000	7	3184335	16000	0	0
238564	30.04.2014 15:46	8410	0	14000	7	3184233	16000	0	0
238565	30.04.2014 15:46	8406	0	14000	7	3184233	16000	1	0

Tabelle 5.5: Wallbox 1, Aufzeichnungsfehler in der Datenbank, Ladeleistung zu hoch

Im folgenden Teil dieses Kapitels folgt die Erläuterung des Ablaufs bei einem Ladevorgang.

Beim Anschließen des Elektrofahrzeuges an die Ladestation ändert sich der Plugwert LS von 0 auf 7. Das Fahrzeug wird entsprechend des Regelalgorithmus in Tabelle 5.4 mit einem von der Erzeugungsleistung der Photovoltaikanlage abhängigen Strom geladen. Dies ist in Tabelle 5.6 ersichtlich. Der Ladevorgang wird solange durchgeführt bis entweder die Batterie vollständig geladen ist oder eine neuerliche Ausfahrt stattfindet, wodurch es zu einer Ladevorgangsunterbrechung kommt.

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungsfehler
19833	26.11.2013 11:08	7269	0	12000	0	0	6000	0	0
19834	26.11.2013 11:09	6836	0	12000	0	0	6000	0	0
19835	26.11.2013 11:10	6541	0	12000	0	0	6000	0	0
19836	26.11.2013 11:11	6517	0	12000	0	0	6000	0	0
19837	26.11.2013 11:12	6231	0	12000	0	0	6000	0	0
19838	26.11.2013 11:13	6197	0	12000	7	2714257	16000	0	0
19839	26.11.2013 11:14	6216	0	12000	7	2683640	16000	0	0
19840	26.11.2013 11:15	6363	0	12000	7	2681232	16000	0	0

Tabelle 5.6: Wallbox 1, Beginn eines Ladevorganges

In Abbildung 5.4 ist die Verteilung der Ladebeginne von Wallbox 1 dargestellt. Der Großteil der Ladebeginne fand im Zeitraum zwischen 06:00 und 17:00 Uhr statt. Dies ist nachvollziehbar, da diese Zeitspanne in etwa einem Arbeitstag entspricht und es am Abend eher unwahrscheinlich erscheint, dass sich Angestellte in der Firma aufhalten und das Fahrzeug an die Ladestation anschließen, wodurch ein Ladevorgang begonnen wird. Der geringe Anteil der Ladebeginne am späten Abend könnte dadurch zustande gekommen sein, dass das Elektrofahrzeug im Zuge einer Schulung oder einer längeren Ausfahrt verwendet wurde, welche erst am späten Abend beendet wurde.

Eine weitere Besonderheit ist der hohe Anteil an Ladebeginn zwischen 07:00 und 09:00 Uhr. Auf diese Auffälligkeit wird später in diesem Kapitel im Zusammenhang mit den Daten der Fahrtantritte eingegangen.




Abbildung 5.4: Wallbox 1, Anzahl der Ladebeginne

Wie schon früher in diesem Kapitel beobachtet wurde, kann man bei der Analyse der Daten von Wallbox 1 neben den Abläufen bei den Ladevorgängen und den Fahrtantritten einen weiteren Ladevorgang erkennen. Dieser kann nicht dem im Vorhin beschriebenen Ladeablauf nach dem Anschließen des Elektrofahrzeuges an die Ladestation zugeordnet werden.

In der nachfolgenden Abbildung ist ersichtlich, dass ein Ladevorgang stattfand, obwohl es zuvor angeschlossen und vollständig geladen war. Dabei stellt sich die Frage, warum ein Ladevorgang notwendig war, wenn keine Ausfahrt stattgefunden hat. Der Grund hierfür liegt in den Eigenschaften des Elektrofahrzeuges (vgl. Kapitel 5.1). Es handelt sich im Speziellen um den Batterietyp des Fahrzeuges, der sogenannten ZEBRA-Batterie. Diese muss auf einer Betriebstemperatur von 280° - 350°C gehalten werden. Dazu ist laut [11] ein eigenes Erwärmungssystem erforderlich, welches die Betriebstemperatur durch zyklische Ladevorgänge im vorgegebenen Temperaturbereich hält. Diese Ladevorgänge sind notwendig, wenn das Fahrzeug über einen längeren Zeitraum durchgehend an die Ladestation angeschlossen ist.

Bei der Datenanalyse kann festgestellt werden, dass diese Ladevorgänge häufiger in den kalten Jahreszeiten auftraten, was sich dadurch erklären lässt, dass die Batterie bei niedrigen Temperaturen schneller abkühlt.

Aufgrund der geringen Energiemengen, die bei diesen Ladevorgängen geladen wurden, werden sie bei der Prognoseerstellung nicht berücksichtigt, damit sie die Prognosewerte für den Energieverbrauch, welcher durch das Fahren mit dem Elektrofahrzeug auftritt, nicht verfälschen. Außerdem ist zu beachten, dass diese Ladevorgänge bei der Analyse der Ladebeginne in Abbildung 5.4 ebenfalls nicht berücksichtigt wurden.

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungs- fehler
43118	12.12.2013 15:13	807	0	6000	7	0	16000	0	0
43119	12.12.2013 15:14	997	0	6000	7	0	16000	0	0
43120	12.12.2013 15:15	1077	0	6000	7	1127938	16000	0	0
43121	12.12.2013 15:16	1111	0	6000	7	1308663	16000	0	0
43122	12.12.2013 15:17	873	0	6000	7	1069724	16000	0	0
43123	12.12.2013 15:18	678	0	6000	7	917939	16000	0	0
43124	12.12.2013 15:19	672	0	6000	7	1039951	16000	0	0
43125	12.12.2013 15:20	707	0	6000	7	923819	16000	0	0
43126	12.12.2013 15:21	673	0	6000	7	1020659	16000	0	0
43127	12.12.2013 15:22	646	0	6000	7	845239	16000	0	0
43128	12.12.2013 15:23	730	0	6000	7	837690	16000	0	0
43129	12.12.2013 15:24	837	0	6000	7	680298	16000	0	0
43130	12.12.2013 15:25	730	0	6000	7	0	16000	0	0
43131	12.12.2013 15:26	759	0	6000	7	0	16000	0	0

Tabelle 5.7: Wallbox 1, Ladevorgang aufgrund der ZEBRA – Batterie

5.2.1.3 Zusammenhänge zwischen Fahrtantritten und Ladebeginn

Vergleicht man die in den beiden vorhergehenden Kapiteln dargestellten Grafiken für die Fahrtantritte und Ladebeginne an der Wallbox 1 unter der Annahme, dass es sich bei dem einen Fahrtantritt kurz nach Mitternacht um einen Aufzeichnungsfehler handelt, so stellt man zwischen 23:00 Uhr abends und 5:00 Uhr morgens keine Aktivität an der Ladestation fest. In dieser Zeitspanne haben also keine Fahrtantritte oder Ladebeginne stattgefunden

Da die analysierten Daten von einem dienstlich genutzten Elektrofahrzeug stammen, könnte man annehmen, dass das Elektrofahrzeug in der Nacht in der Firma an der Ladestation angeschlossen war. Bei einem Vergleich von Abbildung 5.1 mit Abbildung 5.4 erkennt man einen hohen Anteil an Fahrtantritten am späten Nachmittag und einen hohen Prozentsatz der Ladebeginne in den Morgenstunden. Aufgrund dessen könnte man in den Nachtstunden eine oftmalige Abwesenheit des E-Fahrzeuges von der Ladestation vermuten. Im nächsten Kapitel wird sich zeigen, ob das Elektrofahrzeug im Datenaufzeichnungszeitraum in den Nächten öfters unterwegs oder mit der Ladestation verbunden war.

5.2.2 Datenaufbereitung

Da es sich bei der Datenbank der Ladestation Wallbox 1 um Daten eines dienstlich genutzten Elektrofahrzeuges handelt, wird die Annahme getroffen, dass an den Wochenenden keine Ladevorgänge stattfanden. Der Grund liegt daran, dass sich mit hoher Wahrscheinlichkeit keine Angestellten in der Firma aufhielten und deshalb nicht mit dem Elektrofahrzeug gefahren wurde.

Bei einer Analyse der Daten stellt man innerhalb des 488-tägigen Aufzeichnungszeitraums nur drei Ladevorgänge an den Wochenenden fest. Aufgrund dieser geringen Anzahl der Ladevorgänge an den Wochenenden werden diese nicht in die Prognose miteinbezogen, wodurch sich die Anzahl der Ladevorgänge von 148 auf 145 verringert.

Bei der Untersuchung der Datenbank stellt man an vielen Tagen keine Aktivität an der Ladestation fest. Da diese Tage nicht für die Erstellung des Prognosemodells relevant sind, werden diese nicht berücksichtigt. Dadurch reduzieren sich die Tage des Aufzeichnungszeitraums von 488 auf 295. Dabei muss allerdings beachtet werden, dass es sich nun um keine zeitliche, kontinuierliche Datenreihe mehr handelt.

An einigen Stellen der Daten ist zu erkennen, dass der Ladevorgang durch das Abschließen des Ladekabels kurz unterbrochen und anschließend wieder fortgesetzt wurde. Dies ist in Tabelle 5.8 dargestellt. Da es sich bei diesen kurzen Unterbrechungen um keine Fahrtantritte handeln kann und nach kurzer Zeit weitergeladen wurde, werden diese Ladeaussetzer nicht berücksichtigt und die beiden Ladevorgängen vor und nach dem Trennen des Fahrzeuges von der Ladestation als ein durchgehender Ladevorgang angesehen und zusammengefasst. Diese Vorgehensweise wurde bei der Ermittlung der Anzahl der Ladebeginne ebenfalls angewendet.

ID	Zeitstempel	P_PV	Komm.-fehler mit PV	Befehl_LS current in mA	Plugwert LS	P_LS in mW	Max möglicher I_LS in mA	Komm.-fehler mit LS	Ladesteuerungsfehler
3839	15.11.2013 08:34	2454	0	1000	7	3201461	16000	1	0
3840	15.11.2013 08:35	2451	0	1000	7	3201461	16000	1	0
3841	15.11.2013 08:36	2598	0	1000	7	3201461	16000	1	0
3842	15.11.2013 08:37	2606	0	1000	3	0	16000	0	1
3843	15.11.2013 08:38	2634	0	1000	1	0	16000	0	1
3844	15.11.2013 08:39	2679	0	10000	1	0	16000	0	0
3845	15.11.2013 08:40	2809	0	10000	7	1643749	16000	0	0
3846	15.11.2013 08:41	2982	0	9000	7	1643749	16000	1	0

Tabelle 5.8: Wallbox 1, kurzzeitige Unterbrechung des Ladevorganges

Im vorherigen Kapitel wurde erläutert, dass Ladevorgänge, die aufgrund der Eigenschaften der ZEBRA-Batterie stattfanden, nicht berücksichtigt werden. Diese Ladevorgänge, bei denen nur geringe Energiemengen geladen werden, würden die Vorhersage der zukünftigen benötigten Energiemenge verfälschen. Weiters werden Tagesenergiemengen, die weniger als 10 % der maximalen Ladekapazität entsprechen, nicht berücksichtigt. Diese Energiemengen, welche kleiner als 2,2 kWh sind, können bei der Implementierung in ein reales System durch eine Energiereserve im Prognosemodell berücksichtigt werden.

In der folgenden Abbildung sind die geladenen Energiemengen jener Tage dargestellt, an denen mindestens ein Ladevorgang stattfand. Dabei wurden die Ladevorgänge mit kleinen Energiemengen bereits eliminiert. Dadurch ergeben sich insgesamt 96 Tage, an denen mindestens ein Ladevorgang stattgefunden hat.

Die untere horizontale Linie kennzeichnet jenes Energiemengenniveau, das von einem Wert überschritten werden muss, damit er zur Prognose herangezogen wird.

Bei Betrachtung der Grafik kann man erkennen, dass die geladene Energiemenge an einigen Tagen größer ist als die Batterie aufnehmen kann. Dies ist durch mehrmaliges Laden an einem Tag zu erklären. Dabei wurde das Fahrzeug geladen, woraufhin eine Ausfahrt und ein erneuter Ladevorgang folgte.




