




Diplomarbeit

Eine statistische Betrachtung der Abrufmengen von Sekundär- und Tertiärregelenergie in Österreich



Ausgeführt am Institut für
Stochastik und Wirtschaftsmathematik
der Technischen Universität Wien

unter der Anleitung von
Ao. Univ. Prof. Wolfgang Scherrer

Wien, März 2017

David Lun

Danksagung

Ich möchte mich beim Austrian Institute of Technology für die finanzielle Unterstützung meiner Arbeit und ein angenehmes und stimulierendes Arbeitsumfeld bedanken. In erster Linie möchte ich mich hier bei Tara Esterl für ihre kompetente Betreuung und die aufmunternden Gespräche bedanken. Zudem möchte ich mich bei Fabian Leimgruber für seine Hilfe bei der Datenaufbereitung und Anregungen zu statistischen Verfahren und Etiketten des Programmierens bedanken. Darüber hinaus möchte ich mich bei Dominik Schober und Oliver Woll für Vorschläge und Hilfestellungen zu meiner Arbeit sowie Gespräche über Arbeit in einem wissenschaftlichen Kontext bedanken.

Mein besonderer Dank gilt Ao. Univ. Prof. Scherrer für die ausgezeichnete Betreuung meiner Arbeit. Zahlreiche Konversationen, Anregungen und Erklärungen haben maßgeblich zum Verfassen dieser Arbeit beigetragen und haben es zu einem der lehrreichsten Abschnitte meines bisherigen Lebens gemacht. Außerdem möchte ich mich bei meinen Kommilitoninnen und Kommilitonen bedanken, welche mich durch das Studium begleitet haben.

Zu guter Letzt möchte ich mich bei all meinen Freundinnen und Freunden bedanken, welche mich indirekt beim Verfassen dieser Arbeit unterstützt haben. Insbesondere möchte ich mich bei Kevin Hinterberger, Max Ehlmaier und Martin Märzinger für ihre Freundschaft und die vielen gemeinsamen Erinnerungen bedanken. Mein besonderer Dank gilt Luzia Jorda, welche bei sämtlichen Hoch- und Tiefpunkten an meiner Seite war.

Inhaltsverzeichnis

Danksagung	i
1 Einführung	1
2 Einführung in Regelenergie	3
2.1 Grundlegende Erläuterungen zum Strommarkt und zur Regelenergie in Österreich	3
2.2 State of the Art	6
3 Analyse der Abrufmengen von Regelenergie	9
3.1 Deskriptive Statistiken und empirische Analyse der Daten . .	10
3.2 Abhängigkeit der Regelenergieabrufmengen von Variablen des Strommarkts	21
3.2.1 Variablen mit möglichem Einfluss auf die abgerufene Menge an Regelenergie	21
3.3 Verfahren zur Überprüfung des Einflusses verschiedener Variablen und der Prognose	25
3.3.1 Überprüfung der Abhängigkeiten von anderen Variablen	25
3.3.2 Erstellung und Evaluierung von Intraday-Prognosen .	28
3.4 Das lineare Regressionsmodell	32
3.4.1 Das Modell	32
3.4.2 Einfluss der Variablen im Modell	33
3.4.3 Prognose	34
3.4.4 Evaluation der Modellannahmen	42
3.5 Das Tobit Modell	51
3.5.1 Das Modell	51
3.5.2 Einfluss der Variablen im Modell	52
3.5.3 Prognose	54
3.5.4 Evaluation der Modellannahmen	57
3.6 SARIMA	61
3.6.1 Das Modell	61
3.6.2 Prognose	63
3.6.3 Evaluation der Modellannahmen	65
3.7 Nearest Neighbour Regression	69

3.7.1	Das Modell	70
3.7.2	Einfluss der Variablen im Modell	72
3.7.3	Prognose	74
3.7.4	Evaluation der Modellannahmen	76
3.8	Zusammenfassung und Vergleich der Intraday-Prognosen . . .	77
4	Conclusio	83
A	Abbildungen	87
B	Tabellen und Modelle	92
C	Quellenverzeichnis	99
D	Websites	103

KAPITEL 1

Einführung

Eine wesentliche Eigenschaft von Stromnetzen ist, dass sie keine Elektrizität speichern können. Allerdings variiert der Verbrauch und die Erzeugung ständig und unverzüglich. Um die Funktion eines Netzes zu gewährleisten, muss die eingespeiste Menge der entnommenen entsprechen, weswegen ein ständiger Ausgleich erforderlich ist. Regenergie wird durch den Netzbetreiber beschafft und fungiert als letzte Instanz zur Erhaltung des Gleichgewichts.

In den letzten Jahren gab es Entwicklungen am Strommarkt, welche Effekte auf die Anforderungen an Regenergie hinterlassen haben. Bedenken aufgrund steigender CO_2 -Emissionen, globaler Erwärmung und wandelnder Klimaverhältnisse haben zu einem Ausbau an erneuerbaren und nachhaltigen Energieformen geführt. Insbesondere die Stromerzeugung durch Wind- und Photovoltaikanlagen hat zunehmend an Bedeutung gewonnen. Maßnahmen wie diese sind ohne Zweifel notwendig und vernünftig. Allerdings ist die Einspeisung durch erneuerbare Energieformen mit einer gewissen Volatilität verbunden, welche sich auf den Bedarf nach Regenergie auswirkt.

Des Weiteren hat sich auch das regulatorische Umfeld stark verändert. Österreich stellt eine eigene Regelzone dar, der Übertragungsnetzbetreiber ist Austrian Power Grid [APG]. Diese ist mit einer Vielzahl an weiteren Regelzonen Europas verbunden. Netzbetreiber haben die Aufgabe eine ausgeglichene Strombewirtschaftung ihrer Mitglieder zu garantieren, was ein komplexes Unterfangen darstellt.

Regenergie ist das entsprechende Instrument zur Ausbalancierung von Einspeisung und Verbrauch. Die vorzuhaltende Menge wird in Österreich statisch und wöchentlich bestimmt. Mit Veränderungen im Umfeld tritt auch die Frage nach treibenden Faktoren auf. In dieser Arbeit werden mit Ansätzen der Statistik und der Zeitreihenanalyse mögliche Einflüsse auf Abnahmungen von Regenergie in der Regelzone des Austrian Power Grid un-

tersucht. Außerdem werden Intraday-Prognosen erstellt und evaluiert. Der exakte Bedarf nach Regelenergie ist schwer vorhersagbar. Wäre er das nicht, so ließe sich die entsprechende Menge einfach in die reguläre Planung mit-einbeziehen. Diese Arbeit trägt dazu bei diese Schwierigkeiten besser quantifizierbar zu machen. Sie umfasst folgende Punkte.

1. Zunächst werden Details zu Regelenergie erläutert um das Verständnis des Apparates zu erleichtern. Außerdem werden wissenschaftliche Arbeiten in diesem Kontext vorgestellt.
2. Anschließend werden die Abrufmengen von Regelenergie einer deskriptiven statistischen Betrachtung unterzogen. Hierbei handelt es sich um Zeitreihendaten des Jahres 2015 mit viertelstündlicher Auflösung.
3. Danach werden Faktoren mit möglichem Einfluss auf die Abrufmengen von Regelenergie vorgestellt. Ferner wird dargelegt, wie ihr Einfluss untersucht wird, respektive Prognosen erstellt werden.
4. Hierzu werden in der Folge verschiedene Modellansätze verwendet. Diese umfassen das lineare Regressionsmodell, das Tobit Modell, SARIMA und Nearest Neighbour Regression.
5. Zuletzt werden die Ergebnisse zusammengefasst und die Qualität der erstellten Prognosen verglichen.

Da Regelenergie einen Ausgleich zwischen Stromeinspeisung und -entnahme erzielen soll, liegt die intuitive Vermutung nahe, dass Schwankungen der Erzeuger- beziehungsweise Verbraucherseite wesentliche Einflussfaktoren darstellen.

In dieser Arbeit werden sowohl literarische als auch Quellen aus dem Internet angeführt. Erstere werden mit dem Namen der Autorinnen respektive Autoren und einer entsprechenden Jahreszahl referenziert. Zahlen in runden Klammern beziehen sich auf Websites. Sämtliche statistische Analysen und Modellschätzungen wurden mit der Statistik Software R durchgeführt.

Einführung in Regelenergie

2.1 Grundlegende Erläuterungen zum Strommarkt und zur Regelenergie in Österreich

Die allgemeine Stromversorgung ist ein verwobenes Netz verschiedener Akteure. Angebot und Nachfrage werden durch Erzeuger und Verbraucher bestimmt. Der Austausch von Strom erfolgt durch das Übertragungsnetz, welches sämtliche Teilnehmer verbindet. Eine wesentliche Eigenschaft von Stromnetzen ist, dass Elektrizität darin nicht gespeichert werden kann. Damit Strom für Verbraucher verwertbar ist, sind gewisse Rahmenbedingungen einzuhalten - die Netzfrequenz muss beispielsweise stets 50 Hz betragen. Dies ist nur möglich solange die eingespeiste der entnommenen Menge entspricht. Da die Nachfrage nach Elektrizität ständig und unverzüglich erfolgt, ist die Ausbalancierung von Angebot und Bedarf ein komplexes Unterfangen. Regelenergie gleicht sowohl Überschüsse als auch Mängel im Stromnetz augenblicklich aus um die fortwährende Funktion zu gewährleisten.

In Österreich herrscht bei Stromerzeugung sowie -handel und -vertrieb freier Wettbewerb. Darüber hinaus existiert für diese Bereiche ein sogenanntes Bilanzgruppensystem. Teilnehmende dieser Bereiche müssen zur Abrechnung Mitglied einer Bilanzgruppe sein, vom Großerzeuger bis zum einfachen Haushalt. Dazwischen befindet sich der Bereich für Übertragung und Verteilung von Strom. Dieser ist in Österreich reguliert. Austrian Power Grid ist der Übertragungsnetzbetreiber für einen Großteil Österreichs und hat damit eine Monopolstellung inne. Der zugehörige Bereich wird auch Regelzone APG genannt. Der Übertragungsnetzbetreiber ist verantwortlich für die ordnungsgemäße Zählung von Einspeisung und Verbrauch, die vertrauliche Verwaltung der Daten sowie den ausgeglichenen Betrieb der Regelzone. Regelenergie wird von präqualifizierten Erzeugern bereitgestellt, und vom Übertragungsnetzbetreiber durch ein Auktionsverfahren organisiert.

Die Auflagen für die Teilnahme am Regelenergiemarkt sind strenger als die Anforderungen an „normale Erzeuger“, damit der sichere Betrieb des Stromnetzes gewährleistet wird. Die Wiederherstellung der Strombewirtschaftung nach einem Totalausfall würde immense Anstrengungen erfordern.

Man unterscheidet zwischen positiver und negativer Regelenergie. Positive Regelenergie ist zusätzlicher Strom der dem Netz zugeführt wird, falls die Nachfrage den Verbrauch übersteigt, was sich durch einen Abfall der Netzfrequenz bemerkbar macht. Negative Regelenergie wird im gegenteiligen Fall eingesetzt. Hierfür werden entweder zusätzliche Verbrauchsanlagen aktiviert oder die Einspeisung zurückgeschraubt. Ferner wird Regelenergie aus technischen und wirtschaftlichen Gründen in drei Kategorien geteilt. Die Aktivierung von Primärreserven ist die schnellste Art eines möglichen Ausgleichs zwischen Stromerzeugung und -verbrauch. Sie erfolgt dezentral, automatisch und in Abhängigkeit der Netzfrequenz. Primärregelenergie gleicht permanent Schwankungen aus, von dementsprechender Bedeutung ist ihre ständige Verfügbarkeit. Die maximale Aktivierung muss spätestens 30 Sekunden nach einem Störfall verfügbar sein. Zu diesem Zeitpunkt wird bei einem anhaltenden Ungleichgewicht parallel zur Primärregelung die Sekundärregelung aktiviert um diese schrittweise abzulösen und damit ihre ursprüngliche Funktion wieder zu ermöglichen. Sollte die Ausbalancierung des Netzes länger als 15 Minuten andauern, wird die Sekundärregelung durch die Tertiärregelung unterstützt und inkrementell substituiert, um dieser wiederum die Unterstützung der Primärregelung in einem Bedarfsfall zu ermöglichen. Der Ablauf wird schematisch in Abbildung 2.1 dargestellt.