Abbildung 5.5: Wallbox 1, Darstellung der bereinigten Werte der Lademengen

Bei Betrachtung von Abbildung 5.5 lassen sich keine regelmäßigen oder systematischen Änderungen der geladenen Energiemengen feststellen. Man kann lediglich beobachten, dass die meisten Werte zwischen 0,1 Vollladungen (2,2 kWh), was sich aufgrund der festgelegten minimalen Energiemenge ergibt, und 1,1 Vollladungen (24,2 kWh) liegen.

Da diese Erkenntnisse für die Erstellung einer Prognose nicht hilfreich sind, werden die Daten in zwei Teile zerlegt. Bei der Aufteilung wird unterschieden, ob das Fahrzeug in der Nacht vor dem Ladevorgang unterwegs oder an der Ladestation angeschlossen war. Im Zuge dieser Arbeit für wurde für die Nacht der Zeitraum zwischen 23:00 Uhr abends und 05:00 Uhr morgens angenommen.

In Abbildung 5.6 sind die Vollladungen jener Tage dargestellt, bei denen das Fahrzeug in der Nacht zuvor an der Ladestation angeschlossen war. Wie bereits vorhin erwähnt wurde, handelt es sich bei den nachfolgenden Darstellungen um keine zeitlich kontinuierlichen Verläufe.

Insgesamt fanden an 22 Tagen Ladevorgänge statt, wobei an Tag 3 ein sehr hoher Wert erkennbar ist. Hierfür ist eine Ladungsunterbrechung aufgrund einer Ausfahrt verantwortlich, welcher ein weiterer Ladevorgang folgte. Alle anderen Werte liegen zwischen 0,1 und 0,65 Vollladungen, was den Energiewerten von 2,2 kWh und 14,3 kWh entspricht.




Abbildung 5.6: Wallbox 1, Darstellung der Vollladungen, Fahrzeug war verbunden

Die nachfolgende Abbildung zeigt die Vollladungen für den Fall, dass das Elektrofahrzeug in der Nacht zuvor unterwegs und somit nicht mit der Ladestation verbunden war. Dabei fand an 74 Tagen mindestens ein Ladevorgang mit einer Energiemenge über 2,2 kWh statt. In der Grafik sind wiederum einige Ladungsunterbrechungen erkennbar, was dadurch ersichtlich ist, dass an einigen Tagen mehr Energie geladen wurde als von der Batterie aufgenommen werden kann. Die Mehrheit der Werte liegt zwischen 0,4 und 1,1 Vollladungen. Dies entspricht den Energiewerten von 8,8 kWh und 24,2 kWh.




Abbildung 5.7: Wallbox 1, Darstellung der Vollladungen, Fahrzeug war nicht verbunden

Bei einem Vergleich von Abbildung 5.6 mit Abbildung 5.7 bestätigt sich die im vorherigen Kapitel getroffene Annahme, wonach das Fahrzeug oftmals nicht in der Nacht vor dem Ladevorgang an der Ladestation angeschlossen war. Bei einer Gegenüberstellung der beiden Anzahlen der Tage, an denen ein Ladevorgang stattfand, stellt man fest, dass das Elektrofahrzeug knapp $3\frac{1}{2}$ -mal öfter geladen wurde, nachdem es die Nacht vor dem Ladevorgang unterwegs war. Die MitarbeiterInnen sind also abends oftmals mit dem E-Fahrzeug nachhause gefahren, weshalb der Ladevorgang nicht in der Nacht sondern erst am nächsten Tag stattfand.

Um ein besseres Prognoseergebnis zu erhalten, wird eine Datenbereinigung durchgeführt. Dazu werden all jene Werte eliminiert, die nicht zu jenen 90% gehören, welche um den Mittelwert angeordnet sind.

Abbildung 5.8 zeigt die bereinigten Werte der Vollladungen für den Fall, dass das Elektrofahrzeug in der Nacht zuvor mit der Ladestation verbunden war. Dabei fand an 21 Tagen mindestens ein Ladevorgang statt. 80% der Werte liegen zwischen 0,1 und 0,5 Vollladungen. Dieser Bereich wird durch die beiden horizontalen Linien eingegrenzt.

Eine genauere Datenanalyse liefert für die Anzahl der Ladevorgänge den Wert 22. Im Durchschnitt haben also 1,05 Ladevorgänge pro Ladetag stattgefunden. Bei den Ladevorgängen wurde eine Gesamtenergie von 159,2 kWh geladen. Dies entspricht einer durchschnittlichen Energie von 7,6 kWh pro Ladetag. Anders ausgedrückt wurden im Schnitt 0,35 Vollladungen pro Ladetag durchgeführt.

Die Anzahl der Stunden, in denen Energie geladen wurde, betrug in den 21 Ladetagen 114. Dadurch erhält man eine durchschnittliche Ladedauer von 5,4 h pro Ladetag.

Mit den im Vorhinein berechneten Werten ergibt sich für den Durchschnitt der Ladeenergie pro Ladestunde 1,4 kWh.




Abbildung 5.8: Wallbox 1, bereinigte Vollladungen, Fahrzeug war verbunden

In der nachfolgenden Grafik sind die bereinigten Werte der Lademengen unter Annahme, dass das Fahrzeug in der Nacht vor dem Ladevorgang nicht mit der Wallbox verbunden war, ersichtlich. An 67 Tagen fanden Ladevorgänge statt. Da mit dem E-Fahrzeug am Abend oftmals nach Hause gefahren wurde, erfolgte der Start des Ladevorganges erst am nächsten Morgen. Analog zu Abbildung 5.8 befinden sich auch hier über 80% aller Werte im Bereich, welcher durch die beiden horizontalen Linien definiert wird. Allerdings liegt dieser Bereich mit den Grenzen 0,4 und 1 Vollladung auf einem deutlich höheren Niveau.

An den 67 Ladetagen wurden insgesamt 86 Ladevorgänge durchgeführt. Im Durchschnitt erfolgten 1,3 Ladevorgänge pro Ladetag. Die gesamt geladene Energie betrug 980,5 kWh. Dies ergibt für die durchschnittlich geladene Energie pro Tag 14,6 kWh. Vergleicht man diesen Wert mit jenem, bei dem das Fahrzeug verbunden war, so stellt man fest, dass sich diese in etwa um den Faktor zwei unterscheiden. Es wurde also deutlich mehr Energie geladen, wenn das E-Fahrzeug in der Nacht vor dem Ladevorgang nicht mit der Ladestation verbunden war.

Die Anzahl der Stunden, in denen geladen wurde, beträgt 473. Dadurch erhält man für die durchschnittliche Ladedauer 7,06 Ladestunden pro Ladetag. Aufgrund der bisherigen Werte ergibt sich für den Durchschnitt der Ladeenergie pro Ladestunde ein Wert von 2,07 kWh. Dieser Wert ist deutlich höher als jener der anderen Datenmenge, was durch die höhere durchschnittlich geladene Tagesenergiemenge begründet werden kann.




Abbildung 5.9: Wallbox 1, bereinigte Vollladungen, Fahrzeug war nicht verbunden

Bei einer Analyse der beiden vorherigen Abbildungen 5.8 und 5.9 sind keine regelmäßigen oder systematischen Änderungen feststellbar. Deshalb ist es nicht möglich eine genaue Vorhersage für den nächsten Wert aufzustellen, da eine Prognose ungefähr den Mittelwert liefern würde. Um eine zufriedenstellende Prognose zu ermöglichen müssen die Daten dahingehend aufbereitet werden, damit glattere und regelmäßigere Verläufe entstehen. Dies wird durch eine Aufsummierung der Energiemengen erreicht, woraufhin die Veränderung der aufsummierten Energiemenge prognostiziert wird. Anschließend kann eine Rückrechnung auf den Energiewert des entsprechenden Tages durchgeführt werden. Allerdings ist bei dieser Vorgehensweise zu beachten, dass einige der Prognoseverfahren, welche im Theorieteil in Kapitel 3 besprochen wurden, nicht dafür geeignet sind. (vgl. Kapitel 4.2.1)

Die nachfolgenden Abbildungen zeigen die aufsummierten Ladeenergiemengen für die beiden vorhin erläuterten Fälle.




Abbildung 5.10: Wallbox 1, aufsummierte geladene Energie, Fahrzeug war verbunden




Abbildung 5.11: Wallbox 1, aufsummierte geladene Energie, Fahrzeug war nicht verbunden

Bei einem Vergleich der beiden Verläufe kann man erkennen, dass die aufsummierte geladene Energie in Abbildung 5.11 mehr als doppelt so schnell anwächst als in Abbildung 5.10. Dies lässt sich durch den höheren Energiebedarf des Fahrzeuges begründen, da es in der Nacht vor dem Ladevorgang nicht mit der Ladestation verbunden war. Deshalb kann man annehmen, dass eine längere Ausfahrt stattfand.

Geht man analog zu Kapitel 4.2.1 vor und spaltet die aufsummierten Lademengen in die einzelnen Wochentage auf so erhält man die beiden nachfolgenden Grafiken.

Aufgrund der ähnlichen Steigungen macht es für das Prognoseergebnis keinen großen Unterschied, ob man für die Prognoseerstellung als Datengrundlage die einzelnen Wochentage oder die gesamte Woche verwendet. Außerdem stehen bei einer Aufteilung in die einzelnen Tage nur sehr wenige Werte zur Prognoseerstellung zur Verfügung, wodurch keine zufriedenstellenden Ergebnisse erreicht werden.

Deshalb werden die Daten aus Abbildung 5.10 und 5.11 für die Berechnung der Prognose herangezogen.




Abbildung 5.12: Wallbox 1, aufsummierte geladene Energien, Fahrzeug war verbunden




Abbildung 5.13: Wallbox 1, aufsummierte geladene Energien, Fahrzeug war nicht verbunden

Im folgenden Abschnitt wird eine Analyse der Startzeitpunkte der Ladevorgänge der bereinigten Lademengen durchgeführt.

Abbildung 5.14 zeigt die Ladebeginne der bereinigten Ladene Energiemengen für den Fall, dass das Fahrzeug in der Nacht vor dem Ladevorgang an der Ladestation angeschlossen war. Dabei wurden alle Ladevorgänge nach 09:00 Uhr gestartet. Dies scheint durchaus logisch, da an dem Tag, an dem geladen wurde, zuerst eine Ausfahrt mit dem Elektrofahrzeug stattfinden musste, bevor eine Aufladung erforderlich war. Außerdem trat die Mehrheit der Ladestarts, mehr als 76%, nach 12:00 Uhr auf.



Abbildung 5.14: Wallbox 1, Ladebeginne, Fahrzeug war verbunden

Die nachfolgende Grafik zeigt die Ladebeginne, wenn das Fahrzeug die Nacht zuvor unterwegs und somit nicht an der Ladestation angeschlossen war. Dabei fanden alle Starts der Ladevorgänge zwischen 05:00 und 19:00 Uhr statt. Außerdem ist zu erkennen, dass die Mehrheit der Ladungen am Vormittag, genauer gesagt in den Morgenstunden, begonnen wurde. Dies liegt daran, dass die meisten Verbindungsherstellungen des E-Fahrzeuges mit der Ladestation am Morgen bei der Ankunft in der Firma erfolgten.

Bei Ladevorgängen, bei denen das Fahrzeug die Nacht zuvor unterwegs war, fanden knapp 85% aller Ladebeginne vor 12:00 Uhr statt. Weiters kann man in der Abbildung erkennen, dass ungefähr 70% der Aufladungen vor 09:00 Uhr gestartet wurden.



Abbildung 5.15: Wallbox 1, Ladebeginne, Fahrzeug war nicht verbunden

5.3 Lastprognosemodell dienstlich genutzter Elektrofahrzeuge

In diesem Abschnitt wird das Lastprognosemodell für dienstlich genutzte Elektrofahrzeuge erstellt, wobei die in Kapitel 5.2.2 aufbereiteten Daten, sprich die aufsummierten Lademengen wenn das Fahrzeug die Nacht zuvor unterwegs war und diejenigen, bei denen es an der Ladestation angeschlossen war, als Grundlage dienen.