Abbildung 2.1: Schematische Darstellung von Regelenergieabrufen (E-Control: 2013), (12)

In der Grafik 2.1 wird auf der Ordinate ein Leistungsabfall dargestellt, welcher vorerst durch Primärreserven ausgeglichen wird. Diese werden anschließend schrittweise durch die übrigen Regelenenergiearten substituiert. Sollte es sich bei dem Leistungsabfall um eine andauernde Gegebenheit wie einen Kraftwerksausfall handeln, so ist dieser spätestens nach einer Stunde in die reguläre Planung miteinzubeziehen, sodass dadurch kein weiterer Bedarf an Regelenenergie verursacht wird. Allerdings lassen sich nicht alle Ursachen von Leistungsschwankungen so einfach und schematisch abhandeln.

Die ausgeschriebenen Mengen an Regelenenergie unterliegen gewissen Auflagen um den ordnungsgemäßen Betrieb der Regelzone zu gewährleisten. Die Regelzone APG ist verbunden mit anderen Regelzonen Europas. Dies ermöglicht den Stromaustausch zwischen den Zonen. Allerdings hat dies zur Folge, dass sich Ungleichgewichte einer Regelzone auf andere übertragen. Primärregelenenergie wird deshalb durch sämtliche Mitglieder des europäischen Verbundnetzes zur Verfügung gestellt. Die Aktivierung erfolgt automatisch in Abhängigkeit der gemessenen Netzfrequenz und unabhängig von der Quelle. Primärreserven die aus anderen Regelzonen nach Österreich dringen werden von der APG als ungewollter Austausch registriert. Dasselbe gilt für Primärreserven, welche durch österreichische Anbieter zur Verfügung gestellt werden. Dahingegen werden Sekundär- und Tertiärregelenenergie gezielt in Regelzonen mit anhaltenden Ungleichgewichten aktiviert. Unter anderem wurde sich deswegen für die Analyse der Abrufmengen von Sekundär- und Tertiärregelenenergie in dieser Arbeit entschieden (E-Control: 2013), (1, 2, 7).

Situationen welche den Einsatz von Regelenenergie erfordern lassen sich nur schwer prognostizieren. Andernfalls könnte man die betroffenen Momente in die reguläre Planung miteinkalkulieren. Des Weiteren liefert der steigende Anteil an erneuerbaren Energiequellen Diskussionsstoff. Ein plötzlicher Abfall bei der Einspeisung von Strom durch Windenergie muss klarerweise durch andere Erzeugungsquellen kompensiert werden. Allerdings ist beispielsweise in Deutschland der Bedarf an Regelenenergie in Zeiten wachsender Einspeisung durch erneuerbare Energiequellen nicht proportional gestiegen (Hirth und Ziegenhagen: 2013, Kippelt et al. : 2013). Somit bleibt die Frage nach den wichtigsten Treibern beim Bedarf nach Regelleistung. In dieser Arbeit soll die Abhängigkeit der Abrufmengen von Sekundär- und Tertiärregelenenergie von möglichen Einflussfaktoren untersucht und auf verschiedene Arten modelliert werden. Ferner werden Intraday-Prognosen der Abufmengen erstellt und evaluiert.

2.2 State of the Art

In diesem Abschnitt sollen wissenschaftliche Arbeiten vorgestellt werden, welche sich in den letzten Jahren ebenfalls mit der Modellierung von Regelenenergie beschäftigt haben.

Die Dimensionierung der vorzuhaltenden Regelleistung erfolgt im deutschen Sprachraum durch statische Verfahren. Dies bedeutet, dass für einen bestimmten Zeitraum ein gleich bleibender Wert an Regelenenergie vorzuhalten ist. Bei Primärreserven erfolgt die Dimensionierung in Zentraleuropa deterministisch und wird durch ein Referenzereignis - genau genommen durch die fehlenden Kapazitäten bei bestimmten Kraftwerksausfällen - festgelegt. Genaue Vorgaben werden beispielsweise in (10) beschrieben. Die Grundlage für die probabilistische Dimensionierung des Sekundär- und Tertiärregelbedarfs in Deutschland bildet das Graf-Haubrich-Verfahren. Hierbei handelt es sich, vereinfacht gesprochen, um die Approximation der Verteilungen der Kraftwerksausfälle, des Lastrauschens, der Fahrplansprünge und der Prognosefehler der Regelzone und deren anschließende Faltung (9). Die daraus resultierende Verteilung soll anschließend Auskunft über die einzuhaltenden Sicherheitsniveaus liefern. Genaueres ist beispielsweise in Haubrich (2008) nachzulesen. Forscher des Fraunhofer-Instituts in Deutschland haben im Rahmen eines Forschungsprojekts ein dynamisches probabilistisches Verfahren zur Dimensionierung der Sekundär- und Tertiärregelreserven entwickelt und evaluiert. Eine Zusammenfassung hiervon ist in Jost et al. (2015) zu finden. Bei dieser Methode wurde eine Kombination aus neuronalen Netzen und Quantil-Regression verwendet, um Sicherheitsniveaus für die vorzuhaltende Leistung an Regelreserven, jeweils am Tag zuvor, in Abhängigkeit von anderen Variablen des Strommarkts zu bestimmen. Ohsenbrügge (2015) stellt ebenfalls Verfahren zur dynamischen Dimensionierung von Regelleistungsreserven am Vortag vor, wobei hier k -Nearest Neighbour Verfahren und Gradient Boosting Trees zur Anwendung kommen.

In Wenzel (2010) wird die konsolidierte Menge an Sekundär- und Tertiärregelenenergie eines deutschen Übertragungsnetzbetreibers einer Komponentenzerlegung unterzogen. Der Restterm wird anschließend mit Hilfe eines ARIMA-Modells modelliert. In Möller et al. (2011) wird nicht die Menge an Regelenenergie, sondern Ausgleichsenergie betrachtet. Diese ist eng verwandt, jedoch nicht ident zu Abrufmengen an Regelreserven. Eine genaue Erklärung des Unterschieds der beiden Größen ist beispielsweise in E-Control (2013) zu finden. Der Fokus in dieser Arbeit liegt auf der Betrachtung der Residuen im Kontext von SARIMA-Modellen von Zeitreihen, wobei auch Prognosen erstellt und evaluiert werden. In Kurscheid und Düvelmeyer (2009) werden

Abrufe von Tertiärregelung als Poisson-Prozess modelliert. Wolfram et al. (2015) beinhaltet eine Analyse der Korrelation zwischen Regelenergieabrufmengen und möglichen Einflussfaktoren sowie der Autokorrelation.

Zusätzlich ist zu erwähnen, dass Methoden der Ökonometrie und Zeitreihenanalyse in den letzten Jahren auch bei anderen Gelegenheiten auf vielfältige Arten im Kontext der Regelenergiemärkte Anwendung gefunden haben. Des Öfteren wurden hierbei die Preise anstatt der abgerufenen Mengen betrachtet. Beispiele hierfür sind Swzider (2008), Ilieva und Bolkesjø (2014) sowie Nicholson et al. (2010). Neben ökonometrischen Modellen werden auch alternative wahrscheinlichkeitstheoretische Ansätze zur Bestimmung des Regelleistungsbedarfs entwickelt, wie beispielsweise in Brückl (2006) respektive Hirth und Ziegenhagen (2013).

Da die Rahmenbedingungen der Elektrizitätsmärkte und somit auch der Märkte für Regelenergie in den letzten Jahren laufend Änderungen unterzogen wurden, existiert eine Vielzahl an Ansätzen um den Bedarf an Regelleistung zu modellieren beziehungsweise zu prognostizieren. In dieser Arbeit liegt der Fokus nicht auf der Dimensionierung oder der Einhaltung von Sicherheitsniveaus, sondern auf dem Modellieren der Zeitreihe sowie deren Abhängigkeit von weiteren Faktoren. In Betrachtung stehen Abrufmengen von Sekundär- und Tertiärregelenergie in der Regelzone APG des Jahres 2015. Die Modellierung erfolgt hierbei durch ein klassisches lineares Regressionsmodell, ein Tobit Modell sowie SARIMA und k -Nearest Neighbour Regression. Im Kontext dieser Ansätze sollen jeweils exogene Faktoren hervorgehoben werden, welche vergleichsweise hohen Einfluss auf die Abrufmengen an Regelenergie im Rahmen des jeweiligen Modells ausüben sowie Intraday Prognosen erstellt werden. Da der exakte Bedarf an Regelenergie schwer vorhersagbar ist, sollen die Prognosen der Abrufmengen in dieser Arbeit helfen, diese Schwierigkeit etwas besser zu quantifizieren.

KAPITEL 3

Analyse der Abrufmengen von Regelenergie

In diesem Abschnitt werden die Mengendaten der aktivierten Regelenergie in der Regelzone APG des Jahres 2015 analysiert, mit Ausnahme der Primärregelung. Der Grund für die Vernachlässigung der Primärregelung in dieser Analyse ist, dass unter anderem keine Daten für ebendiese durch die APG zur Verfügung gestellt werden. Des Weiteren dient die Primärregelenergie im gesamten europäischen Verbundnetz als erste Instanz zum ausgeglichenen Betrieb des Stromnetzes. Dahingegen werden Sekundär- und Tertiärregelenergie gezielt in den Regelzonen aktiviert, die das Leistungsdefizit beziehungsweise den -überschuss verursacht haben (E-Control: 2013).

Ferner ist zu erwähnen, dass bei der anschließenden Analyse lediglich die konsolidierte Menge an Sekundär- und Tertiärregelenergie betrachtet wird. Dies geschieht aus dem Grund, dass beide Formen der Regelenergie das gleiche Ziel verfolgen - Abweichungen der Regelzone auszugleichen. Auch wenn diese Regelenergie-Märkte unterschiedliche technische Charakteristika haben und getrennt gehandelt werden, besteht die physikalische Notwendigkeit des ständigen Ausgleichs zwischen Stromeinspeisung und -entnahme (2). Die gesamte Leistungsvorhaltung könnte beispielsweise auch nur im Rahmen der Sekundärregelung erfolgen. Ein großer anhaltender Prognosefehler der Einspeisung aus Windenergie kann den Einsatz sämtlicher Stufen der Regelenergievorhaltung verursachen. Dieses Ungleichgewicht verursacht Bedarf an Regelenergie, der Einfluss auf die einzelnen Komponenten ist allerdings nicht immer klar trennbar und hängt vom zeitlichen Verlauf ab. Aufgrund dieser Überlegung wird bei der Analyse der abgerufenen Mengen an Regelenergie die konsolidierte Menge an abgerufenen Sekundär- und abgerufenen Tertiärregelenergie betrachtet. Im Folgenden bezeichnet - wenn nicht anders beschrieben - Regelenergie somit die Summe aus Sekundär- und Tertiärregelenergie.

3.1 Deskriptive Statistiken und empirische Analyse der Daten

Hier wird eine Trennung von positiver und negativer Regelenenergie¹ vorgenommen. In Abbildung 3.1 ist die abgerufene Menge an positiver Regelenenergie für jede Viertelstunde des Jahres 2015 abgebildet. Die Daten hierfür stammen von APG, welche Zeitreihen verschiedener statistischer Daten der Netzregelung in der Regelzone APG mit einer viertelstündlichen Auflösung frei zur Verfügung stellt (3). Man kann aus Abbildung 3.1 ablesen, dass sich viele Aktivierungen positiver Regelenenergie in einer gewissen Bandbreite um Null aufhalten. Ein Wert von Null entspricht keinem Bedarf an positiver Regelenenergie in der jeweiligen Viertelstunde des Jahres 2015. Weder eine Trend- noch eine Saisonkomponente sind eindeutig erkennbar, was unter anderem durch die viertelstündliche Auflösung der Daten und den langen Betrachtungszeitraum von einem Jahr bedingt ist.