Zuerst werden die im Theorieteil behandelten Prognosemodelle untersucht und die Ergebnisse miteinander verglichen. Dieser Abschnitt wird kurz gehalten, da sich ähnliche Ergebnisse wie in Kapitel 4.3.1.1 ergeben.

Zum Abschluss folgt eine Erläuterung der Implementierung in MATLAB sowie eine Erklärung der Ergebnisse.

5.3.1 Analyse der Prognoseverfahren

Als Auswahlkriterium für das verwendete Verfahren dient der Mittelwert der relativen Fehlerbeträge, welcher sich mithilfe von Formel 4.2 berechnen lässt. Dabei ist zu beachten, dass zur Bestimmung der relativen Fehler der einzelnen Tage (Formel 3.32) die gesamte aufsummierte Ladeenergie als Bezugswert verwendet wird. (vgl. Kapitel 4.3.1)

Außerdem werden die ersten vier Werte nicht zur Ermittlung des Fehlers verwendet, da sie das Prognoseergebnis aufgrund von Initialisierungsvorgängen beziehungsweise Parameterbestimmungen verfälschen würden.

5.3.1.1 Tagesprognosen dienstlich genutzter Elektrofahrzeuge

In diesem Abschnitt wird auf die Ergebnisse der Tagesprognose von Wallbox 1 eingegangen. In der Tabelle 5.9 sind die Mittelwerte der relativen Fehlerbeträge der Prognoseverfahren, welche in Kapitel 3 beschrieben wurden, dargestellt. Als Datengrundlage zur Erstellung der Prognosen dienten die Verläufe der aufsummierten Energiemengen aus Abbildung 5.10 beziehungsweise Abbildung 5.11.

	Fahrzeug war verbunden	Fahrzeug war nicht verbunden
Naive Prognose, aktueller Wert	4,97%	1,48%
Naive Prognose, letzter Trend	2,56%	0,58%
Brown Verfahren	5,50%	1,64%
Holt - Winters Verfahren	1,98%	0,54%
ARIMA Verfahren	2,25%	0,46%
Neuronale Netze	2,45%	0,96%

Tabelle 5.9: Wallbox 1, Mittelwerte der relativen Fehlerbeträge

Auf eine Darstellung der einzelnen Fehlerdiagramme wird hier verzichtet, da sich ähnliche Verläufe als bei den privat genutzten Elektrofahrzeugen (vgl. Kapitel 4.3.1.1) ergeben. Die relativen Fehler der naiven Prognose mit Annahme eines konstanten Wertes als Prognosewert und des Brown Verfahrens wurden zwar berechnet, jedoch werden sie für die nachfolgenden Betrachtungen nicht berücksichtigt. Dies liegt daran, dass sie zur Prognose von aufsummierten Datenreihen nicht geeignet sind. (vgl. Kapitel 4.3.1.1)

Die nachfolgende Tabelle zeigt die Mittelwerte der relativen Fehlerbeträge der verwendbaren Prognoseverfahren. Dabei sind bei einer nächtlichen Verbindung des Fahrzeuges mit der Ladestation annähernd gleich große Mittelwerte der relativen Fehler zu erkennen. Der Unterschied der vier untersuchten Verfahren liegt bei maximal 0,58%. Der geringste Wert tritt beim Holt-Winters Verfahren auf. Dieser beträgt 1,98%.

Die Prognoseerstellung mithilfe der Daten, bei denen keine nächtliche Verbindung bestand, liefert geringere Fehlerwerte. Dies liegt einerseits daran, dass mehr Werte zur Prognoseerstellung vorhanden sind. Dadurch können bessere Ergebnisse erreicht werden. Weiters wurden unterschiedliche Bezugswerte zur Fehlerbestimmung der beiden Fälle verwendet. Da für diese Bezugswerte die aufsummierten geladenen Energiemengen der beiden Datenreihen verwendet wurden und bei keiner nächtlichen Verbindung des E-Fahrzeuges mit der Ladestation deutlich mehr Energie geladen wurde, ist der Fehler in diesem Fall geringer. Deshalb können die Mittelwerte der relativen Fehlerbeträge der beiden Fälle nicht miteinander verglichen werden.

Bei einem Vergleich der Fehlerwerte der einzelnen Prognoseverfahren für den Fall, dass das Elektrofahrzeug nicht mit der Ladestation verbunden war, stellt man Werte unter 1% fest. Die Mittelwerte der relativen Fehlerbeträge unterscheiden sich um maximal 0,5%. Allerdings ist der Fehler des Verfahrens der neuronalen Netze ungefähr doppelt so groß als jener bei den anderen drei Prognoseverfahren. Bei Vernachlässigung des Verfahrens der neuronalen Netze, welches für

den Fall keiner nächtlichen Verbindung die schlechtesten Prognoseergebnisse liefert, bemerkt man in etwa gleich große Fehlerwerte. Diese unterscheiden sich um maximal 0,12%, weshalb eine Prognoseerstellung mithilfe dieser drei Verfahren annähernd gleiche Ergebnisse liefert.

	Fahrzeug war verbunden	Fahrzeug war nicht verbunden
Naive Prognose, letzter Trend	2,56%	0,58%
Holt - Winters Verfahren	1,98%	0,54%
ARIMA Verfahren	2,25%	0,46%
Neuronale Netze	2,45%	0,96%

Tabelle 5.10: Wallbox 1, Mittelwerte der relativen Fehlerbeträge der verwendbaren Prognoseverfahren

In Kapitel 4.3.1.1 wurde bereits erläutert, dass es bei jeder Prognoseerstellung sinnvoll ist, die vorliegenden Daten mit den einzelnen Prognoseverfahren zu analysieren und anschließend das Verfahren mit dem geringsten Fehler auszuwählen. Diese Vorgehensweise sollte deshalb gewählt werden, da sich die Struktur der zur Prognose verwendeten Daten ändern kann. Wird zum Beispiel eine Effizienzsteigerung im Sektor der Elektromobilität erreicht oder ändert sich das Nutzungsverhalten eines Elektrofahrzeuges, so kommt es zu einer Veränderung der geladenen Energiemengen. Dadurch ist es möglich, dass ein anderes Prognoseverfahren als das bisher verwendete bessere Ergebnisse liefert.

Die in Kapitel 5.2.2 ermittelten Werte für die durchschnittlich geladenen Energien pro Ladetag betragen:

- Fahrzeug war verbunden
 - 7,6 kWh
- Fahrzeug war nicht verbunden
 - 14,6 kWh

Mithilfe dieser Werte lassen sich die mittleren absoluten Fehler pro Ladetag bestimmt. Diese Fehler sind in der Tabelle 5.11 dargestellt. Die absoluten Prognosefehler für den Fall, dass das Elektrofahrzeug in der Nacht vor dem Ladevorgang mit der Ladestation verbunden war, liegen zwischen 150 Wh und 195 Wh. Demnach unterscheidet sich der Maximalwert des absoluten Fehlers durch 45 Wh vom minimalen Wert.

Bestand vor dem Ladevorgang keine nächtliche Verbindung zwischen dem E-Fahrzeug und der Ladestation, so sind die Mittelwerte der absoluten Fehler der Tagesprognose um einiges kleiner.

Die Werte liegen zwischen 85 *Wh* und 140 *Wh*. Allerdings sticht bei der Betrachtung der in der Tabelle dargestellten Werte ein hoher absoluter Fehler der Prognose mithilfe der neuronalen Netze ins Auge. Dieser ist ungefähr um den Faktor 1,6 bis 2 größer als die Fehler der anderen drei Verfahren. Die Erklärung dafür liefert der relative Fehler (vgl. Tabelle 5.10), welcher beim Verfahren der neuronalen Netze in etwa doppelt so groß ist als bei den anderen Verfahren.

Die Mittelwerte der absoluten Fehler bei einer beziehungsweise keiner nächtlichen Verbindung des E-Fahrzeuges mit der Ladestation können nicht miteinander verglichen werden. Dies liegt an den unterschiedlich großen Bezugswerten, welche zur Bestimmung der relativen Fehler verwendet wurden.

	Fahrzeug war verbunden	Fahrzeug war nicht verbunden
Naive Prognose, letzter Trend	195 Wh	85 Wh
Holt - Winters Verfahren	150 Wh	79 Wh
ARIMA Verfahren	171 Wh	67 Wh
Neuronale Netze	186 Wh	140 Wh

Tabelle 5.11: Wallbox 1, Mittelwerte der absoluten Fehler der Tagesprognose

Tabelle 5.12 und Abbildung 5.16 zeigen einige ausgewählte Quantile der relativen Fehlerbeträge für den Fall, dass das Elektrofahrzeug in der Nacht vor dem Ladevorgang mit der Ladestation verbunden war. Bei einer Analyse der Tabelle stellt man unterschiedlich große Bereiche der verschiedenen Quantile fest. Die 25%-Quantile der vier Prognoseverfahren liegen 0,67% auseinander. Sieht man sich die 100%-Quantile an, so bemerkt man einen deutlich größeren Abstand. Dieser beträgt 3,01%. Dies liegt daran, dass bei den größeren Quantilen fast alle beziehungsweise beim 100%-Quantil alle Werte miteinbezogen werden. Deshalb werden Ausreißer stärker berücksichtigt, wodurch die Werte dieser Quantile weiter auseinander liegen.

	Fahrzeug war verbunden				
	25%-Quantil	50%-Quantil	75%-Quantil	90%-Quantil	100%-Quantil
Naive Prognose	0,99%	2,72%	3,85%	4,97%	5,50%
Holt - Winters Verfahren	0,66%	1,73%	2,74%	3,88%	5,44%
ARIMA Verfahren	1,30%	1,54%	3,49%	4,25%	4,76%
Neuronale Netze	0,63%	1,67%	3,59%	6,18%	7,77%

Tabelle 5.12: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war verbunden




Abbildung 5.16: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war verbunden

Die nachfolgenden Darstellungen zeigen einige Quantile für den Fall, dass das Fahrzeug in der Nacht vor dem Ladevorgang nicht mit der Ladestation verbunden war. Vergleicht man Tabelle 5.13 mit Tabelle 5.12, so erkennt man deutlich geringere Werte. Da die Anzahl der Ladetage höher ist, wurde mehr Energie geladen. Diese gesamt geladene Energie, welche als Bezugswert zur Fehlerbestimmung verwendet wird, ist höher. Deshalb sind die relativen Fehler (vgl. Tabelle 5.10) und damit die Werte der Quantile geringer.

	Fahrzeug war nicht verbunden				
	25%-Quantil	50%-Quantil	75%-Quantil	90%-Quantil	100%-Quantil
Naive Prognose	0,25%	0,55%	0,85%	1,06%	1,59%
Holt - Winters Verfahren	0,25%	0,41%	0,82%	1,10%	2,07%
ARIMA Verfahren	0,19%	0,43%	0,71%	0,88%	1,07%
Neuronale Netze	0,41%	0,99%	1,36%	1,61%	2,98%

Tabelle 5.13: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war nicht verbunden




Abbildung 5.17: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war nicht verbunden

5.3.1.2 Stundenprognosen dienstlich genutzter Elektrofahrzeuge

Bei der Stundenprognose wird für jede Stunde eine Vorhersage getroffen, wobei als Datengrundlage die gleiche Stunde aller bisherigen Tage dient. (vgl. Kapitel 4.3.1.2) Weiters besteht eine Abhängigkeit zwischen der zur prognostizierenden Stunde und den bisherigen Stunden des Tages.

Bei der Vorhersage wird wiederum die aufsummierte geladene Energiemenge prognostiziert, woraufhin auf den jeweiligen Stundenenergiwert zurückgerechnet werden kann. Analog zu Kapitel 5.3.1.1 wird auch hier auf die Analyse der Prognose mithilfe der naiven Prognose mit Annahme eines konstanten Wertes als Prognosewert und auf das Brown Verfahren verzichtet, da diese in Verbindung mit den vorliegenden Datenreihen keine sinnvollen Ergebnisse liefern.

In Tabelle 5.14 sind die Mittelwerte der relativen Fehlerbeträge der verschiedenen Prognoseverfahren dargestellt. Dabei ist bei einigen Stunden kein Fehler eingetragen. Dies liegt daran, dass in diesen Stunden nichts geladen wurde, weshalb sich kein Prognosefehler bestimmen lässt.

Bei einem genaueren Blick auf die Prognosefehler der Daten, bei denen eine nächtliche Verbindung bestand, stellt man bei der naiven Prognose in der ersten Stunde des Tages einen Mittelwert der relativen Fehlerbeträge von 0,0% fest. Hierfür ist verantwortlich, dass das Elektrofahrzeug zu dieser Zeit nur am zweiten Tag geladen wurde, weshalb das Verfahren ab dem

vierten Tag keinen Anstieg der aufsummierten geladenen Energiemenge vorhersagt. Da der Fehler erst ab dem fünften Tag berechnet wird und die konstant prognostizierten Werte der aufsummierten geladenen Energiemengen mit dem tatsächlichen Werten übereinstimmen, ergibt sich der Fehler von 0,0%.

In der Tabelle ist zu erkennen, dass die Prognose mithilfe der neuronalen Netze sowohl bei einer nächtlichen Verbindung als auch bei keiner nächtlichen Verbindung des Elektrofahrzeuges mit der Ladestation die schlechtesten Ergebnisse liefert. Dies liegt daran, dass nur wenige Werte pro Stunde als Datengrundlage zur Prognoseerstellung zur Verfügung stehen. Dies wirkt sich zwar bei allen vier Prognoseverfahren aus, jedoch hat es bei den neuronalen Netzen den größten Einfluss. Bei diesem Verfahren werden in einem Lernmodus zuerst die Parameter anhand von Eingangsgrößen und deren zugehörigen, bekannten Ausgangsgrößen bestimmt. (vgl. Kapitel 3.1.6) Aufgrund der geringen Anzahlen an Stundenwerten können diese Parameter nicht so genau gelernt werden, wodurch sich größere Fehler ergeben.

Die mittleren Fehler der drei Verfahren mit den geringsten Werten sind in etwa gleich groß. Deshalb wird zur Prognoseerstellung beider Datenreihen das einfache Holt-Winters Verfahren gewählt, wodurch die Berechnungszeit gering gehalten werden kann. (vgl. 4.3.1.2)

Verfahren: Stunde:	Fahrzeug war verbunden				Fahrzeug war nicht verbunden			
	Naive Prognose	Holt Winters	ARIMA	Neuronale Netze	Naive Prognose	Holt Winters	ARIMA	Neuronale Netze
00:00 - 01:00	0,0%	0,6%	14,8%	15,7%	-	-	-	-
01:00 - 02:00	-	-	-	-	-	-	-	-
02:00 - 03:00	-	-	-	-	-	-	-	-
03:00 - 04:00	-	-	-	-	-	-	-	-
04:00 - 05:00	-	-	-	-	-	-	-	-
05:00 - 06:00	8,6%	9,9%	7,8%	15,8%	3,2%	3,0%	3,0%	5,2%
06:00 - 07:00	4,9%	8,5%	6,2%	8,1%	3,1%	2,7%	2,2%	4,2%
07:00 - 08:00	7,7%	7,7%	10,0%	12,6%	2,2%	1,6%	2,0%	7,1%
08:00 - 09:00	11,8%	10,8%	24,2%	17,8%	1,4%	1,5%	1,3%	2,8%
09:00 - 10:00	11,8%	11,3%	8,3%	9,1%	1,2%	1,3%	1,1%	2,9%
10:00 - 11:00	11,5%	11,0%	7,7%	23,3%	1,1%	1,1%	1,0%	2,0%
11:00 - 12:00	9,8%	7,1%	7,9%	13,6%	1,2%	1,1%	0,9%	2,2%
12:00 - 13:00	6,9%	7,0%	8,5%	12,6%	1,3%	1,1%	1,0%	2,6%
13:00 - 14:00	8,6%	3,5%	5,8%	11,0%	1,6%	1,8%	1,6%	3,1%
14:00 - 15:00	7,5%	4,5%	5,8%	14,7%	2,1%	1,8%	2,1%	5,0%
15:00 - 16:00	9,8%	5,8%	8,5%	13,8%	2,1%	2,2%	2,3%	3,9%
16:00 - 17:00	8,1%	6,7%	4,7%	6,4%	2,5%	2,2%	2,8%	5,7%
17:00 - 18:00	5,7%	5,0%	8,1%	14,2%	2,5%	2,2%	2,0%	6,3%
18:00 - 19:00	5,2%	4,7%	7,7%	9,2%	2,6%	2,1%	2,4%	5,7%
19:00 - 20:00	6,3%	7,3%	6,2%	7,9%	2,6%	2,4%	2,2%	4,1%
20:00 - 21:00	6,5%	9,6%	6,2%	6,9%	2,6%	2,5%	2,2%	3,5%
21:00 - 22:00	6,1%	8,5%	4,9%	3,9%	3,0%	2,6%	2,1%	6,2%
22:00 - 23:00	4,9%	7,8%	4,0%	3,4%	3,0%	2,5%	2,6%	6,9%
23:00 - 24:00	5,9%	7,8%	4,9%	5,6%	3,1%	2,6%	2,4%	6,6%
mittlerer Fehler:	7,4%	7,3%	8,1%	11,3%	2,2%	2,0%	2,0%	4,5%

Tabelle 5.14: Wallbox 1, Mittelwerte der relativen Fehlerbeträge der Stundenprognose

In Kapitel 5.2.2 wurden folgende Werte für die durchschnittlich geladene Energiemenge pro Stunde und die Ladestunden pro Ladetag ermittelt:

- Fahrzeug war verbunden:
 - 1,4 kWh / Stunde
 - 5,4 Ladestunden / Ladetag
- Fahrzeug war nicht verbunden:
 - 2,07 kWh / Stunde
 - 7,06 Ladestunden / Ladetag

Mit diesen Werten und den Ergebnissen aus Tabelle 5.14 können die durchschnittlichen absoluten Prognosefehler der Stundenprognose pro Stunde berechnet werden. Die absoluten Fehler der Stundenprognose pro Stunde für den Fall, dass das Fahrzeug in der Nacht vor dem Ladevorgang mit der Ladestation verbunden war, liegen zwischen 104 *Wh* und 158 *Wh*, wobei die Prognose mithilfe der neuronalen Netze, bei der der Fehler von 158 *Wh* auftritt, deutlich schlechtere Ergebnisse liefert, als die drei anderen Verfahren.

Die absoluten Fehler bei keiner nächtlichen Verbindung des Elektrofahrzeuges mit der Ladestation liegen zwischen 41 *Wh* und 93 *Wh*, wobei wiederum die Prognose mit den neuronalen Netzen einen viel größeren Fehler aufweist.

Vergleicht man die Ergebnisse aus Tabelle 5.15 mit jenen der privat genutzten Elektrofahrzeuge in Tabelle 4.6, so lassen sich bei den beiden Fällen (Fahrzeug war verbunden bzw. nicht verbunden) unterschiedliche Resultate feststellen. Bei einer Gegenüberstellung der Ergebnisse der dienstlich genutzten E-Fahrzeuge für den Fall, dass keine nächtliche Verbindung zwischen Fahrzeug und Ladestation bestand, mit jenem von Fahrzeug 1 der privat genutzten Elektrofahrzeuge, bemerkt man annähernd gleich große absolute Prognosefehler.

War das Fahrzeug hingegen in der Nacht vor dem Ladevorgang mit der Ladestation verbunden, so treten zwischen den absoluten Fehlern des dienstlich genutzten Fahrzeuges und des privat genutzten Fahrzeuges 1 deutliche Unterschiede auf. Dies liegt daran, dass beim dienstlich genutzten Elektrofahrzeug nur wenige Werte zur Ermittlung der Prognosen der einzelnen Stunden zur Verfügung stehen. Aufgrund dessen weisen die aufsummierten Daten der einzelnen Stunden, welche als Grundlage zur Prognose verwendet werden, einen sehr unregelmäßigen, sprunghaften Verlauf auf, wodurch sich höhere relative und damit größere absolute Fehler ergeben. Außerdem ist der Bezugswert, welcher zu Fehlerbestimmung verwendet wird, aufgrund der wenigen Werte der geladenen Energien geringer, was ebenfalls zu einem höheren relativen Fehler führt.

	Fahrzeug war verbunden	Fahrzeug war nicht verbunden
Naive Prognose	104 Wh	46 Wh
Holt – Winters Verfahren	102 Wh	41 Wh
ARIMA Verfahren	113 Wh	41 Wh
Neuronale Netze	158 Wh	93 Wh

Tabelle 5.15: Wallbox 1, Mittelwerte der absoluten Fehler der Stundenprognose pro Stunde

Mithilfe der Ladestunden pro Ladetag können die durchschnittlichen Mittelwerte der absoluten Fehler der Stundenprognose pro Tag ermittelt werden. Diese sind in der Tabelle 5.16 aufgelistet. Die absoluten Fehler der Stundenprognose pro Tag liegen bei einer nächtlichen Verbindung vor dem Ladevorgang zwischen 551 *Wh* und 853 *Wh* und bei keiner nächtlichen Verbindung zwischen 290 *Wh* und 657 *Wh*. Dabei liefern die Prognosen mithilfe der neuronalen Netze die schlechtesten Ergebnisse.

Ein Vergleich dieser Werte mit jenen der Tagesprognose aus Tabelle 5.11 zeigt, dass sich bei der Stundenprognose viel höhere absolute Fehler ergeben. Dies kann wiederum auf die geringe Anzahl an Werten, welche als Datengrundlage zur Prognose der einzelnen Stunden dienen, zurückgeführt werden. (vgl. Kapitel 4.3.1.2)

	Fahrzeug war verbunden	Fahrzeug war nicht verbunden
Naive Prognose	561 Wh	325 Wh
Holt – Winters Verfahren	551 Wh	290 Wh
ARIMA Verfahren	610 Wh	290 Wh
Neuronale Netze	853 Wh	657 Wh

Tabelle 5.16: Wallbox 1, Mittelwerte der absoluten Fehler der Stundenprognose pro Tag

5.3.2 Realisierung

In diesem Unterkapitel wird die Erstellung des MATLAB-Programms, welches zur Prognose des Energiebedarfes von dienstlich genutzten Elektrofahrzeugen verwendet wird, erläutert.

Zuerst erfolgt eine Beschreibung des Programmablaufs sowie des Aufbaus des grafischen User Interfaces.

Dabei wird auf die Erklärung der einzelnen Funktionen des Programms verzichtet, da dies den Umfang dieser Arbeit übersteigen würde.

Zum Abschluss werden die Ergebnisse betrachtet und eine Schlussfolgerung gezogen.

5.3.2.1 *MATLAB - Programm*

In der Abbildung 5.18 ist der Aufbau des MATLAB-Programms dargestellt. In Kapitel 5.1 wurde bereits erwähnt, dass als Eingangsparameter die Daten eines Renault Kangoos dienen, welche von der Firma VLOTTE zur Verfügung gestellt wurden. Dabei hat eine Ladestation, die sogenannte Wallbox 1, über einen Zeitraum von 488 Tagen die Ladeleistungen sowie die Ladezeiten protokolliert. (vgl. Kapitel 5.2) Mithilfe dieser Daten und den im vorigen Abschnitt untersuchten Prognoseverfahren soll nun im folgenden Teil eine Implementierung in MATLAB durchgeführt werden. Wie es bereits bei der Realisierung des Prognosemodells für privat genutzte Fahrzeuge der Fall war, besteht auch hier die Möglichkeit zwischen 2 verschiedenen Modi zu wählen. Modus 1 dient dazu, die Prognoseergebnisse der einzelnen Verfahren mit den vorhandenen Daten der Wallbox 1 darzustellen und bei Auswahl von Modus 2 wird die Prognose der benötigten Energiemenge erstellt. Eine genauere Beschreibung der Abläufe bei der Wahl der beiden Modi erfolgt im nächsten Abschnitt.