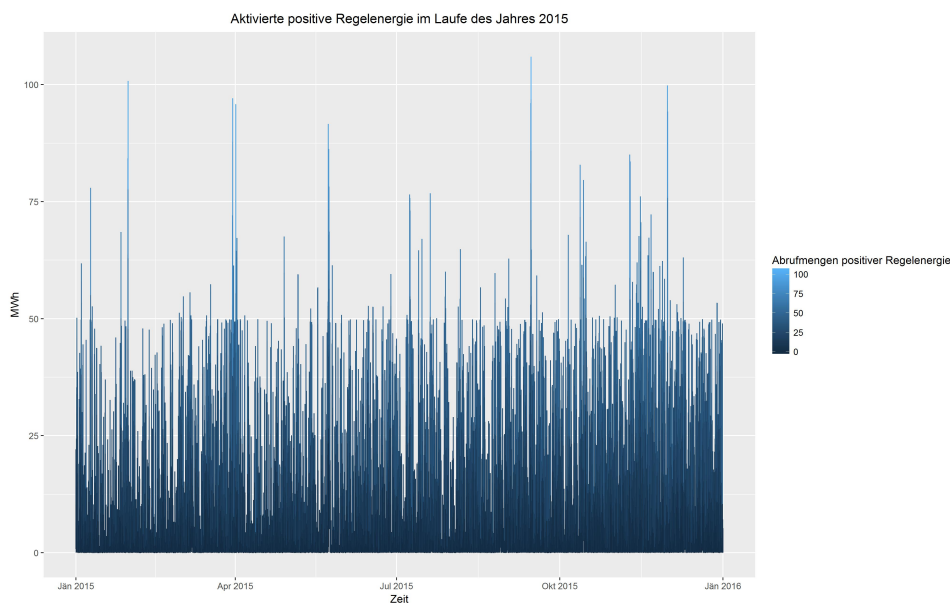


Abbildung 3.1: Abgerufene Menge an positiver Regelenenergie für jede Viertelstunde des Jahres 2015

In Abbildung 3.2 werden ein Histogramm und eine Kerndichteschätzung der Abbrufmengen der positiven Regelenenergie 2015 dargestellt. Null-Aufrufe wer-

¹Regelenenergie bezieht sich hier, wie zuvor erwähnt, auf die Summe aus Sekundär- und Tertiärregelenenergie.

den hier nicht miteinbezogen, da sich auf die tatsächlich abgerufene Menge an positiver Regelenenergie bezogen werden soll. Man sieht, dass die meisten Abrufe von positiver Regelenenergie in einem Bereich nahe bei Null liegen und höhere Mengen mit tendenziell niedrigerer Wahrscheinlichkeit abgerufen werden. Die Balkenbreite des Histogramms beträgt 2,5 MWh.

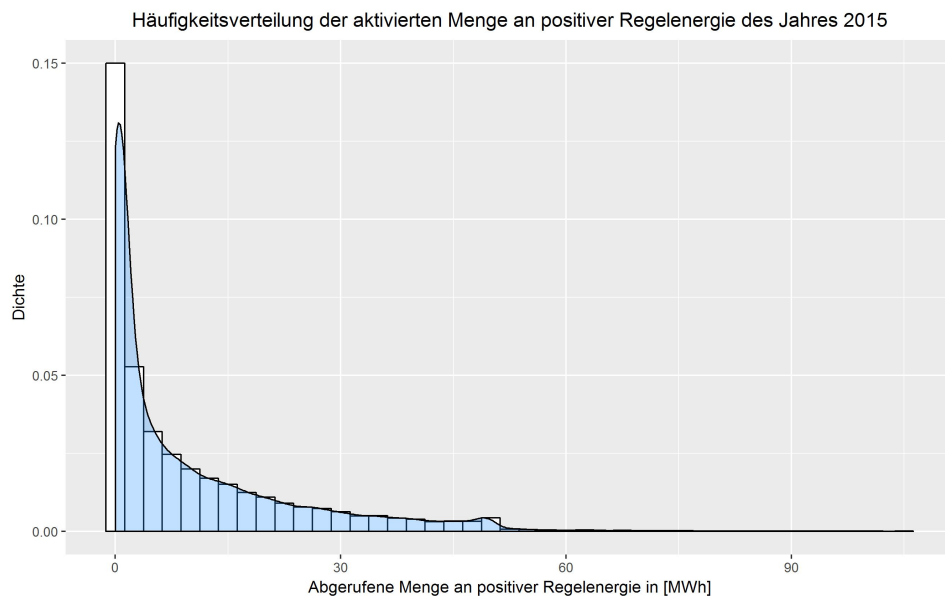


Abbildung 3.2: Häufigkeitsverteilung der aktivierten Menge an positiver Regelenenergie des Jahres 2015

Abbildung A.1 und Abbildung A.2 im Abbildungsappendix entsprechen den eben vorgestellten Plots, jedoch für die Menge an abgerufener negativer Regelenenergie. In den Abbildungen 3.2 und A.2 ist zu erkennen, dass Mengen größer als 50 MWh nur selten abgerufen werden, was dem abrupten Rückgang der Balkenhöhe im Histogramm ab diesem Wert entspricht. 50 MWh entsprechen dem Maximum der abgerufenen Menge an Sekundärregelenenergie jeder Viertelstunde in der Regelzone APG (4). Einträge über dieser Grenze entsprechen also Abrufen von Tertiärregelleistung. Die folgende Tabelle enthält einige weitere Kenngrößen der Verteilungen der Mengen an abgerufener Regelenenergie. Die Werte sind gerundet.

Statistiken		Positive Regelennergie									
Typ	Min	25%-Quant.	Med.	MW	75%-Quant.	Max	Schiefe	Kurtos	SD	MAD	Null-Aufrufe
Positive Regelennergie ohne Null-Aufrufe	0,01	0,31	3,59	9,74	14,41	106,00	1,88	6,89	13,34	5,23	-
Positive Regelennergie	0,00	0,01	0,82	7,33	9,73	106,00	2,27	8,78	12,32	1,216	24,67%
Statistiken		Negative Regelennergie									
Typ	Min	25%-Quant.	Med.	MW	75%-Quant.	Max	Schiefe	Kurtos	SD	MAD	Null-Aufrufe
Negative Regelennergie ohne Null-Aufrufe	0,01	0,63	4,49	11,82	16,84	103,79	1,88	6,57	16,10	6,46	-
Negative Regelennergie	0,00	0,03	1,84	9,36	12,26	103,79	2,20	8,05	15,11	2,73	20,81%

Tabelle 3.1: Deskriptive Statistiken zu den Zeitreihen der Abrufmengen an Regelennergie des Jahres 2015

Man sieht, dass Abrufmengen, sowohl für positive als auch für negative Regelennergie, rechtsschiefe und leptokurtische Verteilungen mit einigen Ausreißern aufweisen. Negative Regelennergie wurde im Jahr 2015 öfter und im Schnitt in höheren Mengen abgerufen. Beide Zeitreihen weisen einen beachtlichen Anteil an Null-Aufrufen vor, welcher die Schätzung einiger Statistiken stark beeinflusst.²

Abbildung 3.3 stellt die Schätzung der Autokorrelationsfunktion [ACF] und der partiellen Autokorrelationsfunktion [PACF] der Menge der abgerufenen positiven Regelennergie im Jahr 2015 dar. Bei diesen Werten werden nun wieder alle Werte der Zeitreihe - also auch Null-Aufrufe - miteinbezogen. Man sieht, dass ACF und PACF auch mit wachsenden Zeitabständen für gewisse Lags statistisch signifikant von Null verschieden sind. Aus dieser Darstellung lässt sich nicht nur eine Abhängigkeit der abgerufenen Regelenenergiermenge zu unmittelbar vorhergehenden Werten ablesen, sondern auch eine periodische Komponente in der ACF erkennen. Dies kann unter anderem durch einen Trend oder eine saisonale Komponente der Zeitreihe begründet sein, wie beispielsweise in Brockwell und Davis (2006: Abschnitt 1.4) erläutert. Da es sich bei den zugrundeliegenden Daten um Zeitreihen mit einer viertelstündlichen Auflösung handelt, entspricht ein Abstand von 96 lags genau einer zeitlichen Differenz von einem Tag. Die ACF besitzt lokale Maxima bei Vielfachen von 96 und die PACF lokale Minima bei Vielfachen von 96 plus einem Lag. Abbildung A.3 im Abbildungsappendix enthält die Darstellung der ACF und der PACF der Menge der abgerufenen negativen Regelennergie und liefert ein sehr ähnliches Bild.

²Min ... Minimum, 25%-Quant. ... 25%-Quantil, Med. ... Median, MW ... Mittelwert, 75%-Quant. ... 75%-Quantil, Max ... Maximum, Kurtos. ... Kurtosis, SD ... Standardabweichung, MAD ... Median Absolute Deviation




Abbildung 3.3: ACF und PACF der Abrufmengen positiver Regelenergie 2015

Zeitreihen werden in der Theorie stochastischer Prozesse als Realisation ebensolcher Prozesse aufgefasst. Im Folgenden werden die Zeitreihen der abgerufenen Mengen an positiver und negativer Regelenergie daher als Trajektorien stochastischer Prozesses aufgefasst. Eine zentrale Eigenschaft von stochastischen Prozessen ist Stationarität. In dieser Arbeit wird zum größten Teil Bezug auf schwache Stationarität von zeitdiskreten stochastischen Prozessen genommen. Die Definitionen der genannten Begriffe sind in der Literatur vielfach erläutert und üblicherweise folgendermaßen definiert (nachzulesen beispielsweise in Hamilton (1994)).

Sei $(\Omega, \mathcal{F}, \mu)$ ein Maßraum, (Ψ, Σ) ein Raum, welcher mit der Sigma-Algebra Σ versehen ist und T eine Indexmenge. In dieser Arbeit handelt es sich bei Ψ um \mathbb{R} beziehungsweise \mathbb{R}^n , Σ entspricht der borelschen Sigma-Algebra hierauf und T bezeichnet \mathbb{Z} und wird üblicherweise als Zeit interpretiert. Es werden also nur zeitdiskrete Prozesse betrachtet. Ein stochastischer Prozess entspricht einer Familie von Zufallsvariablen, welche auf einem gemeinsamen Maßraum $(\Omega, \mathcal{F}, \mu)$ definiert sind, also einer Abbildung der Gestalt

$$X : \Omega \times t \rightarrow \Psi : (\omega, t) \rightarrow X_t(\omega)$$

wobei $X_t : \omega \rightarrow X_t(\omega)$ eine \mathcal{F} - Σ -messbare Abbildung ist. Ψ beinhaltet alle Werte, welche der Prozess annehmen kann. Hält man in der obigen Abbildung ω fest und betrachtet

$$X(\omega, \cdot) : T \rightarrow \Psi : t \mapsto X_t(\omega)$$

So spricht man von Trajektorien, Pfaden oder Realisationen des Prozesses. Wenn in dieser Arbeit von Zeitreihen gesprochen wird so sind derartige Trajektorien gemeint.

Ein stochastischer Prozess X_t ist schwach stationär (beziehungsweise Kovarianzstationär), falls er folgende Eigenschaften erfüllt:

$$\begin{aligned} \mathbb{E}|X_t|^2 < \infty \quad \forall t \in \mathbb{Z}, \quad \mathbb{E}X_t = \mu \quad \forall t \in \mathbb{Z} \\ \gamma_X(t, t-j) = \text{Cov}(X_t, X_{t-j}) = \mathbb{E}(X_t - \mu)(X_{t-j} - \mu) = \\ = \gamma_X(t+s, t-j+s) \quad \forall t, j, s \in \mathbb{Z} \end{aligned}$$

Ein schwach stationärer Prozess ist quadratisch integrierbar. Der Erwartungswert und die Varianz eines derartigen Prozesses hängen nicht von t ab, die Autokovarianzfunktion ebenso wenig, sondern lediglich vom zeitlichen Abstand der Terme. Im Folgenden ist stets diese Definition der schwachen Stationarität gemeint wenn Aussagen zu Stationarität formuliert werden. Wenn Bezug auf strikte Stationarität genommen wird, so wird dies explizit erwähnt.

Auf die Zeitreihen der Regelennergieabrufe wurden nun einige übliche Tests zwecks Überprüfung von Stationarität des zugrunde liegenden Prozesses angewendet, namentlich der Augmented-Dickey-Fuller-Test [ADF] und der Kwiatowski-Philips-Schmidt-Shin-Test [KPSS]. Nähere Erläuterungen zu diesen Tests finden sich in Hamilton (1994) und Kwiatkowski et al. (1992). Genau genommen wird hierbei getestet, ob die Stichprobe möglicherweise durch einen integrierten Prozess beziehungsweise einen Prozess mit einer Einheitswurzel erzeugt wurde. Ein Prozess wird integriert der Ordnung d genannt, falls er nach d -maligem Differenzieren den oben genannten Stationaritätseigenschaften genügt. Niedrigere Grade der Differentiation eines solchen Prozess führen nicht zu einem stationären Prozess. Diese Eigenschaft bei stochastischen Prozessen wird üblicherweise als $I(d)$ notiert.³ Ein in diesem Sinne nicht stationärer Prozess wird auch als differenzenstationär bezeichnet - da d -maliges Differenzieren des Prozesses zum einem stationären Prozess führt. Bei den erwähnten Tests zur Überprüfung des Integrationsgrades besteht ein wesentlicher Unterschied: der ADF-Test geht in seiner Nullhypothese von der Präsenz einer Einheitswurzel aus, wohingegen, der KPSS-Test die Absenz einer Einheitswurzel annimmt.

³ $I(0)$ bedeutet in diesem Zusammenhang stationär.