Abbildung 5.18: dienstlich genutzte E-Fahrzeuge, MATLAB Modell

Beim Starten des Programms erscheint das folgende grafische User Interface, wobei zwischen den beiden im Vorhinein erwähnten Modi

- Modus 1: Daten darstellen und
- Modus 2: Prognose

gewählt werden kann.





Abbildung 5.19: dienstlich genutzte E-Fahrzeuge, Modus Auswahl

Abbildung 5.20 zeigt die Eingabemaske bei Auswahl von Modus 1. Hierbei ist das gewünschte Prognoseverfahren auszuwählen, wobei unter den folgenden Verfahren selektiert werden kann:

- 1 Naive Prognose mit Annahme eines konstanten Wertes als Prognosewert
- 2 Naive Prognose mit Annahme eines konstanten Wertes zuzüglich des letzten Trends als Prognosewert
- 3 Brown Verfahren
- 4 Holt-Winters Verfahren
- 5 ARIMA Verfahren
- 6 Neuronale Netze

Da die Verfahren 1 und 3 nicht zur Prognose der vorliegenden Datenmenge geeignet sind, werden diese bei Auswahl von Modus 2 nicht berücksichtigt. (vgl. Kapitel 4.3.2.1)



The screenshot shows a software window titled 'main' with a subtitle 'Ladeenergieprognose von Wallbox 1:'. Below the subtitle, there are two dropdown menus. The first is labeled 'Modus auswählen:' and has 'Daten darstellen' selected. To its right is a button labeled 'Berechnung'. The second dropdown menu is labeled 'Prognoseverfahren:' and has 'Naive Prognose, const. Wert' selected.

Abbildung 5.20: dienstlich genutzte E-Fahrzeuge, Modus 1, Eingabemaske

Die folgende Abbildung zeigt die Ergebnisse bei Auswahl der naiven Prognose bei Verwendung des aktuellen Wertes zuzüglich des letzten Trends zur Prognoseerstellung. Dabei wird die Differenz zwischen der aufsummierten Energie und den Prognosewerten dargestellt. Weiters werden die relativen Fehler für die beiden Fälle, dass das Fahrzeug in der Nacht vor dem Ladevorgang mit der Ladestation verbunden beziehungsweise nicht verbunden war, dargestellt.

Hierbei ist jedoch zu beachten, dass die Fehler der beiden Fälle nicht miteinander vergleichbar sind, was daran liegt, dass als Bezugswerte zur Fehlerbestimmung jeweils die maximal aufsummierten Energien verwendet werden, welche sich unterscheiden (vgl. Kapitel 4.3.2.1). Deshalb ist der Fehler bei keiner nächtlichen Verbindung geringer, da mehr Energie geladen wurde, wenn das Fahrzeug in der Nacht vor dem Ladevorgang unterwegs war. Zum Abschluss erfolgt eine Ermittlung der beiden Mittelwerte der Fehlerbeträge, wodurch sich die einzelnen Prognoseverfahren miteinander vergleichen lassen.




Abbildung 5.21: dienstlich genutzte E-Fahrzeuge, Modus 1, Daten darstellen

Bei Auswahl von Modus 2 erscheint das grafische User Interface, welches in Abbildung 5.22 dargestellt ist. Dabei kann neben dem Prognoseverfahren ein Datum und eine Stunde eingegeben werden, wobei das ausgewählte Datum einem bestimmten Tag und die Stunde der Tageszeit entspricht. Für die nachfolgenden Betrachtungen wird angenommen, dass nicht der letzte Ladetag in den aufgezeichneten Daten ausgewählt wird. Dadurch können die Prognosewerte mit den tatsächlichen Werten der geladenen Energien verglichen werden.

The screenshot displays the 'Ladeenergieprognose von Wallbox 1' software interface in Modus 2. The input fields are as follows:

- Modus auswählen: **Prognose**
- Prognoseverfahren: **Holt und Winters Verfahren**
- Datum auswählen: **20.10.2014** (01.04.2014 - 20.02.2015)
- Stunde auswählen: **00**

A **Berechnung** button is located next to the 'Modus auswählen' field.

Abbildung 5.22: dienstlich genutzte E-Fahrzeuge, Modus 2, Eingabemaske

Nach Wahl der gewünschten Parameter kann die Prognoseerstellung erfolgen. Die drei nachfolgenden Abbildungen zeigen die Ergebnisse für den 20.10.2014 zu verschiedenen Tageszeiten.

In der Abbildung 5.23 sind die Ergebnisse für 06:00 Uhr morgens dargestellt. Dabei wird zuerst der Verbindungszustand des Elektrofahrzeuges ermittelt und ausgegeben. Dies bedeutet für die gewählten Parameter, dass das Fahrzeug unterwegs und somit nicht an der Ladestation angeschlossen ist.

Anschließend erfolgt die Prognoseerstellung für den nächsten Ladetag. Dabei werden die vorhergesagte Energiemenge, die tatsächlich geladene Energiemenge, sowie der Prognosefehler berechnet und ausgegeben.

Zum Abschluss der Berechnungen wird die Stundenprognose für den folgenden Ladetag ermittelt, wobei als Prognoseverfahren das Holt-Winters Verfahren gewählt wurde. (vgl. Kapitel 5.3.1.2)

Nach den Berechnungen werden die Differenzen zwischen den aufsummierten Energien und den zugehörigen Prognosewerten des gewählten Verfahrens dargestellt, woraufhin eine Darstellung der Ladeprognose für den nächsten Tag folgt.

Laut Kapitel 5.2.2 wurde das Elektrofahrzeug im Datenaufzeichnungszeitraum von 488 Tagen insgesamt 96-mal aufgrund einer Ausfahrt geladen, was im Durchschnitt einem Ladevorgang an ungefähr jedem fünften Tag entspricht. Aufgrund der seltenen Ladevorgänge kann zwar eine Ladeprognose für den aktuellen Tag erstellt werden, jedoch ist es wahrscheinlicher, dass an diesem Tag nichts geladen wird. Die Schwierigkeit der Prognose liegt also nicht bei der Ermittlung des benötigten Energiebedarfs, sondern bei der Vorhersage ob ein Ladevorgang stattfindet oder nicht. Dieses Problem lässt sich mithilfe eines Reservierungssystems, auf welches in Kapitel 5.4 kurz eingegangen wird, lösen.




Abbildung 5.23: dienstlich genutzte E-Fahrzeuge, Modus 2, 20.10.2014, 06:00 Uhr

Die folgende Abbildung zeigt die Prognoseergebnisse für den gleichen Tag um 12:00 Uhr. Hierbei kann man erkennen, dass das Fahrzeug gerade an der Ladestation angeschlossen ist und geladen wird. Dabei wird wiederum die Prognose der benötigten Energiemenge, die tatsächlich geladene Energiemenge sowie der Prognosefehler für den folgenden Ladetag bestimmt, wobei zu beachten ist, dass die Energieprognose aufgrund des aktuellen Verbindungsstatus geschieht. Vergleicht man die prognostizierte Energie für den nächsten Ladetag von Abbildung 5.23 mit jener von Abbildung 5.24, so stellt man fest, dass sich diese beiden unterscheiden, was auf die Änderung des Verbindungszustandes zurückzuführen ist. In der vorherigen Abbildung sind die Daten bei nächtlicher Verbindung und in der nachfolgenden jene bei keiner nächtlichen Verbindung zur Prognoseerstellung verwendet worden.

Nach der Prognoseerstellung des folgenden Tages wird der aktuelle Tag näher betrachtet. Zuerst erfolgt die Prognoseerstellung der Tagesladungsmenge. Außerdem werden die tatsächlich geladene Energie und der Prognosefehler ermittelt. Im Anschluss daran wird der aktuelle Ladestand ermittelt, woraufhin der Prognosewert für die noch zu ladende Energie sowie die tatsächlich geladene Energie bestimmt werden.

Nach der Tagesprognose wird die Stundenprognose und deren mittlerer Prognosefehler berechnet, wobei als Prognoseverfahren ebenfalls das Holt-Winters Verfahren dient. Zum Abschluss werden die aufsummierten Energien sowie die Ladeprognosen der beiden Tage dargestellt.




Abbildung 5.24: dienstlich genutzte E-Fahrzeuge, Modus 2, 20.10.2014, 12:00 Uhr

Die Abbildung 5.25 zeigt die Ergebnisse für 18:00 Uhr. Hierbei ist zu erkennen, dass der Ladevorgang beendet wurde und das Fahrzeug wieder unterwegs ist, weshalb es zu einer Änderung des Verbindungsstatus und somit zu einer Prognoseänderung des Energiebedarfs des nächsten Ladetages kommt.




Abbildung 5.25: dienstlich genutzte E-Fahrzeuge, Modus 2, 20.10.2014, 18:00 Uhr

5.3.3 Ergebnisse und Schlussfolgerung

In diesem Kapitel wird ein Lastprognosemodell für dienstlich genutzte Elektrofahrzeuge erstellt. Dieses soll eine Prognose des Energiebedarfs für den aktuellen sowie den folgenden Tag mit einer Prognoseschrittweite von einer Stunde ermöglichen. Die Daten, welche im Zuge einer früheren Bachelorarbeit [10] aufbereitet wurden, stammen von der Firma VLOTTE deren Sitz in Vorarlberg ist. Dabei wurden von einem Elektrofahrzeug des Typs Renault Kangoo an 488 Tagen verschiedene Parameter von der Ladestation, welche Wallbox 1 genannt wird, aufgezeichnet. In diesem Kapitel sind die Ladeleitungen, die Ladezeitpunkte sowie der Plugwert des Elektrofahrzeuges, welcher den Verbindungsstatus des E-Fahrzeuges mit der Ladestation beschreibt, von Bedeutung.

Laut [10] wird das Elektrofahrzeug entsprechend eines Regelalgorithmus mit einem von der Erzeugungsleistung einer Photovoltaikanlage abhängigen Strom geladen. Dadurch kommt es zu

einer effizienten Nutzung des durch die Photovoltaikanlage produzierten Stroms. Der minimale Ladestrom bei angeschlossenem und nicht vollständig geladenem E-Fahrzeug beträgt 6 A. Dieser Strom erhöht sich in Abhängigkeit von der momentanen Photovoltaik Erzeugungsleistung bis zu einem Maximalwert von 16 A.

Bei der Analyse der Datenbank wird festgestellt, dass an zwei Tagen mit sehr hohen Leistungen, welche ungefähr 4,5 kW betragen, geladen wurde. Dies ist jedoch nicht möglich, da die maximale Ladeleistung aufgrund des Maximalwertes des Ladestroms 3,68 kW beträgt. Der Grund für diese hohen Leistungen sind Aufzeichnungsfehler. An diesen Tagen wurden die Ladeleistungen zu bestimmten Tageszeiten mehrmals abgespeichert, wodurch sich größere geladene Energien ergeben. Weiters sind in der Datenbank Ladevorgänge zu erkennen, obwohl das Elektrofahrzeug durchgehend an der Ladestation angeschlossen war. Hierbei handelt es sich um Ladevorgänge, die aufgrund des Batterietyps, der ZEBRA-Batterie, des E-Fahrzeuges durchgeführt werden müssen. Diese muss durch zyklische Ladevorgänge auf einer Betriebstemperatur von 280° - 350°C gehalten werden [11]. Dabei kann laut [11] davon ausgegangen werden, dass eine Heizleistung von rund 5W pro kWh Speichervermögen benötigt wird. Diese Ladevorgänge werden im Zuge der Prognoseerstellung nicht berücksichtigt.

Damit Ladevorgänge, bei denen nur geringe Energiemengen geladen werden, die Vorhersage der zukünftigen Energiemenge nicht verfälschen, werden all jene Tagesenergiemengen nicht berücksichtigt, bei denen weniger als 10% der maximalen Ladekapazität der ZEBRA-Batterie geladen wurde. Dies entspricht der Energiemenge von 2,2 kWh.