ADF-Test H_0 : Der datengenerierende Prozess beinhaltet eine Einheitswurzel
 H_A : Der datengenerierende Prozess beinhaltet keine Einheitswurzel

KPSS-Test H_0 : Der datengenerierende Prozess beinhaltet keine Einheitswurzel
 H_A : Der datengenerierende Prozess beinhaltet eine Einheitswurzel

Die Tests wurden mit Hilfe der R-Funktionen *ur.df* und *ur.kpss* aus dem R-Paket *urca* realisiert⁴ (23). In der nachfolgenden Tabelle sind alle durch R berechneten Teststatistiken sowie die dazugehörigen Quantile, anhand derer über die Annahme oder Ablehnung der Nullhypothese entschieden wird, zu verschiedenen Signifikanzniveaus abgebildet.

<i>Test</i>	<i>ADF</i>	<i>ADF</i>	<i>ADF</i>	<i>KPSS</i>	<i>KPSS</i>
<i>Typ</i>	<i>Nichts</i>	<i>Konstante</i>	<i>Trend</i>	<i>Konstante</i>	<i>Trend</i>
1%-Quantil	-2.58	-3.43	-3.96	0.739	0.216
5%-Quantil	-1.95	-2.86	-3.41	0.463	0.146
10%-Quantil	-1.62	-2.57	-3.12	0.347	0.119
Positive Regelenergie	-59.401	-71.895	-72.910	6.010	0.240
Negative Regelenergie	-48.349	-58.536	-59.430	5.658	0.092

Tabelle 3.2: ADF- und KPSS-Statistiken der Abrufmengen an Regelenergie des Jahres 2015

Wie die Tabelle andeutet, gibt es verschiedene Versionen der genannten Tests. Im Wesentlichen beziehen sich die unterschiedlichen Varianten auf den deterministischen Teil, der bei den Tests für die Modellierung des Prozesses einfließt: keine deterministische Komponente, eine Konstante beziehungsweise ein linearer deterministischer Trend. Die Nullhypothese des ADF-Tests wird zu einem Signifikanzniveau von 1% für positive und negative Regelenergie in jeder Variante abgelehnt, was Stationarität im Sinne dieses Tests bedeutet.⁵ Das Ergebnis des KPSS-Tests ist jedoch weniger eindeutig. Die Nullhypothese - welche von der Absenz einer Einheitswurzel ausgeht - wird lediglich für negative Regelenergie und die Version des Tests mit einem linearen deterministischen Trend zu den angeführten Signifikanzniveaus angenommen. Falls beim KPSS-Test keine Lags zur Fehlerterm-Korrektur verwendet werden, wird die Nullhypothese in jedem Fall abgelehnt.

⁴Die Anzahl der Lags für den ADF-Test wurde für jede Variable durch AIC ausgewählt. Beim KPSS-Test wurde $\sqrt[4]{12 \frac{n}{100}}$, gerundet auf die nächste ganze Zahl, als Anzahl der verwendeten Lags gewählt.

⁵Als Anzahl der Lags wird jeweils nur ein Lag durch AIC ausgewählt. Das Ergebnis des Tests bleibt jedoch unverändert auch wenn 100 gelagte Werte verwendet werden.

Das konsolidierte Ergebnis der Tests lässt keine einfache Interpretation zu. Es ist zu bemerken, dass es streng genommen nur eine Art der Stationarität gibt, jedoch unendlich viele Arten die vorgestellten Stationaritätsbedingungen nicht zu erfüllen. Jeder integrierte Prozess ist nicht stationär, aber nicht jeder nicht stationäre Prozess ist integriert. Damit soll ausgedrückt werden, dass die Voraussetzung, dass Erwartungswert, Varianz und ACF eines Prozesses zeitinvariant sind durch eine Vielzahl von Faktoren beeinflusst werden kann. Beispielsweise kann ein Prozess einen deterministischen Trend oder eine deterministische Saisonkomponente enthalten, welche verschiedenste Gestalten annehmen können. Des Weiteren kann aber auch ein außenstehendes Phänomen oder ein Strukturbruch bewirken, dass die Stationarität einer Zeitreihe durch statistische Tests abgelehnt wird.⁶ Integrierte Prozesse sind eine Art nicht stationärer Prozesse. Zeitreihen aus der Realität genügen selten exakt theoretischen Konzepten, weswegen heuristische Überlegungen zu den Eigenschaften des dahinterstehenden Prozesses ebenso wichtig sind wie statistische Tests.

Möller et al. (2011) verwenden in ihrer Arbeit Daten zur Ausgleichsenergie in Deutschland von 2003 bis 2008, wenden darauf einen ADF-Test an und stellen einige heuristische Argumente für die Stationarität der Zeitreihe vor.⁷ Ausgleichsenergie ist eng verknüpft mit Regelenergie, jedoch nicht ident,⁸ allerdings lassen sich einige der erwähnten Argumente auch auf Regelenergie anwenden: Obwohl Regelenergie jedes Ungleichgewicht an Verbrauch und Erzeugung ausgleichen soll, wird sie durch Kraftwerke zur Verfügung gestellt, die selbst Grenzen unterliegen und nicht unbeschränkt und unmittelbar anpassungsfähig sind. Ferner existieren Schranken für die Menge an Schwankungen, die ein Netzbetreiber bewältigen kann. Außerdem ist zu erwähnen, dass Regelenergie durch festgelegte Ober- und Untergrenzen, im Sinne der ausgeschriebenen Mengen, beschränkt ist. Die Menge an abgerufener Regelenergie kann dadurch nicht beliebig groß werden und ist somit in einem Band um Null enthalten. Auch wenn hohe Mengen an Regelenergie abgerufen werden, folgen darauf Perioden, in denen die Zeitreihe wieder kleine Werte beziehungsweise Null annimmt.

⁶Ein Lehrbuch-Beispiel wäre einen stationären Prozess mit Mittelwert ungleich Null mit $(-1)^t$ zu multiplizieren.

⁷Genau genommen, wird in der Arbeit die Zeitreihe nach Abzug zweier deterministischer Komponenten betrachtet. Die dargelegten Argumente bleiben jedoch gültig.

⁸Regelenergie wird angefordert bei der Unausgeglichenheit einer Regelzone. Ausgleichsenergie wird einer Bilanzgruppe verrechnet, wenn ihr Verbrauch nicht mit ihrer Erzeugung übereinstimmt. Allerdings können sich zwei unausgeglichene Bilanzgruppen gegenseitig ausbalancieren, wodurch kein Regelenergiebedarf erzeugt wird, wodurch die Summe an Ausgleichsenergie einer Regelzone stets größer oder gleich der entsprechenden Regelenergie ist. Der Saldo der Ausgleichsenergie über alle Bilanzgruppen ergibt den Regelenergiebedarf einer Regelzone (E-Control: 2013).

Zusammenfassend lässt sich sagen: die Menge an abgerufener Regelenergie ist eine Zeitreihe nichtnegativer beschränkter Werte. Ein linearer deterministischer Trend erscheint wenig sinnvoll für die Modellierung, da die Werte stets zu Null zurückkehren. Ein Differenzieren der Zeitreihe aufgrund der Vermutung einer Einheitswurzel im datengenerierenden Prozess erscheint ebenso fragwürdig. Eine Einheitswurzel würde implizieren, dass die Varianz des Prozesses mit der Zeit divergieren würde, was bei der beobachteten Zeitreihe klarerweise nicht der Fall ist. Mit derselben Argumentation lässt sich die Existenz einer saisonalen Einheitswurzel anzweifeln. Dahingegen scheint die Präsenz einer saisonalen Komponente plausibel. Saisonale Komponenten spielen eine große Rolle bei vielen Variablen des Strommarktes. Die Stromnachfrage hängt beispielsweise von Außentemperaturen ab. Auch die Stromerzeugung variiert saisonal, wie beispielsweise die Verfügbarkeit von Solar- und Windenergie.

Als mögliche saisonale Komponenten wurden jahreszeitliche Muster, wochentagbezogene und tageszeitbezogene Muster identifiziert. In Abbildung 3.4 ist die Verteilung der abgerufenen Menge an positiver Regelenergie für die unterschiedlichen Monate der Jahre 2012 bis 2015 dargestellt (3). Hierin ist zu erkennen, dass sich die Verteilung der Abrufmengen für dasselbe Monat unterschiedlicher Kalenderjahre teilweise stark unterscheiden.

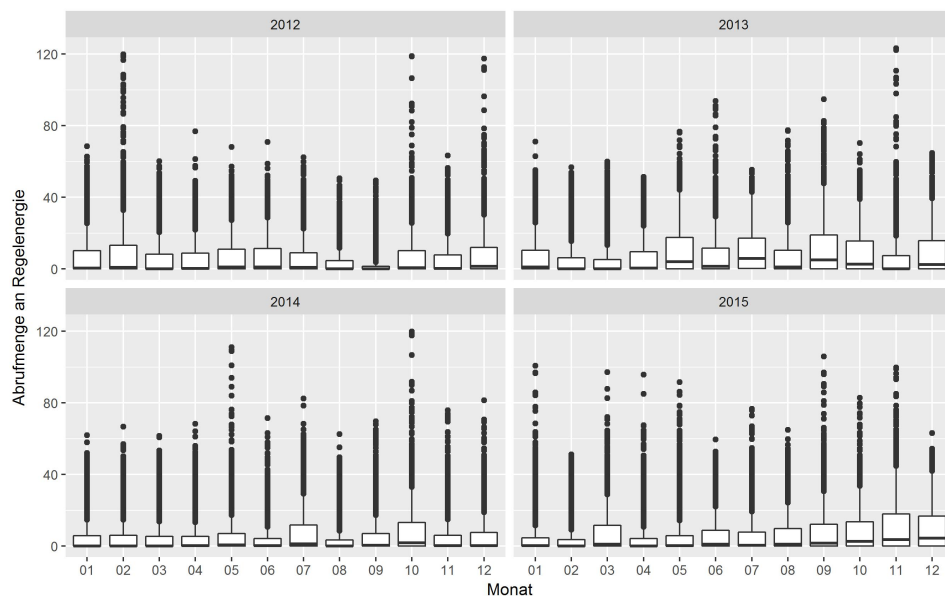


Abbildung 3.4: Boxplots der Abrufmenge positiver Regelenergie für Monate in 2012-2015

Ein klares deterministisches Jahresmuster scheint somit nicht vorzuliegen. Abbildung 3.5 beinhaltet Boxplots der Abrufmengen von positiver Regelenergie an jedem Wochentag des Jahres 2015. Hieraus lässt sich erkennen, dass Abrufmengen positiver Regelenergie sehr homogen über die verschiedenen Wochentage verteilt sind, lediglich bei Ausreißern gibt es klar ersichtliche Unterschiede. Montag und Mittwoch weisen den größten Interquanti- abstand der Boxen auf, allerdings scheint eine Wochentagskomponente nicht der dominierende saisonale Faktor der Abrufmengen zu sein. Abbildung 3.6 stellt die Verteilung der Abrufmengen positiver Regelenergie des Jahres 2015 für verschiedene Tageszeiten dar.

Aus Abbildung 3.6 ist ersichtlich, dass Abrufmengen positiver Regelenergie im Jahr 2015 sehr tageszeitabhängig sind. Allerdings ist hierbei anzumerken, dass nicht nur Unterschiede in der Lage der Daten vorliegen, sondern vor allem hohe Diskrepanzen in der Volatilität verschiedener Tageszeiten ersichtlich sind. Dies lässt sich unter anderem an den Interquanti- abständen, also den Breiten der Boxen ablesen, welche ein Maß für die Streuung der Daten darstellen. Abbildung A.4, A.5 und A.6 im Abbildungsappendix sind das Pendant des eben Gezeigten für die Menge an abgerufener negativer Regelenergie. Die Interpretation der Plots lässt auf Analoges schließen. Allerdings ist zu bemerken, dass in Abbildung A.6 der Interquanti- abstand der Boxen bei negativer Regelenergie auch zu Zeitabschnitten in der Nacht mit erhöhter Frequenz auffällig groß ist, im Gegensatz zu der positiven Regelenergie in Abbildung 3.6.

Abbildung 3.7 stellt den Mittelwert und die Standardabweichung der Abrufmengen positiver Regelenergie zu verschiedenen Tageszeiten dar. Hierbei werden die beiden Statistiken in einem Punktediagramm gegenübergestellt, wobei sie sich proportional zueinander verhalten zu scheinen. Tageszeiten mit erhöhtem Mittelwert besitzen tendenziell eine erhöhte Standardabweichung. Abbildung A.7 im Appendix entspricht dem Pendant für negative Regelenergie und zeichnet ein ähnliches Bild.




Abbildung 3.5: Boxplots der Abrufmenge positiver Regelenergie für Wochentage in 2015




Abbildung 3.6: Boxplots der Abrufmenge positiver Regelenergie für Tageszeiten in 2015




Abbildung 3.7: Mittelwert und Standardabweichung der Abrufmenge positiver Regelernergie zu verschiedenen Tageszeiten im Jahr 2015

Um die erwähnten tageszeitlichen Schwankungen zumindest teilweise abzubilden, werden in der weiteren Analyse saisonale Dummies für die Tageszeit in jedes Modell miteinbezogen. Eine Alternative hierzu wäre, die Zeitreihe durch die tageszeitlichen Mittelwerte zu bereinigen. Allerdings würden hierdurch negative Werte entstehen. Des Weiteren lässt sich durch die Modellierung mit Dummies der tageszeitliche Effekt am Modell ablesen und Interpretationen der Abhängigkeiten der abgerufenen Regelernergie zu anderen Variablen sind klarer, da keine Transformation auf die Zeitreihe angewendet wird. Allerdings ist zu bemerken, dass die Verwendung von Dummies für verschiedene Tageszeiten, beispielsweise in einem linearen Regressionsmodell, der Modellierung eines unterschiedlichen Mittelwertes für jede Tageszeit entspricht. Ein Boxplot der Residuen einer linearen Regression ausschließlich auf die genannten Dummies, wie in Abbildung 3.6, würde lediglich die Zentren der Boxen näher aneinander bringen. Jedoch wäre der Interquartilsabstand - und die damit assoziierte Streuung der Daten - unverändert.

Weiters soll die Menge an abgerufenen Regelernergie im Folgenden nicht nur durch deterministische Faktoren, sondern auch durch exogene Variablen erklärt werden. Im folgenden Abschnitt werden ausgewählte Variablen vorgestellt, deren Einfluss auf die Abrufmengen vorerst intuitiv erklärt und anschließend durch verschiedene Modelle überprüft wird.

3.2 Abhängigkeit der Regelenergieabrufmengen von Variablen des Strommarkts

Die Aktivierung von Sekundär- und Tertiärregelenergie erfolgt nach einem gewissen Zeitraum respektive einer wesentlichen Differenz zwischen Einspeisung und Entnahme von Strom. Diese Abweichungen können verschiedene Ursachen haben, sowohl auf der verbrauchenden als auch der erzeugenden Seite. In der Literatur werden derartige Ungleichgewichte zusätzlich auf unterschiedliche Art und Weise klassifiziert, wie beispielsweise zeitlich oder quellengebunden.

3.2.1 Variablen mit möglichem Einfluss auf die abgerufene Menge an Regelenergie

Verschiedene Variable stehen mit Schwankungen von Stromverbrauch und -erzeugung in Verbindung und können somit auch den Bedarf an Regelenergie beeinflussen (siehe beispielsweise Jost et al. (2015), Kabinger et al. (2014)). Die folgenden Variablen werden für weitere Analysen betrachtet.

- Last – Niveau, Prognose, Prognosefehler
- Einspeisung aus Wind – Niveau, Prognose, Prognosefehler
- Einspeisung aus Photovoltaik – Prognose
- Ungewollter Stromaustausch mit Nachbarnetzen – Import, Export
- Nicht geplante Nicht-Verfügbarkeiten von Erzeugungsanlagen
- Volumen am Intraday-Markt für Strom – Kauf- und Verkaufsvolumen
- Tageszeiten und Feiertage

Es ist zu bemerken, dass einige der angeführten Variablen keineswegs unabhängig voneinander sind - beispielsweise beeinflusst Wetter die Einspeisung aus Wind und Photovoltaik, kann aber auch einen Effekt auf die Gesamtlast haben. Außerdem können Effekte der Variablen oft nur überlagert wahrgenommen werden können. Ein Beispiel wäre ein Überschätzen der Last und eine gleichzeitig zu hoch prognostizierte Einspeisung aus Windenergie, wodurch ein Ausgleich der Stromentnahme und -erzeugung erzielt werden kann. Allerdings können ebendiese Effekte in anderen Situationen sehr wohl die Ursache eines erhöhten Bedarfs an Regelenergie darstellen.

Last

Die Last bezeichnet den Gesamtverbrauch an Strom. Prognosefehler der Last erfordern eine erhöhte beziehungsweise eine verminderte Stromeinspeisung um ein ausgeglichenes Netz zu betreiben. Bei einem steilen Anstieg oder Abfall der Last kann es zu Anpassungsschwierigkeiten der Erzeugerseite kommen, wodurch ebenfalls ein Bedarf an Regelenergie entstehen kann. Hierzu ist noch zu bemerken, dass auch das Design des Strommarkts, im speziellen die diskreten Abrechnungsintervalle der Bilanzgruppen beziehungsweise das Handeln von Stundenprodukten am Strommarkt, zu sprunghaften Abweichungen der Last führen können. Auch wenn Bilanzgruppen den Bedarf an Strom in einem Zeitintervall korrekt prognostizieren, werden innerhalb dieses Intervalls von ihnen oft keine Anpassungen vorgenommen, was zu kurzfristigen Leistungsüberschüssen und -defiziten führen kann (CONSENTEC: 2007).

Wind und Photovoltaik

Die Einspeisung von Energie durch Wind und Photovoltaik ist eine wichtige, emissionsfreie und zukunftsorientierte Quelle von Energie. Allerdings lässt sie sich nur bedingt steuern und ist zu einem gewissen Maße den Gesetzen der Natur ausgeliefert, daher der mögliche Einfluss von Prognosefehlern dieser Energieformen auf den Regelleistungsbedarf. Hierzu ist zu bemerken, dass Zeiten mit sehr hoher und sehr niedriger Einspeisung durch Wind und Photovoltaik üblicherweise besser prognostiziert werden können, als Zeiten mit mittlerer Einspeisung (Jost et al. : 2015). Es ist zu erwähnen, dass für die Einspeisung aus Photovoltaik in Österreich durch die angeführte Datenquelle lediglich prognostizierte Werte zur Verfügung stehen.

Ungewollter Stromaustausch mit Nachbarnetzen

Da die Regelzone APG Teil des Verbands europäischer Übertragungsnetzbetreiber ist, kommt es gelegentlich zu ungewollten Stromimporten und -exporten zwischen den Regelzonen (5, 7). Hierzu gibt es die folgende unmittelbare Interpretationsmöglichkeit: eine hohe Menge an ungewolltem Stromimport kann einen Bedarf an negativer Regelleistung nach sich ziehen, da womöglich zu viel Strom im Netz ist. Allerdings wird zum ungewollten Austausch auch die Primärregelenergie gezählt, welche aus anderen Ländern in die Regelzone APG dringt, beziehungsweise umgekehrt (2). Der Zusammenhang zwischen dem Bedarf nach Regelenergie und ungewolltem Stromaustausch ist somit nicht völlig eindeutig.

Nicht geplante Nicht-Verfügbarkeiten von Erzeugungsanlagen

Ungeplante Kraftwerksausfälle verursachen kurzfristigen Bedarf an Regelenergie, da das dadurch entstehende Defizit in der Stromerzeugung nicht antizipiert wurde. Allerdings werden derartige Ausfälle binnen kurzer Zeit in die Planung miteinbezogen, wodurch nur ein kurzfristiger Bedarf nach Regelenergie entsteht.

Volumen am Intraday-Markt für Strom

Produkte des Intraday-Strommarktes ermöglichen es, den Bilanzgruppenverantwortlichen schneller auf nicht antizipierte Änderungen zu reagieren. Ein hohes Volumen am Intraday-Markt kann es den Bilanzgruppen ermöglichen, flexibler und dynamischer zu planen und somit Prognosefehlern entgegenzusteuern, beziehungsweise den Bedarf an Regelenergie zu senken (Kabinger et al. : 2014).

Tageszeiten und Feiertage

Sowohl die Stromerzeugung als auch der -verbrauch sind abhängig von der Tageszeit und dem Wochentag. Beispielsweise schläft ein großer Anteil der Bevölkerung nachts, wodurch sich in dieser Zeit eine andere Last ergibt als tagsüber. Auf der Erzeugerseite wird nachts durch Photovoltaikanlagen kein Strom eingespeist. Allgemein hängt eine Vielzahl von Prozessen von der Tageszeit ab, was einen indirekten Einfluss auf den Bedarf an Regelenergie verursacht. Des Weiteren gibt es signifikante Unterschiede zwischen der Last an normalen Arbeitstagen und an Wochenenden (6). Feiertage können ebenso derartige Abweichungen mit sich bringen (Jost et al. : 2015). Ferner wurde in Abschnitt 3.1 bereits das tageszeitliche Muster von Regelenergieabrufen untersucht und eine sichtbare Abhängigkeit der Regelenergieabrufe von der Tageszeit festgestellt. Die Abhängigkeit der Abrufmenge von verschiedenen Wochentagen wurde ebenfalls bereits betrachtet, jedoch als nebensächlich eingestuft.

Datengrundlage

Die Datenquelle für die Menge an aufgerufener Sekundär- und Tertiärregelenergie bilden die „Balancing Statistics“ der APG (3). Diese beinhalten auch Daten zum ungewollten Stromaustausch mit Nachbarnetzen. Last, die Einspeisung aus Wind und Photovoltaik und die entsprechenden Prognosen wurden der ENTSO-E transparency platform entnommen (8). Anhand dieser Zahlen wurden dazugehörige Prognosefehler berechnet. Für ungeplante Nicht-Verfügbarkeiten von Erzeugungsanlagen wurden ebenfalls Daten der ENTSO-E transparency platform verwendet. Bei einem nicht-geplanten Aus-

fall einer Erzeugungsanlage wurde die dadurch verloren gegangene Kapazität dieser Anlage für die nächste Stunde in einer Zeitreihe zusammengefasst. Die Quelle für das Volumen am Intraday-Markt für Strom ist die Strombörse EPEX Spot (11). Hierbei wurde das Kauf- und Verkaufsvolumen der Produkte ausgewählt, die zur jeweiligen Viertelstunde zur Verfügung standen - Werte für Stundenprodukte wurden ignoriert.

Abschließend ist noch zu bemerken, dass es sich bei allen Daten um Zeitreihen aus dem Jahr 2015 mit viertelstündlicher Auflösung handelt und bei der weiteren Analyse sowohl kontemporäre als auch gelaggte Werte der genannten Variablen verwendet werden, um deren Einfluss auf die Menge an abgerufener Regelenergie zu erklären.

Kommentar zu vernachlässigten Variablen

Bei einigen Modellen, welche in den kommenden Abschnitten für die weitere Analyse verwendet werden, handelt es sich um Regressionsmodelle, welche lineare Unabhängigkeit in der Datenmatrix der unabhängigen Variablen für eine sinnvolle Schätzung erfordern.⁹ Aus diesem Grund wurden hier einige Variablen nicht angeführt, die in anderen Arbeiten für die Analyse der Regelenergiemenge verwendet wurden, wie beispielsweise Residuallast und Gradienten in Jost et al. (2015). Residuallast ergibt sich aus der Last abzüglich der Einspeisung aus Wind und Photovoltaik und stellt somit eine Linearkombination bereits verwendeter Variablen dar. Mit Gradienten verschiedener Variablen sind, in diesem Kontext, deren Werte in ersten Differenzen gemeint, welche Entwicklungen der Variablen in bestimmte Richtungen beschreiben und somit zusätzlichen Erklärungsgehalt liefern können. Allerdings werden in der weiteren Analyse auch gelaggte Werte der angeführten Variablen verwendet, wodurch sich Gradienten hieraus linear kombinieren lassen würden und deswegen ausgeschlossen werden. Ferner wurden noch aggregierte Füllmengen von Speicherpegelständen in Österreich, sowie Daten zur Temperatur, Windgeschwindigkeit und solaren Einstrahlung als mögliche Kandidaten für die Analyse in Betracht gezogen. Allerdings konnten keine Datenquellen identifiziert werden, welche die relevanten Daten mit einer zufriedenstellenden Auflösung zur freien Verfügung gestellt hätten.

⁹Die Annahme der linearen Unabhängigkeit der Spalten der Matrix der Regressoren ist eine Standard-Annahme im Kontext von Regressionsmodellen, nachzulesen zum Beispiel in Hamilton (1994), Hayashi (2000).

3.3 Verfahren zur Überprüfung des Einflusses verschiedener Variablen und der Prognose

In diesem Abschnitt soll erklärt werden, wie die Abhängigkeit der Regelenergieabrufmengen von verschiedenen Variablen überprüft wird. Außerdem soll das Verfahren dargelegt werden, mit welchem die Intraday-Prognosen erstellt und evaluiert wurden.