Nachdem die Daten bereinigt wurden, werden sie genauer analysiert und aufbereitet. An 96 Tagen fand mindestens ein Ladevorgang statt. Bei Betrachtung der geladenen Energien dieser Tage lassen sich keine regelmäßigen oder systematischen Änderungen feststellen. Da die geladenen Energiemengen im Bereich zwischen 2.2 kWh und 24.2 kWh schwanken, werden sie unterteilt. Dabei wird bei der Aufteilung unterschieden, ob das Fahrzeug in der Nacht vor dem Ladevorgang unterwegs oder an der Ladestation angeschlossen war. Im Zuge dieser Arbeit wird für die Nacht der Zeitraum zwischen 23:00 Uhr abends und 05:00 Uhr morgens angenommen.

Nach der Aufteilung der Daten kann man feststellen, dass für den Fall einer nächtlichen Verbindung deutlich weniger Energie geladen wurde. Außerdem fanden mehr als dreiviertel der Ladetage statt, nachdem das Fahrzeug in der Nacht vor dem Ladevorgang unterwegs und somit nicht an der Ladestation angeschlossen war. Um bessere Prognoseergebnisse zu erhalten, wird eine Bereinigung der beiden Datenmengen durchgeführt. Dazu werden all jene Werte eliminiert,

die nicht zu jenen 90% gehören, welche um den Mittelwert angeordnet sind. Dadurch erhält man für den Fall einer nächtlichen Verbindung 21 und für den Fall keiner nächtlichen Verbindung vor dem Ladevorgang 67 Tage, an denen mindestens ein Ladevorgang stattfand.

Wenn das Elektrofahrzeug in der Nacht vor dem Ladevorgang mit der Ladestation verbunden war, so haben im Durchschnitt 1,05 Ladevorgänge pro Ladetag stattgefunden, wobei durchschnittlich 7,6 kWh geladen wurden. Der Durchschnittswert der Ladedauer pro Ladetag beträgt 5,4 h.

War das E-Fahrzeug in der Nacht vor dem Ladevorgang nicht an der Ladestation angeschlossen, dann wurden durchschnittlich 1,3 Ladevorgänge pro Ladetag durchgeführt. Die Durchschnittswerte für die geladene Energie pro Ladetag und für die Ladestunden pro Ladetag betragen 14,6 kWh und 7,06 h. Vergleicht man diese Werte mit jenen für den Fall einer nächtlichen Verbindung, so stellt man sowohl bei der Ladeenergie als auch bei der Ladedauer deutlich höhere Werte fest, was daran liegt, dass das Elektrofahrzeug länger unterwegs war. Dies rechtfertigt die durchgeführte Unterteilung aufgrund des Kriteriums ob das Fahrzeug in der Nacht vor dem Ladevorgang angeschlossen oder nicht angeschlossen war.

Da eine Prognoseerstellung anhand der geladenen Energiemengen in etwa den Mittelwert liefern würde, müssen die beiden Datenmengen dahingehend aufbereitet werden, sodass akzeptable Prognoseergebnisse erreicht werden. Dies geschieht durch Aufsummierung der geladenen Energiemengen, wodurch sich regelmäßiger und glattere Verläufe ohne große Sprünge ergeben. Bei der Prognose wird die Änderung der aufsummierten geladenen Energiemenge erstellt, woraufhin eine Rückrechnung auf den jeweiligen Wert erfolgt.

In Kapitel 5.3.1 erfolgt eine Untersuchung der Prognoseverfahren, welche im Theorieteil besprochen werden. Zur Bewertung der Qualität der verschiedenen Prognoseverfahren wird der Mittelwert der relativen Fehlerbeträge verwendet. Dabei können nicht alle Prognoseverfahren zur Prognose der vorliegenden Datenreihen angewendet werden. Der Grund liegt daran, dass zwei Prognoseverfahren eine kleiner werdende aufsummierte Energiemenge vorhersagen, was jedoch nicht möglich ist.

Bei der Tagesprognose kann man für die verschiedenen Prognoseverfahren für den Fall, dass das Fahrzeug in der Nacht vor dem Ladevorgang mit der Ladestation verbunden war, absolute Fehler zwischen 150 Wh und 195 Wh feststellen. Die absoluten Fehler sind für den Fall keiner nächtlichen Verbindung deutlich geringer. Sie liegen zwischen 67 Wh und 140 Wh. Diese

Unterschiede ergeben sich einerseits dadurch, dass bei keiner nächtlichen Verbindung deutlich mehr Werte zur Prognoseerstellung verfügbar sind, wodurch bessere Prognoseergebnisse erreicht werden. Außerdem ist zu beachten, dass die Fehler bei einer nächtlichen Verbindung des Fahrzeuges mit der Ladestation nicht mit jenen bei keiner nächtlichen Verbindung verglichen werden können. Der Grund dafür liegt darin, dass als Bezugswerte für die Fehlerberechnung jeweils die beiden gesamten aufsummierten Energiewerte, welche sich unterscheiden, verwendet werden. (vgl. Kapitel 5.3.1)

Analysiert man die Ergebnisse der Stundenprognose, so stellt man fest, dass die mittleren Prognosefehler pro Stunde der beiden Fälle bei allen Verfahren, außer der Prognose mithilfe von neuronalen Netzen, bei welcher der Fehler deutlich höher ist, in etwa gleich groß sind. Sie liegen bei den drei Verfahren mit den geringsten Fehlern bei einer nächtlichen Verbindung zwischen 102 *Wh* und 113 *Wh* und bei keiner nächtlichen Verbindung zwischen 41 *Wh* und 46 *Wh*. Aufgrund der annähernd gleich großen Prognosefehler der drei einfacheren Verfahren wurde das Holt und Winters Verfahren zur Erstellung der Stundenprognose gewählt. Dies liegt einerseits daran, dass es laut Theorie bessere Ergebnisse liefert als die einfachere naive Prognose mit Annahme eines konstanten Wertes zuzüglich des letzten Trends als Prognosewert und andererseits daran, dass die Prognose mithilfe des ARIMA Modells sehr viel Rechenzeit in Anspruch nimmt und keine besseren Ergebnisse liefert.

Vergleicht man die absoluten Prognosefehler der Stundenprognose pro Tag, welche mithilfe der durchschnittlichen Ladedauer pro Ladetag ermittelt werden, mit jenen der Tagesprognose, so stellt man fest, dass die Fehler der Stundenprognose deutlich größer sind. Der Hauptgrund dafür liegt daran, dass bei der Stundenprognose nur wenige Werte zur Prognose der einzelnen Stunden zur Verfügung stehen, wodurch größere Prognoseabweichungen auftreten.

Die vorherigen Abschnitte dieser Arbeit haben gezeigt, dass eine Prognose des benötigten Energiebedarfs von Elektrofahrzeugen mit zufriedenstellendem Ergebnis erstellt werden kann. Die Schwierigkeit bei der Prognoseerstellung liegt also nicht bei der Prognose der Energiemenge, sondern bei der Vorhersage der Ladezeitpunkte. Diese lassen sich zwar prinzipiell ziemlich genau prognostizieren, jedoch kann es bei Abweichungen vom üblichen Fahrverhalten zu hohen Abweichungen bei den Prognosewerten der einzelnen Stundenladungen kommen. Dieses Problem kann mithilfe eines Reservierungssystems, welches in Kapitel 5.4 kurz behandelt wird, behoben werden.

5.4 Fiktives Reservierungssystem

Die Ergebnisse der beiden entwickelten Modelle haben gezeigt, dass sich zwar eine zufriedenstellende Prognose des benötigten Energiebedarfs von privat- beziehungsweise dienstlich genutzten Elektrofahrzeugen aufstellen lässt, es jedoch schwierig ist, die genauen Ladezeitpunkte zu prognostizieren, falls diese vom generellen Verhalten abweichen.

Deshalb ist es bei dienstlich genutzten Elektrofahrzeugen in Verbindung mit einem Elektrofahrzeugfuhrpark sinnvoll, ein Reservierungssystem zu implementieren. Dadurch kann man eine effiziente Zuordnung von Fahrzeugen eines Fuhrparks zu MitarbeiterInnen vornehmen, wodurch nicht immer alle Fahrzeuge vollständig geladen werden müssen.

Mithilfe eines Reservierungssystems ist es zum Beispiel möglich, dass Elektrofahrzeuge mit einem niedrigen Batterieladezustand für geringe Distanzen verwendet werden, wodurch die E-Fahrzeuge mit einem hohen Ladezustand für längere Ausfahrten verfügbar bleiben.

Weiters ist es möglich die einzelnen Fahrzeuge in Abhängigkeit der benötigten Ladeenergiemengen zu laden. Dadurch müssen sie nicht immer vollständig geladen werden, wodurch der Strombedarf in Spitzenlastzeiten sinkt. Dies führt in weiterer Folge zu einer Kostensenkung sowie zu einer Entlastung des Versorgungsnetzes.

Die Abbildung 5.26 zeigt eine mögliche Realisierung eines Reservierungssystems mithilfe von MATLAB und Outlook. Dabei tragen die Personen, welche ein Fahrzeug benötigen, die Zeitpunkte der Fahrtantritte sowie die Beanspruchungsdauer in einen Kalender ein. Optional kann die zurückzulegende Wegstrecke angegeben werden, wodurch eine direkte Ermittlung der benötigten Energie erfolgen kann.

Bei Angabe keiner Strecke wird das Prognosemodell zur Bestimmung des Energiebedarfes verwendet. Dabei ist die Ermittlung der Energieprognosen allerdings nicht auf Grundlage der Elektrofahrzeuge möglich. Dies liegt daran, dass die verschiedenen Fahrzeuge nicht immer von denselben Personen verwendet werden. Bei Firmen mit einer willkürlichen Zuteilung von E-Fahrzeugen zu MitarbeiterInnen ist es wahrscheinlicher, dass die Personen ein regelmäßigeres Fahrverhalten aufweisen als die einzelnen Fahrzeuge.

Deshalb ist es sinnvoll, den Energiebedarf der einzelnen Angestellten zu protokollieren und als Datengrundlage zu verwenden.

Nachdem die einzelnen MitarbeiterInnen, welche ein Elektrofahrzeug benötigten, ihre Daten in den Kalender eingetragen haben und die benötigten Energiemengen ermittelt wurden, kann vom Reservierungssystem eine Fahrzeugzuordnung erfolgen. Dabei werden die verfügbaren Elektrofahrzeuge und deren Ladestände ermittelt, woraufhin die Zuordnung der Fahrzeuge, aufgrund der benötigten Energiemengen und der aktuellen Ladestände, durchgeführt wird.

Ist der Ladestand des zugeordneten E-Fahrzeuges kleiner als die für die Ausfahrt benötigte Energiemenge so muss das Fahrzeug vor der Ausfahrt geladen werden. Andernfalls kann das Fahrzeug dann geladen werden, wenn genug Strom, welcher zum Beispiel durch eine hauseigene Photovoltaikanlage erzeugt wird, vorhanden ist.

Zum Abschluss wird die Fahrzeugzuordnung in den Kalender eingetragen, woraufhin die einzelnen MitarbeiterInnen ihr zugeteiltes Fahrzeug abfragen können. Außerdem kann an die Angestellten eine Nachricht gesendet werden, wodurch sie sich den Blick in den Kalender ersparen.




Abbildung 5.26: Mögliche Realisierung eines Reservierungssystems

6 Zusammenfassung

Im Zuge dieser Arbeit werden mithilfe von MATLAB zwei Modelle entwickelt, welche zeitliche und energetische Prognosen der Energiebedarfe von privat- beziehungsweise dienstlich genutzten Elektrofahrzeugen ermöglichen. Dabei wird als Prognosehorizont ein Tag und als Schrittweite eine Stunde gewählt.

Aufgrund der wachsenden Anzahl von elektrisch betriebenen Fahrzeugen steigt der Leistungsbedarf, wodurch es zu einem Anstieg der Lastspitzen kommt. Dies führt zu einer höheren Auslastung des Versorgungsnetzes sowie zu höheren Kosten, da mehr Kraftwerke zur Deckung des erhöhten Leistungsbedarfs benötigt werden. Deshalb ist der Einsatz einer Laststeuerung (engl. „Demand Side Management“, kurz DSM) sinnvoll. Dadurch kann eine Lastverschiebung und somit eine Verringerung der Lastspitzen erreicht werden. Um DSM einsetzen zu können ist es erforderlich, dass die benötigte Energiemenge im Vorhinein bekannt ist. Dazu wird die Lastprognose eingesetzt, bei der zukünftige Werte aufgrund von Vergangenheitsinformationen vorhergesagt werden.

Das erste Modell dient zur Prognose des Energiebedarfs von privat genutzten Elektrofahrzeugen. Die verwendeten Daten stammen von der Modellregion Köstendorf aus Salzburg, wobei von 26 Elektrofahrzeugen die Ladeleistungen und die Ladezeitpunkte protokolliert wurden. Im Zuge der Datenaufbereitung und Prognoseerstellung wird das Fahrzeug 1 verwendet, da es dem Mittel aller E-Fahrzeuge nahe kommt. Außerdem werden alle Elektrofahrzeuge zu einem Fahrzeugpool zusammengefasst, welcher ebenfalls näher betrachtet wird. Da sich die geladenen Energiemengen der einzelnen Wochentage unterscheiden werden die Prognosen auf Basis der einzelnen Wochentage erstellt. Für die Analyse der Prognoseverfahren wird der Sonntag gewählt, da die geladenen Energiemengen dieses Tages dem Durchschnitt aller Tage entsprechen.

Das zweite Modell dient zur Vorhersage des Energiebedarfs von dienstlich genutzten E-Fahrzeugen, wobei die Daten von der Firma VLOTTE, deren Sitz in Vorarlberg ist, zur Verfügung gestellt wurden. Dabei wurden von einem Elektrofahrzeug des Typs Renault Kangoo die Ladeleistungen und die Ladezeitpunkte aufgezeichnet.

Am Beginn der Modellentwicklung werden die Daten aufbereitet und analysiert. Dabei wird festgestellt, dass sowohl bei den Daten der privat genutzten Elektrofahrzeuge als auch bei jenen der dienstlich genutzten E-Fahrzeuge Aufzeichnungsfehler auftreten. Aufgrund der maximalen Ladeströme von 16 A betragen die maximalen Ladeleistungen $3,68\text{ kW}$. In den Daten treten

jedoch Ladeleistungen auf, welche größer als $3,68\text{ kW}$ sind. Da es sich bei diesen hohen Werten um Aufzeichnungsfehler handelt, werden sie aus den Daten eliminiert.

Weiters werden Tage, an denen sehr wenig Energie geladen wurde, bei der Prognoseerstellung nicht berücksichtigt, da sie die Prognoseergebnisse verfälschen würden.

Bei Betrachtung der Daten des privat genutzten Elektrofahrzeuges stellt man fest, dass bei Fahrzeug 1 am Sonntag eine durchschnittliche Energie von $6,02\text{ kWh}$ geladen wurde. Der Durchschnittswert eines Fahrzeuges des Fahrzeugpools liegt bei $7,5\text{ kWh}$. Demnach wurde bei einem durchschnittlichen Fahrzeug des Pools um ungefähr $1,5\text{ kWh}$ mehr Energie geladen als beim Fahrzeug 1.

Nach dem Bereinigen der Werte des dienstlich genutzten Fahrzeuges stehen 96 Tage zur Verfügung, wobei an jedem Tag mindestens ein Ladevorgang stattfand. Dabei wurden Energiemengen geladen, welche im Bereich zwischen $2,2\text{ kWh}$ und $24,2\text{ kWh}$ liegen. Da die Energiemengen in diesem großen Bereich schwanken, werden die Daten unterteilt. Bei der Aufteilung wird unterschieden, ob das Fahrzeug in der Nacht vor dem Ladevorgang unterwegs oder mit der Ladestation verbunden war. Als Nacht wird der Zeitraum zwischen 23:00 Uhr abends und 05:00 Uhr morgens angesehen. Nach der Unterteilung bemerkt man, dass das Elektrofahrzeug 22-mal geladen wurde, wenn es in der Nacht vor dem Ladevorgang mit der Ladestation verbunden war. Die durchschnittlich geladene Energie pro Ladetag beträgt $7,6\text{ kWh}$. Weiters kann man an 74 Tagen Ladevorgänge feststellen, falls das E-Fahrzeug in der Nacht vor dem Ladevorgang nicht an der Ladestation angeschlossen war. Der Durchschnittswert für die geladene Energie pro Ladetag ergibt sich zu $14,6\text{ kWh}$. Diese unterschiedlich hohen Werte der Ladeenergien rechtfertigen die Aufteilung der Daten aufgrund des gewählten Kriteriums. Nachdem die Daten aufbereitet und bereinigt wurden, werden Ausreißerwerte eliminiert. Dazu werden alle Werte nicht berücksichtigt, die nicht zu jenen 90% gehören, welche um den Mittelwert aller Werte angeordnet sind.

Die geladenen Energien der Elektrofahrzeuge weisen keine systematischen oder regelmäßigen Änderungen auf, wodurch bei einer Prognose lediglich der Mittelwert vorhergesagt wird. Deshalb werden sie aufsummiert, wodurch glattere regelmäßige Verläufe entstehen von denen zufriedenstellende Prognosen erstellt werden können. Bei der Prognoseerstellung wird die Änderung der gesamt geladenen Energiemenge vorhergesagt, woraufhin eine Rückrechnung auf den tatsächlichen Wert erfolgt. Allerdings sind nicht alle Prognoseverfahren, welche im

Theorieteil besprochen werden, für die Prognoseerstellung der aufsummierten Daten geeignet, da die Vorhersagen keine sinnvollen Ergebnisse liefern. Der Grund liegt daran, dass bestimmte Prognoseverfahren eine kleiner werdende aufsummierte Energiemenge vorhersagen. Dies ist allerdings nicht möglich.

Die zwei erstellten Modelle ermöglichen einerseits eine Darstellung der Ergebnisse der verschiedenen Prognoseverfahren aufgrund der aufbereiteten aufsummierten Datenmengen und andererseits können mit ihnen die Energiebedarfe für den aktuellen und den folgenden Tag mit einer Schrittweite von einer Stunde prognostiziert werden. Zur Bewertung der Qualität der verschiedenen Prognoseverfahren wird der Mittelwert der relativen Fehlerbeträge verwendet.

Die Auswertungen der Resultate der Prognosen zeigen, dass die Vorhersage des Energiebedarfs eines Fahrzeugpools geringere Prognosefehler aufweist als jene eines einzelnen Fahrzeuges, was sich dadurch begründen lässt, dass die Aufsummierung der Energien mehrere Fahrzeuge zu einem glatteren und regelmäßigen Verlauf der geladenen Energie führt, weshalb die Prognoseverfahren bessere Ergebnisse liefern. Außerdem werden zur Fehlerberechnung unterschiedliche Bezugswerte verwendet. Hierfür werden die gesamt geladenen Energiemengen herangezogen. Da beim Fahrzeugpool deutlich mehr Energie geladen wurde, sind die Mittelwerte der relativen Fehlerbeträge um einiges geringer.

Im Zuge der Arbeit wird ersichtlich, dass zufriedenstellende Prognosen der Energiebedarfe eines ganzen Tages und der einzelnen Stunden aufgestellt werden können. Die Ergebnisse zeigen, dass die mittleren absoluten Prognosefehler pro Tag der verschiedenen Prognoseverfahren sowohl beim dienstlich genutzten Elektrofahrzeug als auch beim privat genutzten E-Fahrzeug unter 200 Wh liegen. Die Mittelwerte der absoluten Prognosefehler pro Stunde sind kleiner als 159 Wh . Bei einem Vergleich der absoluten Fehler der Tagesprognose mit jenen der Stundenprognose erscheinen die Fehler der Stundenprognose sehr hoch. Der Grund dafür liegt darin, dass bei der Stundenprognose nur wenige Werte zur Vorhersage der einzelnen Stunden zur Verfügung stehen, wodurch größere Prognoseabweichungen auftreten.

Bei der Erstellung der Stundenprognose wird festgestellt, dass die Schwierigkeit bei der Prognoseerstellung nicht bei der Vorhersage der Menge der benötigten Energien, sondern bei der Prognose der Ladezeitpunkte liegt. Deshalb wird zum Abschluss der Arbeit die Implementierung eines Reservierungssystems in Verbindung mit dienstlich genutzten Elektrofahrzeugen betrachtet.

Durch die Verwendung eines solchen Reservierungssystems kann eine effiziente Zuordnung von Fahrzeugen zu MitarbeiterInnen erfolgen. Dadurch müssen die Elektrofahrzeuge nicht immer vollständig geladen werden, wodurch das Versorgungsnetz entlastet und in weiterer Folge Kosten gesenkt werden können. Außerdem können die Fahrzeuge hauptsächlich dann geladen werden, wenn genug Strom vorhanden ist. Dies führt wiederum zu einer Kostensenkung.

Literaturverzeichnis

- [1] RAINER SCHLITTGEN, BERND H. J. STREITBERG., *Zeitreihenanalyse*, Verlag: De Gruyter Oldenbourg, Ausgabe 2001, 9., unwesentlich veränderte Auflage, ISBN: 3-486-25725-0.
- [2] NÜBEL, H., *Prognose von Zeitreihen*, Seminararbeit, Abteilung Jülich, Fachhochschule Aachen, Dezember 2010. https://www.matse.itc.rwthachen.de/dienste/public/show_document.php?id=7163
- [3] BRUCE H. ANDREWS, MATTEW D. DEAN, ROBERT SWAIN, CAROLINE COLE., *Building ARIMA and ARIMAX Models for Predicting Long-Term Disability Benefit Application Rates in the Public/Private Sectors*, University of Southern Maine, August 2013. <https://www.soa.org/Files/Research/Projects/research-2013-arima-arimax-ben-appl-rates.pdf>
- [4] HUFENDIEK K., KALTSCHMITT M., *Einsatz künstlicher neuronaler Netze bei der kurzfristigen Lastprognose*, Institut für Energiewirtschaft und Rationelle Energieanwendung, Universität Stuttgart, November 1998. http://elib.uni-stuttgart.de/bitstream/11682/1495/1/374_1.pdf
- [5] EISENBACH D., *Künstliche Neuronale Netze zur Prognose von Zeitreihen*, Diplomarbeit, Institut für Informatik, Westfälische Wilhelms-Universität Münster, März 2005. <http://www.math.uni-muenster.de:8010/Professoren/Lippe/diplomarbeiten/html/eisenbach/Diplomarbeit/Diplomarbeit.pdf>
- [6] OTTO P., SCHUNK T., *Fuzzybasierte Zeitreihenvorhersage*, Fakultät für Informatik und Automatisierung, Technische Universität Ilmenau, Oktober 1999. http://www.rst.e-technik.tu-dortmund.de/cms/Medienpool/Downloads/Veranstaltungen/GMA-Fachausschuss/Publikationen/workshop99/Otto__Schunk.pdf
- [7] STEINBERGER T., *Kurzfristige Prognose des Stromverbrauchs in Vorarlberg auf Stunden und Viertelstundenbasis*, Fachhochschule Vorarlberg, Forschungszentrum für Prozess- und Produkt-Engineering, Dezember 2004. <http://www.fhv.at/media/pdf/forschung/prozess-und-produktengineering/working-papers/working-papers-2004/kurzfristige-prognose>

- [8] BRIEGEL R., FILZEK D., RITTER P., *Stromlastprognose*, Regenerative Modellregion Harz, Mai 2012. http://www.regmodharz.de/fileadmin/user_upload/bilder/Service/Arbeitspakete/AP-Bericht-Stromlastprognose_AP2.4_CUBE.pdf
- [9] RINNE H., *Taschenbuch der Statistik*, Verlag: Deutsch, Harri GmbH, Ausgabe 2008, 4. Auflage. ISBN: 978-3808556825.
- [10] LANGER D., *Analyse des DSM-Potenzials eines Elektrofahrzeugfuhrparks*, Bachelorarbeit, Fakultät für Elektrotechnik und Informationstechnik, Technische Universität Wien, Mai 2015.
- [11] SCHUSTER A., *Batterie- bzw. Wasserstoffspeicher bei elektrischen Fahrzeugen*, Diplomarbeit, Fakultät für Elektrotechnik und Informationstechnik, Technische Universität Wien, September 2008. <http://www.ub.tuwien.ac.at/dipl/2008/AC05038587.pdf>
- [12] MATTHIAS LAUX., *Energiewende! Aber wie? Energiespeicher als intelligente Schlüssel für den deutschen Energiemarkt nach dem EnWG, EEG und StromStG*, Bachelorarbeit 2012, Druck/Herstellung: Bachelor + Master Publishing, Hamburg 2013, ISBN: 978-3-95549-152-9.
- [13] DIETMAR RICHARD GRAEBER., *Handeln mit Strom aus erneuerbaren Energien*, Verlag: Springer Gabler, ISBN: 978-3-658-05941-5.
- [14] KARL-WERNER HANSMANN, *Kurzlehrbuch Prognoseverfahren*, Verlag: Springer Fachmedien Wiesbaden GmbH, ISBN: 978-3-409-13444-6.
- [15] FRANK BEICHELT, *Stochastische Prozesse für Ingenieure*, Verlag: Springer Fachmedien Wiesbaden GmbH, ISBN: 978-3-519-02989-2.
- [16] HANS-OTTO GEORGII, *Stochastik, Einführung in die Wahrscheinlichkeitstheorie und Statistik*, Verlag: De Gruyter Berlin – New York, 3., überarbeitete und erweiterte Auflage, ISBN: 978-3-11-019349-7.