3.3.1 Überprüfung der Abhängigkeiten von anderen Variablen

Zur Evaluierung des Einflusses der Variablen werden verschiedene statistische Modelle geschätzt, welche die Abrufmengen von Regelenergie als Funktion der im vorausgehenden Abschnitt vorgestellten Variablen darstellen. Dabei werden jeweils verschiedene Spezifikationen desselben Modells geschätzt und anhand eines Maßes für die Güte des Modells evaluiert. Durch den Vergleich der Evaluationskriterien soll herausgearbeitet werden, welche Variablen, im jeweiligen Modell, den höchsten Erklärungsbeitrag in Bezug auf die abgerufene Menge an Regelenergie liefern.

Im Kontext des linearen Regressionsmodells bedeutet dies beispielsweise: für jede Variable, deren Einfluss überprüft werden soll, werden zwei Modellspezifikationen geschätzt: Einmal wird die Menge an abgerufener Regelenergie lediglich auf die betroffene Variable regressiert - ein anderes Mal werden sämtliche übrigen Variablen als Regressoren verwendet. Die Idee in diesem Zusammenhang ist folgende: Führt das Ausschließen einer Variablen zu einem vergleichsweise schlechten Evaluationskriterium, so bedeutet dies, dass das Berücksichtigen dieser Variablen, im Kontext des linearen Regressionsmodells, zu einer höheren Erklärungsgüte der Abrufmengen von Regelenergie führt. Respektive: Liefert ein Modell, welches lediglich einen Regressor enthält vergleichsweise bessere Ergebnisse für eine bestimmte Variable, so kann argumentiert werden, dass diese Variable, bei den vorhandenen Daten, einen vergleichsweise hohen Einfluss auf die abgerufene Menge an Regelenergie, im Sinne des verwendeten Modells, ausübt.

Die Regressoren umfassen in jeder Modellspezifikation auch immer gelaggte Werte der entsprechenden Variablen und saisonale Dummies für deterministische Faktoren wie Tageszeit und Feiertage.¹⁰ Grund hierfür ist, dass Sekundär- und Tertiärregelenergie für den ausgeglichenen Betrieb des Stromnetzes verantwortlich sind, jedoch bei Schocks erst verzögert abgerufen werden. Sollte die Primärregelenergie nicht ausreichen um eine Unausgeglichen-

¹⁰Lediglich für deterministische Dummies werden keine gelaggte Werte verwendet.

heit zu beseitigen, werden sukzessive die anderen Regelenergiearten hinzugeschaltet. Dadurch kann beispielsweise eine schlechte Prognose der Einspeisung von Windenergie jetzt mit dem Aufruf von Sekundär- beziehungsweise Tertiärregelenergie einige Zeit später zusammenhängen.

Die Schätzung jeder Modellspezifikation basiert jeweils auf Daten von elf Monaten des Jahres 2015. Anschließend wird das Modell auf die Daten des im Schätzprozess nicht verwendeten Monats angewendet. Aus den daraus resultierenden Residuen lassen sich verschiedene Fehlermaße wie der Root Mean Squared Error [RMSE] oder der Mean Absolute Error [MAE] berechnen, welche Evaluationskriterien der jeweiligen Modelle darstellen. Dies entspricht einem Kreuzvalidierungsverfahren, welches unter anderem oft zur Prüfung der Vorhersagegenauigkeit eines statistischen Modells verwendet wird (Hyndman und Athanasopoulos: 2014). Bei dem vorgestellten Ansatz wird dies erweitert, indem ein Kreuzvalidierungsverfahren für verschiedene Varianten eines Modells durchgeführt wird, wodurch Variablen, welche verhältnismäßig mehr zum Ergebnis beitragen, hervorgehoben werden.

Die Anzahl der verwendeten Lags in sämtlichen Modellen wird vor der Schätzung global bestimmt. Es wird ein Modell über den gesamten Datensatz mit sämtlichen Variablen und deren gelaggtten Werten geschätzt, wobei über die Anzahl der verwendeten Lags gemeinsam variiert wird.¹¹ Anschließend wurde die Lag-Anzahl des Modells mit dem kleinsten AIC für das weitere Verfahren verwendet.

Abbildung 3.8 stellt die Ergebnisse des Verfahrens für das lineare Regressionsmodell und positive Regelenergie dar. Im Kästchen, welches als `wind_fc_error` bezeichnet wird, sind für jeden Monat zwei RMSE-Werte aufgetragen. Der dunkle Punkt bezieht sich auf den RMSE des linearen Regressionsmodells, dessen Regressoren alle bisher erwähnten relevanten Variablen mit Ausnahme des Prognosefehlers der Einspeisung aus Wind umfassen.¹² Der helle Punkt bezieht sich auf den RMSE-Wert des Modells, bei dem lediglich auf den Windprognosefehler regressiert wird. Die RMSE-Werte ergeben sich hier durch das Schätzen der Modelle mit den Daten für elf Monate und dem Evaluieren der Modelle im Monat an der jeweiligen Stelle der Werte.¹³

¹¹Es werden nur Modelle geschätzt, in denen die Anzahl der Lags für alle Variablen gleich ist. Würde man auch über die verwendeten Lags jeder einzelnen Variable variieren, so würde ein Modell ausgewählt werden welches gewissen Variablen a priori mehr Einfluss zurechnet.

¹²Natürlich sind mit Variablen wiederum auch deren gelaggte Werte gemeint.

¹³Die Schätzung erfolgt hier durch die Ordinary-Least-Squares-Methode. Der Datenpunkt zu Januar entspricht also dem Wert, welchen man erhält, wenn das Modell mit den Daten von Februar bis Dezember 2015 geschätzt und im Januar evaluiert wird.

3.3. VERFAHREN ZUR ÜBERPRÜFUNG DES EINFLUSSES VERSCHIEDENER VARIABLEN UND DER PROGNOSE




Abbildung 3.8: RMSE-Vergleich gesamt: Lineares Regressionsmodell – abgerufene positive Regelenergie

In diesem Plot lassen sich also auch Unterschiede in der Erklärungsgüte der einzelnen Variablen für unterschiedliche Monate herauslesen. Rechts in jedem Kästchen sind die über die Monate gemittelten RMSE-Werte der Variablen aufgetragen, welche sozusagen eine Zusammenfassung der Erklärungsgüte der einzelnen Variablen für dieses Modell, basierend auf dem gesamten Datensatz, darstellen. Dies lässt sich auch in einem Plot wie in Abbildung 3.9 zusammenfassen, wobei hier ebenfalls MAE-Werte dargestellt werden. Dabei lässt sich schneller erkennen, welche Variablen, im Sinne der vorgestellten Methode und des verwendeten Modells, im Schnitt über die Monate des Jahres 2015, relativ gesehen am meisten Erklärungsgüte im Hinblick auf die abgerufenen Mengen an Regelenergie beisteuern.

Fehlermaße wie RMSE-Werte lassen sich auch für verschiedene Modelle von Punktschätzern vergleichen. Daher liegt die Wahl eines derartigen Evaluationskriteriums nahe.¹⁴ Im linearen Regressionsmodell würden sich beispielsweise auch das adjustierte Bestimmtheitsmaß R_{adj}^2 sowie Informationskriterien wie AIC und BIC anbieten. Allerdings fußen Informationskriterien wie diese oft auf zusätzlichen Annahmen beziehungsweise sind nicht in allen, hier

¹⁴Es lassen sich auch verschiedene Schätzmethoden derselben Modellspezifikation vergleichen.




Abbildung 3.9: RMSE/MAE-Vergleich gemittelt: Einfluss der Variablen: Lineares Regressionsmodell – abgerufene positive Regelenergie

verwendeten, statistischen Modellen definiert.¹⁵ AIC-Werte für verschiedene statistische Modellklassen zu vergleichen ist problematisch, jedoch sind sie ein häufig genutztes Werkzeug um innerhalb einer Modellklasse über die Auswahl verwendeter Variablen zu entscheiden (Hyndman und Athanassopoulos: 2014). Vor der Anwendung des vorgestellten Verfahrens soll das Erstellen und Evaluieren der Intraday-Prognosen skizziert werden.

3.3.2 Erstellung und Evaluierung von Intraday-Prognosen

Bei der Prognose ist zu beachten: Nicht alle Werte der vorgestellten Variablen sind zu den prognostizierten Zeitpunkten bekannt. Beispielsweise wäre es unzulässig, die Last zu einem bestimmten Zeitpunkt für die Prognose der Regelenergiemenge in ebendiesem Moment zu verwenden.¹⁶ Die folgende

¹⁵AIC und BIC sind nur im Kontext der Maximum-Likelihood-Schätzung definiert (Schwarz: 2011). Im linearen Regressionsmodell wird hierfür üblicherweise die Normalverteilung des Fehlerterms angenommen. R_{adj}^2 existiert im Kontext von Tobit Modellen beispielsweise nicht. Es gibt ein Pendant, R_{pseudo}^2 , welches gelegentlich für Modellvergleiche herangezogen wird, aber anders interpretiert wird.

¹⁶Zwar kann für eine Vier-Schritt-Prognose der Abrufmenge an Regelenergie die Lastprognose zu diesem Zeitpunkt verwendet werden, nicht aber der tatsächliche Wert der Last, da er sich gleichzeitig mit der Abrufmenge an Regelenergie realisiert. In diesem Szenario liegt der letzte bekannte Wert der tatsächlichen Last vier Perioden zurück. Werte danach können nicht verwendet werden.

Tabelle soll eine Übersicht über das a priori-Wissen verschiedener Variablen darstellen. Der maximale Prognosehorizont beläuft sich in dieser Arbeit auf vier Stunden.

Prognose der Last	Bekannt
Prognose der Einspeisung aus Wind	Bekannt
Prognose der Einspeisung aus Photovoltaik	Bekannt
Lastprognosefehler und Lastniveau	Nicht bekannt
Windprognosefehler und Einspeisung aus Wind	Nicht bekannt
Ungewollter Stromimport und -export	Nicht bekannt
Nicht-geplante Nicht-Verfügbarkeiten	Nicht bekannt
Kauf- und Verkaufsvolumen am Intraday-Markt	Nicht bekannt

Tabelle 3.3: Übersicht zu a priori-Wissen von Variablen des Strommarktes bei der Prognose

Bei den verschiedenen Prognosewerten handelt es sich um day-ahead-Prognosen, weswegen sie für die relevanten Vorhersagehorizonte als bekannt angenommen werden können. Neben den oben angeführten Variablen werden auch vergangene Werte der Regelenergieabrufmengen für die Prognose verwendet. Die Motivation für diese Entscheidung ergibt sich unmittelbar aus dem Autokorrelogramm, welches eine hohe Abhängigkeit der Abrufmengen zu ihrer eigenen Vergangenheit aufweist. Außer unmittelbar vergangenen Werten werden auch Abrufmengen zu den Lags 96 und 97 miteinbezogen. Diese Werte entsprechen einem zeitlichen Abstand von einem Tag. Die PACF der Zeitreihe weist eine entsprechende Auffälligkeit bei diesem Zeitabstand auf, wie in Abschnitt 3.1 dargelegt wurde. Des Weiteren werden Dummies für Tageszeiten und Feiertage sowie einseitige Moving Averages der Abrufmengen und der Prognose-Variablen verwendet, um Regelenergie vorherzusagen. Hierbei wird eine Ordnung von 24 verwendet, was den letzten sechs Stunden entspricht.

Klarerweise muss das verwendete statistische Modell für jeden Prognosehorizont neu geschätzt werden, da sich der Zusammenhang zwischen den Variablen mit dem zeitlichen Abstand ändert.¹⁷ Das Modell bezieht sich in diesem Kontext auf die Funktion, welche den Zusammenhang zwischen den Abrufmengen und den angeführten Variablen beschreibt.