Abkürzungsverzeichnis

ACF	<u>A</u> uto <u>c</u> orrelation <u>F</u> unction
aDSM	aktives <u>D</u> emand <u>S</u> ide <u>M</u> anagement
CSV	<u>C</u> omma <u>S</u> eparated <u>V</u> olume
DSM	<u>D</u> emand <u>S</u> ide <u>M</u> anagement
MSE.....	<u>M</u> ean <u>S</u> quared <u>E</u> rror
PACF.....	<u>P</u> artial <u>A</u> uto <u>c</u> orrelation <u>F</u> unction
ZEBRA.....	<u>Z</u> ero <u>E</u> mission <u>B</u> attery <u>R</u> esearch <u>A</u> ctivity

Abbildungsverzeichnis

Abbildung 3.1: Diskreter Kalman - Filter	24
Abbildung 3.2: Schema eines Feedforward - Netzes mit drei Schichten	25
Abbildung 4.1: Ladeenergien von Fahrzeug 1	31
Abbildung 4.2: Aufsummierte Ladeenergien von Fahrzeug 1, alle Wochentage	31
Abbildung 4.3: Aufsummierte Ladeenergien von Fahrzeug 1, einzelne Wochentage.....	32
Abbildung 4.4: Ladeenergien des Fahrzeugpools.....	33
Abbildung 4.5: Aufsummierte Ladeenergien des Fahrzeugpools, alle Wochentage	34
Abbildung 4.6: Aufsummierte Ladeenergien des Fahrzeugpools, einzelne Wochentage.....	35
Abbildung 4.7: Durchschnittliche Ladeleistungen von Fahrzeug 1	37
Abbildung 4.8: Durchschnittliche Ladeleistungen des Fahrzeugpools.....	38
Abbildung 4.9: Durchschnittliche Ladeleistungen pro Ladevorgang privat genutzer E-Fahrzeuge	40
Abbildung 4.10: Ladebeginne von Fahrzeug 1	41
Abbildung 4.11: Ladebeginne des Fahrzeugpools.....	41
Abbildung 4.12: Anzahl der Tage, an denen die privat genutzten E-Fahrzeuge geladen wurden	43
Abbildung 4.13: Anzahl der Ladestunden der privat genutzten E-Fahrzeuge	43
Abbildung 4.14: Durchschnittliche Ladestunden pro Ladetag der privat genutzten E-Fahrzeuge.....	44
Abbildung 4.15: Naive Prognose mit aktuellem Wert, Fahrzeug 1, Sonntag	48
Abbildung 4.16: Naive Prognose mit aktuellem Wert, Fahrzeugpool, Sonntag	48
Abbildung 4.17: Naive Prognose mit letztem Trend, Fahrzeug 1, Sonntag.....	49
Abbildung 4.18: Naive Prognose mit letztem Trend, Fahrzeugpool, Sonntag.....	49
Abbildung 4.19: Brown Verfahren, Fahrzeug 1, Sonntag	50
Abbildung 4.20: Brown Verfahren, Fahrzeugpool, Sonntag	50
Abbildung 4.21: Holt-Winters Verfahren, Fahrzeug 1, Sonntag	51
Abbildung 4.22: Holt-Winters Verfahren, Fahrzeugpool, Sonntag	51
Abbildung 4.23: ARIMA Verfahren, Fahrzeug 1, Sonntag	52
Abbildung 4.24: ARIMA Verfahren, Fahrzeugpool, Sonntag	52
Abbildung 4.25: Neuronale Netze Verfahren, Fahrzeug 1, Sonntag	53
Abbildung 4.26: Neuronale Netze Verfahren, Fahrzeugpool, Sonntag	53
Abbildung 4.27: Darstellung der Quantile von Fahrzeug 1, Wochentag: Sonntag	57
Abbildung 4.28: Darstellung der Quantile des gesamten Fahrzeugpools, Wochentag: Sonntag	59
Abbildung 4.29: privat genutzte E-Fahrzeuge, MATLAB-Modell.....	64
Abbildung 4.30: privat genutzte E-Fahrzeuge, Modus Auswahl	65
Abbildung 4.31: privat genutzte E-Fahrzeuge, Modus 1, Eingabemaske	65
Abbildung 4.32: privat genutzte E-Fahrzeuge, Modus 1, Fahrzeug 1, Sonntag	67

Abbildung 4.33: privat genutzte E-Fahrzeuge, Modus 1, Fahrzeugpool, Sonntag	67
Abbildung 4.34: privat genutzte E-Fahrzeuge, Modus 2, Eingabemaske	68
Abbildung 4.35: privat genutzte E-Fahrzeuge, Modus 2, Fahrzeug 1	69
Abbildung 4.36: privat genutzte E-Fahrzeuge, Modus 2, Fahrzeugpool	70
Abbildung 5.1: Wahlbox 1, Anzahl der Fahrtantritte	79
Abbildung 5.2: Wallbox 1, Darstellung der maximalen Ladeleistung.....	81
Abbildung 5.3: Wallbox 1, Darstellung der maximalen Ladeleistung im Sommer	82
Abbildung 5.4: Wallbox 1, Anzahl der Ladebeginne	84
Abbildung 5.5: Wallbox 1, Darstellung der bereinigten Werte der Lademengen.....	87
Abbildung 5.6: Wallbox 1, Darstellung der Vollladungen, Fahrzeug war verbunden.....	88
Abbildung 5.7: Wallbox 1, Darstellung der Vollladungen, Fahrzeug war nicht verbunden.....	88
Abbildung 5.8: Wallbox 1, bereinigte Vollladungen, Fahrzeug war verbunden.....	89
Abbildung 5.9: Wallbox 1, bereinigte Vollladungen, Fahrzeug war nicht verbunden.....	90
Abbildung 5.10: Wallbox 1, aufsummierte geladene Energie, Fahrzeug war verbunden.....	91
Abbildung 5.11: Wallbox 1, aufsummierte geladene Energie, Fahrzeug war nicht verbunden.....	91
Abbildung 5.12: Wallbox 1, aufsummierte geladene Energien, Fahrzeug war verbunden.....	92
Abbildung 5.13: Wallbox 1, aufsummierte geladene Energien, Fahrzeug war nicht verbunden.....	93
Abbildung 5.14: Wallbox 1, Ladebeginne, Fahrzeug war verbunden.....	93
Abbildung 5.15: Wallbox 1, Ladebeginne, Fahrzeug war nicht verbunden.....	94
Abbildung 5.16: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war verbunden.....	99
Abbildung 5.17: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war nicht verbunden...	100
Abbildung 5.18: dienstlich genutzte E-Fahrzeuge, MATLAB Modell.....	105
Abbildung 5.19: dienstlich genutzte E-Fahrzeuge, Modus Auswahl.....	105
Abbildung 5.20: dienstlich genutzte E-Fahrzeuge, Modus 1, Eingabemaske.....	106
Abbildung 5.21: dienstlich genutzte E-Fahrzeuge, Modus 1, Daten darstellen	107
Abbildung 5.22: dienstlich genutzte E-Fahrzeuge, Modus 2, Eingabemaske.....	107
Abbildung 5.23: dienstlich genutzte E-Fahrzeuge, Modus 2, 20.10.2014, 06:00 Uhr	108
Abbildung 5.24: dienstlich genutzte E-Fahrzeuge, Modus 2, 20.10.2014, 12:00 Uhr	109
Abbildung 5.25: dienstlich genutzte E-Fahrzeuge, Modus 2, 20.10.2014, 18:00 Uhr	110
Abbildung 5.26: Mögliche Realisierung eines Reservierungssystems	115

Tabellenverzeichnis

Tabelle 4.1: Mittelwerte der relativen Fehlerbeträge der Tagesprognose, Wochentag: Sonntag.....	55
Tabelle 4.2: Mittelwerte der absoluten Fehler pro Tag der Tagesprognose, Wochentag: Sonntag	56
Tabelle 4.3: Quantile von Fahrzeug 1, Wochentag: Sonntag.....	57
Tabelle 4.4: Quantile des gesamten Fahrzeugpools, Wochentag: Sonntag.....	58
Tabelle 4.5: Mittelwerte der relativen Fehlerbeträge der Stundenprognose	61
Tabelle 4.6: Mittelwerte der absoluten Fehler der Stundenprognose pro Stunde	62
Tabelle 4.7: Mittelwerte der absoluten Fehler der Stundenprognose pro Tag	62
Tabelle 5.1: Wallbox 1, Aufbau der Datenbank	76
Tabelle 5.2: Wallbox 1, Plugwertänderung bei Fahrtantritt.....	78
Tabelle 5.3: Wallbox 1: Aufzeichnungsfehler in der Datenbank, einige Tage fehlen	79
Tabelle 5.4: Wallbox 1, Ladestrom in Abhängigkeit der Erzeugungsleistung	80
Tabelle 5.5: Wallbox 1, Aufzeichnungsfehler in der Datenbank, Ladeleistung zu hoch.....	83
Tabelle 5.6: Wallbox 1, Beginn eines Ladevorganges.....	83
Tabelle 5.7: Wallbox 1, Ladevorgang aufgrund der ZEBRA – Batterie.....	85
Tabelle 5.8: Wallbox 1, kurzzeitige Unterbrechung des Ladevorganges.....	86
Tabelle 5.9: Wallbox 1, Mittelwerte der relativen Fehlerbeträge	96
Tabelle 5.10: Wallbox 1, Mittelwerte der relativen Fehlerbeträge der verwendbaren Prognoseverfahren	97
Tabelle 5.11: Wallbox 1, Mittelwerte der absoluten Fehler der Tagesprognose	98
Tabelle 5.12: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war verbunden.....	98
Tabelle 5.13: Wallbox 1, Quantile der relativen Fehlerbeträge, Fahrzeug war nicht verbunden.....	99
Tabelle 5.14: Wallbox 1, Mittelwerte der relativen Fehlerbeträge der Stundenprognose.....	101
Tabelle 5.15: Wallbox 1, Mittelwerte der absoluten Fehler der Stundenprognose pro Stunde.....	103
Tabelle 5.16: Wallbox 1, Mittelwerte der absoluten Fehler der Stundenprognose pro Tag	103

Hiermit erkläre ich, dass die vorliegende Arbeit gemäß dem Code of Conduct – Regeln zur Sicherung guter wissenschaftlicher Praxis (in der aktuellen Fassung des jeweiligen Mitteilungsblattes der TU Wien), insbesondere ohne unzulässige Hilfe Dritter und ohne Benutzung anderer als der angegebenen Hilfsmittel, angefertigt wurde.

Die aus anderen Quellen direkt oder indirekt übernommenen Daten und Konzepte sind unter Angabe der Quelle gekennzeichnet.

Die Arbeit wurde bisher weder im In– noch im Ausland in gleicher oder in ähnlicher Form in anderen Prüfungsverfahren vorgelegt.

Wien, am 18.10.2016

Martin Zinggl