¹⁷Kurz gesagt: Die Last zum Zeitpunkt t übt auf die Abrufmenge der Regelenergie zum Zeitpunkt $t + 1$ einen anderen Effekt aus als auf die Abrufmenge zum Zeitpunkt $t + 2$.

$$\begin{aligned} \text{Regelenergie}_{t+h} = f(\text{Regelenergie}_t, \dots, \text{Regelenergie}_{t-p}, \\ \text{Lastprognose}_{t+h}, \dots, \text{Lastprognose}_{t+h-q}, \dots, \\ \text{UngewollterImport}_t, \dots, \text{UngewollterImport}_{t-k}, \\ \dots, \text{Dummy}_{10:15}, \dots) \end{aligned}$$

In einem linearen Regressionsmodell würde man beispielsweise für jeden Prognosehorizont den Koeffizientenvektor β neu schätzen. Bei der Wahl der verwendeten Lags der verschiedenen Variablen für die Prognose wurde wieder auf AIC zurückgegriffen. Dabei wurden in den verschiedenen Modellen gelagte Werte der Prognosevariablen, der Abrufmengen und der a priori nicht bekannten Variablen zugelassen, welche als einflussreich im Kontext des Modells kategorisiert wurden. Da bei der Prognose ein akkurates Ergebnis im Vordergrund steht, wird über die verwendeten Lags jeder Variablen individuell variiert, wobei als Obergrenze für die exogenen Variablen drei gelagte Werte gewählt wurden. Die Anwendung der R-Funktion *ar* des Pakets *stats* (13) auf die Abrufmengen der Regelenergie resultiert in einer Schätzung der AR-Ordnung über 700. Die Anwendung der Funktion auf die Residuen der Regression der Abrufmengen auf die genannten Variablen der Prognose ergibt ebenfalls dreistellige Ordnungsschätzungen. Da bei der Prognose allgemeine Zusammenhänge erfasst werden sollen und eine perfekte Anpassung der Schätzung an den vorhandenen Datensatz hierfür nicht dienlich ist, muss eine sinnvolle Obergrenze für die verwendeten Lags der Abrufmengen festgelegt werden, wobei sich für acht entschieden wurde, was den Werten der zwei letzten bekannten Stunden entspricht.

Es wurde somit für jeden Prognosehorizont eine Modellspezifikation bestimmt, basierend auf dem gesamten Datensatz. Anschließend wurde wieder ein Kreuzvalidierungsverfahren durchgeführt: Die verschiedenen Modelle der jeweiligen h -Schritt-Prognose wurden anhand der Daten von 11 Monaten des Jahres 2015 geschätzt und anschließend auf das verbliebene Monat angewendet. Auf die daraus resultierenden Residuen lassen sich wiederum verschiedene Fehlermaße wie RMSE oder MAE anwenden, wodurch sich die Prognosegüte der Modelle vergleichen lässt. Abbildung 3.10 illustriert dies anhand des linearen Regressionsmodells der abgerufenen Menge an positiver Regelenergie. Die einzelnen Datenpunkte für jeden Monat stehen hierbei für den RMSE der h -Schritt-Prognosen, wobei die Anzahl der Schritte in der Legende angegeben ist.

3.3. VERFAHREN ZUR ÜBERPRÜFUNG DES EINFLUSSES VERSCHIEDENER VARIABLEN UND DER PROGNOSE




Abbildung 3.10: RMSE-Werte der Prognose: Lineares Regressionsmodell der Abrufmengen positiver Regelernergie

Man sieht, dass die Ein-Schritt-Prognose des Prognosemodells einen geringeren RMSE-Wert erzeugt, als die Modelle zur Analyse der Abhängigkeiten, da vergangene Werte der abhängigen Variablen dementsprechend viel Erklärungsgüte beisteuern. Im Folgenden wird das in diesem Abschnitt vorgestellte auf das lineare Regressionsmodell angewendet und die Ergebnisse interpretiert.

3.4 Das lineare Regressionsmodell

In diesem Abschnitt wird das Ausmaß des Einflusses verschiedener Variablen auf die abgerufene Menge an Regelernergie durch ein lineares Regressionsmodell beschrieben. Außerdem wird eine Intraday-Prognose der Abrufmengen vorgestellt und evaluiert. Anschließend werden die Annahmen des Modells evaluiert. Zunächst wird das Modell kurz vorgestellt.

3.4.1 Das Modell

Regressionsmodelle sind ein häufig genutztes Werkzeug zur statistischen Analyse von Daten, werden in vielen unterschiedlichen wissenschaftlichen Disziplinen verwendet und eignen sich insbesondere auch zur Analyse von Zeitreihen - Daten werden hierbei als Realisationen von Zufallsvariablen behandelt. Das Modell versucht eine Variable, welche auch als abhängige Variable, endogene Variable oder Regressand bezeichnet wird, durch eine Funktion anderer Variablen zu erklären. Die erklärenden Variablen in diesem Zusammenhang heißen auch unabhängige Variable oder Regressoren. Im linearen Regressionsmodell wird versucht die abhängige Variable durch eine lineare Funktion der Regressoren zu approximieren. Die angeführten Ausführungen zum linearen Regressionsmodell folgen hier Hayashi (2000).

$$y_t = x_{1,t}\beta_1 + \dots + x_{K,t}\beta_K + \varepsilon_t$$

y_t bezieht sich auf den beobachteten Wert der abgerufenen Menge an Regelernergie zum Zeitpunkt t , wobei t einer Viertelstunde des Jahres 2015 entspricht. $x_{i,t}$ bezieht sich auf in den vorhergehenden Abschnitten vorgestellte Variable. Fasst man diese in einem Zeilenvektor zusammen, so lässt sich die obige lineare Beziehung auch folgendermaßen darstellen.

$$y_t = X_t\beta + \varepsilon_t$$

β ist ein unbekannter Parametervektor, der durch Multiplikation mit den Regressoren die Abrufmenge der Regelernergie zum Zeitpunkt t approximieren soll. Der Unterschied zwischen diesem Näherungswert und dem entsprechenden Wert von y_t entspricht ε_t , dem unbekanntem Fehlerterm der beschriebenen linearen Beziehung. Der lineare Zusammenhang der Variablen wird in vielen Anwendungsfällen allerdings nicht exakt beobachtet sondern lediglich postuliert. Dadurch muss die Beziehung - also der unbekannt Parametervektor β - auf Basis einer Stichprobe geschätzt werden. Hierfür gibt es verschiedene Verfahren, das bekannteste in diesem Zusammenhang ist das Ordinary Least Squares - Schätzverfahren [OLS]. Die Fehler, welche sich aus einem Schätzverfahren ergeben werden Residuen genannt. Das lineare Regressionsmodell wird im folgenden Abschnitt auf die angeführten Daten angewendet um herauszufinden welche Variablen, im Sinne dieses Modells,

einen vergleichsweise hohen Einfluss auf die Menge an abgerufener Regelenergie ausüben.

3.4.2 Einfluss der Variablen im Modell

Wie im Abschnitt 3.3.1 erklärt, wurden nun mehrere lineare Regressionsmodelle über verschiedene Zeiträume geschätzt und evaluiert. Die Ergebnisse für Abrufmengen von positiver Regelenergie wurden bereits im genannten Abschnitt dargestellt. Abbildung 3.11 und 3.12 stellen das jeweilige Pendant der Plots zu den Abrufmengen negativer Regelenergie dar. Hierbei wurden jeweils acht als Obergrenze der verwendeten Lags festgelegt.




Abbildung 3.11: RMSE-Vergleich gesamt: Lineares Regressionsmodell – abgerufene negative Regelenergie

In Abbildung 3.11 lässt sich erkennen, dass große Unterschiede der RMSE-Werte der Modelle für unterschiedliche Monate bestehen. Monate mit hohen RMSE-Werten weisen auch tendenziell einen hohen Interquartilsabstand in Abbildung A.4 auf. Für die Abrufmengen von positiver Regelenergie lässt sich eine ähnliche Interpretation in Abbildung 3.8 und Abbildung 3.4 herauslesen. Abbildung 3.12 stellt über die Monate gemittelte RMSE- und MAE-Werte für die unterschiedlichen Variablen dar. Hierbei lässt sich erkennen, dass der Ausschluss von ungewolltem Stromexport und dem Windprognosefehler, im Schnitt über die Monate, zu einem höheren RMSE respektive

MAE beim linearen Regressionsmodell führt. Modelle, bei welchen lediglich auf diese beiden Variablen, sowie die Einspeisung aus Wind, regressiert wird, schneiden vergleichsweise besser als andere Modellspezifikationen dieser Art ab. Für die Menge an abgerufener positiver Regelenergie trifft eine analoge Interpretation zu, wobei hier der ungewollte Stromimport anstatt des -exports zu den einflussreichen Variablen zählt. Die exakten Werte des Kreuzvalidierungsverfahrens können einer Tabelle im Appendix entnommen werden.

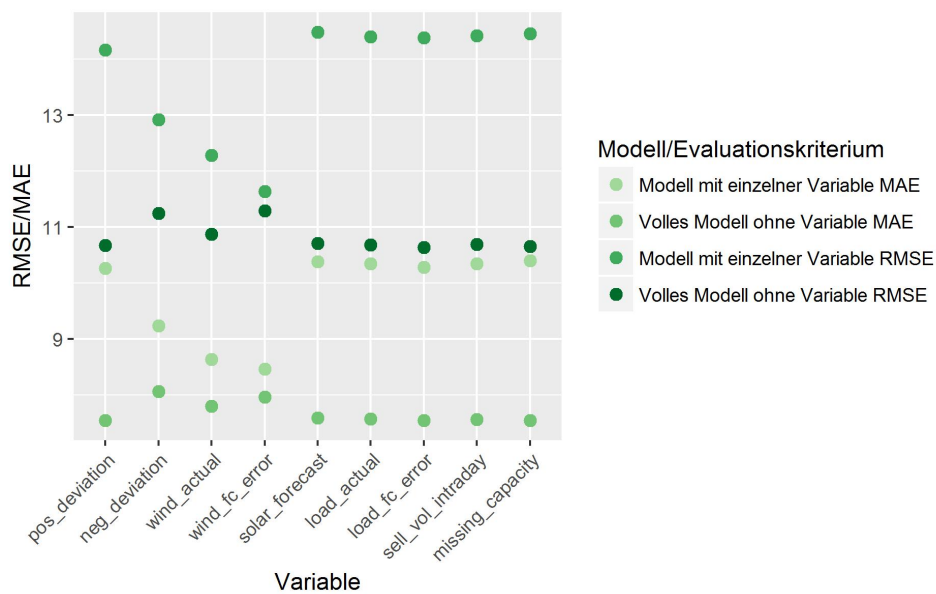


Abbildung 3.12: RMSE/MAE-Vergleich gemittelt: Lineares Regressionsmodell – abgerufene negative Regelenergie

3.4.3 Prognose

Die Prognose der Abrufmengen von Regelenergie wurde, wie im Abschnitt 3.3.2 beschrieben, durchgeführt, wobei schon Ergebnisse für positive Regelenergie in Abbildung 3.10 angeführt wurden. Dabei handelt es sich um die RMSE-Werte der h -Schritt-Prognosen des linearen Regressionsmodells, wobei OLS für die Parameterschätzung verwendet wurde. Abbildung 3.13 stellt nun das entsprechende Pendant für die Abrufmengen negativer Regelenergie dar.

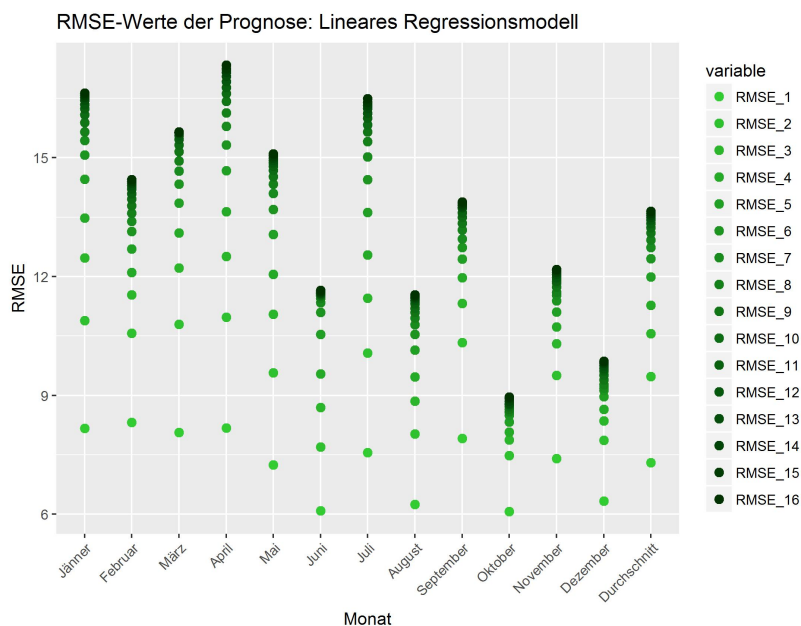


Abbildung 3.13: Prognose: Lineares Regressionsmodell der Abrufmengen negativer Regelenergie

Neben der Schätzung der Regressionsbeziehung der untransformierten Zeitreihen durch OLS werden noch weitere Ansätze zur Erstellung von Intraday-Prognosen verwendet. Einerseits sollen durch die Schätzung mit Weighted Least Squares [WLS] sowie die Schätzung mittels einer Prais-Winsten-Transformation [PW] mögliche Verletzungen der Annahmen an den Fehlerterm berücksichtigt werden. Die Prognose nach einer Yeo-Johnson-Transformation der abhängigen Variablen sowie die Prognose mit sämtlichen Variablen in ersten Differenzen, jeweils mit OLS, werden ebenfalls betrachtet.

Für die Schätzung mit WLS werden drei Spezifikationen evaluiert. Einmal wird angenommen, die Modellresiduen sind heteroskedastisch in Bezug auf die Tageszeiten, jedoch unabhängig von anderen Faktoren. Bei einer weiteren Variante werden die quadrierten Residuen einer OLS-Regression auf die gefitteten Werte der Regression regressiert. Bei der dritten Möglichkeit werden die quadrierten OLS-Residuen einfach auf die ursprünglichen Regressoren regressiert.¹⁸ In allen Fällen erhält man eine Schätzung der Varianz-Kovarianz-Matrix des Fehlerterms, wodurch Gewichte ω_t berechnet werden können.

¹⁸Genau genommen handelt es sich bei diesen Schätzvarianten um eine Feasible Generalized Least Squares-Schätzung, da die Gestalt der Varianz-Kovarianz-Matrix des Fehlerterms nicht bekannt ist, sondern auf einer Annahme basiert und durch eine Stichprobe geschätzt wird.

$$\mathbb{E}(\varepsilon_T \varepsilon_T') = \Omega \sigma^2, \quad \Omega = \text{diag}(\gamma_1, \dots, \gamma_T)$$

$$\gamma_t = \mathbb{E}\varepsilon_t^2 = f(z_t), \quad \hat{\omega}_t = \frac{1}{\sqrt{\gamma_t}}$$

Eine wesentliche Annahme bei der WLS-Schätzung ist, dass die Varianz-Kovarianz-Matrix die Struktur einer Diagonalmatrix besitzt. Die berechneten Gewichte ermöglichen eine WLS-Schätzung, die mit der R-Funktion *lm* aus dem Paket *stats* realisiert wird (13). Die Varianten der Parameterschätzung werden im Folgenden mit WLS I, II respektive III bezeichnet. Diese Art der Schätzung soll Heteroskedastizität, also einer nicht konstanten Varianz, im Fehlerterm entgegenwirken, berücksichtigt allerdings keine Autokorrelation. Hierfür eignet sich beispielsweise eine PW-Transformation. Dabei wird angenommen, dass der Fehlerterm einem AR(1)-Prozess entspricht.¹⁹ Die Variablen der Regressionsgleichung werden folgendermaßen transformiert.

$$\varepsilon_t = \rho \varepsilon_{t-1} + \epsilon_t$$

$$\bar{y}_t = \begin{cases} \sqrt{1 - \rho^2} y_t, & \text{für } t = 1 \\ y_t - \rho y_{t-1}, & \text{für } t > 1 \end{cases}, \quad \bar{X}_t = \begin{cases} \sqrt{1 - \rho^2} X_t, & \text{für } t = 1 \\ X_t - \rho X_{t-1}, & \text{für } t > 1 \end{cases}$$

Treffen die Annahmen des Modells, insbesondere die an den Fehlerterm, zu so handelt es sich bei $\bar{y}_t = \bar{X}_t \beta + \epsilon_t$ um ein „klassisches“ Modell (Scherrer: 2015).

Zeitreihen werden oftmals transformiert, sodass Eigenschaften, wie der Anstieg ihrer Variabilität mit dem Niveau, eingedämmt werden. Dies führt in einigen Fällen zu einfacheren Prognose-Modellen respektive präziseren Prognosen (Hyndman und Athanasopoulos: 2014). Eine bekannte Transformation dieser Art ist die Familie der Box-Cox-Transformationen, allerdings erfordert diese die strikte Positivität sämtlicher Zeitreiheneinträge. Die Yeo-Johnson-Transformation kann als eine Erweiterung hiervon betrachtet werden und ist für nichtnegative Zeitreihen folgendermaßen definiert (Yeo und Johnson: 2000):

$$\psi(\lambda, y) = \begin{cases} \frac{(y+1)^\lambda - 1}{\lambda}, & \text{für } \lambda \neq 0, y \geq 0 \\ \log(y + 1) & \text{für } \lambda = 0, y \geq 0 \end{cases}$$

Wie die Box-Cox-Transformation hängt sie von einem Parameter λ ab, der in Abhängigkeit von den Daten gewählt wird. Für nichtnegative Werte entspricht sie der Box-Cox-Transformation einer Variablen, zu welcher Eins addiert wurde. Die Schätzung von λ basiert auf dem gesamten Datensatz und wird für die gesamte anschließende Kreuzvalidierung verwendet. Dabei wird die transformierte Zeitreihe prognostiziert, anschließend rücktransformiert

¹⁹Für Genaueres zu autoregressiven Prozessen, siehe beispielsweise 3.6.1.

und schließlich die Prognosefehler berechnet. Die Schätzung des Parameters erfolgt mit der R-Funktion *powerTransform* aus dem Paket *car* (15). Hier ist zu erwähnen, dass für positive Regelernergie $\lambda = -0.4$ respektive $\lambda = -0.3$ für negative Regelernergie gewählt wird. Die resultierende transformierte Variable ist nichtnegativ und besitzt eine wesentlich geringere Streuung. Allerdings ist bei der Rücktransformation folgendes zu beachten: Durch die Negativität des Parameters λ ist sie, für reellwertige Inputs, nur bis zu einer gewissen Grenze definiert.²⁰ Des Weiteren divergiert die Funktion bei der Annäherung an diese Grenze. Werden also im Modell der transformierten Daten Werte prognostiziert, welche nahe an oder gar über dieser Grenze liegen, so ergeben sich bei der entsprechenden Rücktransformation unrealistische beziehungsweise gar keine Werte. Deshalb wurden Prognosen welche das globale Maximum der jeweiligen Zeitreihe überschreiten auf ebendieses Maximum gesetzt.

Des Weiteren werden auch die ersten Differenzen sämtlicher Zeitreihen verwendet um Prognosen zu erstellen. Der Grund hierfür sind die Ergebnisse von Einheitswurzeltests, auf die in Abschnitt 3.4.4 näher eingegangen wird. Mit Hilfe der differenzierten Variablen werden Prognosen der ersten Differenzen der Abrufmengen berechnet und anschließend mit dem zum jeweiligen Prognosehorizont letzten bekannten Wert auf die ursprüngliche Skala rücktransformiert und somit Residuen der Prognose berechnet. Außerdem werden bei einer weiteren Modifikation die prognostizierten Werte der gewöhnlichen OLS-Schätzung bei Null zensiert, da des Öfteren durch die beschriebenen Regressionsmodelle negative Werte vorhergesagt werden.

Ferner wurde eine Variante der Prognose realisiert, bei welcher nicht ein einziges Modell, sondern jeweils ein Modell für jede Viertelstunde des Tages geschätzt wird. Sämtliche beschriebene Schätzverfahren werden auch auf diese Spezifikation angewendet, mit Ausnahme von Prais-Winsten und WLS I, da diese in dem beschriebenen Kontext nicht sinnvoll erscheinen.

Die genaue Struktur der Ein-Schritt-Prognose-Modelle, also die Wahl der exogenen Variablen, sind in Abschnitt 3.4.4 angeführt. Die Ergebnisse der verschiedenen Prognosevarianten sind nun in den folgenden Tabellen zusammengefasst, jeweils für positive und negative Abrufmengen. Hierbei wurde aus Gründen der Übersichtlichkeit auf die Werte der Fehlermaße der einzelnen Monate verzichtet und lediglich die Durchschnittswerte der verschiedenen Varianten, über die Monate, aufgetragen. Die Anzahl der verwendeten Lags der Variablen wurde dabei wie in Abschnitt 3.3.1 basierend auf dem gesamten Datensatz ausgewählt.

²⁰Für ein negatives λ und die angeführte Transformation entspricht der reellwertige Definitionsbereich der Rücktransformation $\{x \in \mathbb{R} : x < \frac{1}{|\lambda|}\}$.

KAPITEL 3. ANALYSE DER ABRUFMENGEN VON REGELENERGIE

RMSE		Positive Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	6,97	9,12	9,83	10,21	10,59	10,82	10,96	11,05	11,15	11,22	11,28	11,32	11,37	11,41	11,44	11,47
WLS I	6,98	9,13	9,83	10,21	10,59	10,82	10,96	11,06	11,15	11,23	11,28	11,33	11,37	11,41	11,44	11,47
WLS II	7,05	9,23	9,88	10,23	10,60	10,83	10,96	11,04	11,14	11,21	11,26	11,31	11,35	11,39	11,42	11,45
WLS III	7,04	9,22	9,88	10,24	10,61	10,83	10,96	11,05	11,15	11,22	11,27	11,31	11,36	11,40	11,43	11,46
Prais-Winsten	6,98	12,77	10,59	10,72	11,13	11,20	11,22	11,26	11,37	11,41	11,44	11,47	11,51	11,53	11,57	11,59
Yeo-Johnson	9,84	11,02	11,47	11,79	12,08	12,26	12,40	12,45	12,52	12,58	12,62	12,66	12,70	12,73	12,76	12,78
Differenzen	7,10	9,40	10,20	10,72	11,22	11,56	11,80	11,99	12,17	12,32	12,44	12,52	12,58	12,64	12,70	12,79
Zensiert	6,86	9,02	9,77	10,18	10,56	10,80	10,95	11,05	11,14	11,22	11,27	11,32	11,37	11,40	11,44	11,47
96 Modelle	7,14	9,60	10,49	10,98	11,35	11,60	11,75	11,87	11,93	12,02	12,12	12,13	12,16	12,19	12,25	12,28
96 Modelle WLS II	7,04	9,37	10,19	10,66	10,98	11,23	11,41	11,55	11,67	11,73	11,81	11,85	11,87	11,91	11,94	11,95
96 Modelle WLS III	7,11	9,37	10,22	10,68	11,00	11,28	11,52	11,63	11,72	11,79	11,92	11,94	11,95	11,93	12,00	12,04
96 Modelle Yeo-Johnson	11,31	12,47	12,69	12,86	13,19	13,34	13,39	13,27	13,33	13,34	13,37	13,35	13,34	13,47	13,41	13,36
96 Modelle Differenzen	7,57	10,18	11,24	11,93	12,48	12,89	13,26	13,66	13,93	14,18	14,41	14,64	14,80	14,93	15,09	15,28
96 Modelle zensiert	6,93	9,34	10,23	10,75	11,14	11,40	11,54	11,66	11,74	11,82	11,90	11,94	11,99	12,01	12,04	12,08
MAE		Positive Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	4,78	6,34	6,75	6,93	7,23	7,44	7,55	7,61	7,70	7,77	7,83	7,86	7,91	7,95	7,99	8,01
WLS I	4,75	6,32	6,74	6,93	7,23	7,44	7,56	7,62	7,71	7,78	7,84	7,87	7,92	7,96	7,99	8,02
WLS II	4,65	6,18	6,62	6,84	7,16	7,37	7,50	7,58	7,67	7,74	7,80	7,84	7,89	7,93	7,96	7,99
WLS III	4,64	6,19	6,62	6,84	7,16	7,38	7,51	7,58	7,67	7,75	7,80	7,84	7,89	7,93	7,96	7,99
Prais-Winsten	4,77	9,02	7,30	7,39	7,72	7,78	7,80	7,84	7,93	7,96	7,99	8,01	8,06	8,08	8,11	8,13
Yeo-Johnson	4,86	5,76	6,04	6,20	6,38	6,51	6,59	6,63	6,68	6,71	6,74	6,76	6,79	6,81	6,83	6,84
Differenzen	4,84	6,54	7,00	7,27	7,66	7,94	8,13	8,26	8,41	8,55	8,66	8,75	8,82	8,86	8,93	9,02
Zensiert	4,40	6,00	6,52	6,80	7,12	7,34	7,47	7,56	7,66	7,73	7,79	7,83	7,88	7,92	7,96	7,99
96 Modelle	4,82	6,55	7,13	7,47	7,71	7,89	7,99	8,07	8,14	8,20	8,26	8,31	8,36	8,39	8,42	8,46
96 Modelle WLS II	4,55	6,15	6,70	7,03	7,27	7,46	7,60	7,70	7,79	7,85	7,92	7,95	8,00	8,03	8,05	8,07
96 Modelle WLS III	4,60	6,18	6,71	7,03	7,28	7,48	7,67	7,71	7,81	7,87	7,96	8,00	8,04	8,05	8,09	8,13
96 Modelle Yeo-Johnson	5,27	6,17	6,41	6,56	6,76	6,86	6,91	6,92	6,97	7,00	7,01	7,00	7,01	7,06	7,06	7,05
96 Modelle Differenzen	4,97	6,82	7,50	7,93	8,33	8,63	8,89	9,14	9,36	9,56	9,76	9,97	10,12	10,23	10,38	10,57
96 Modelle zensiert	4,37	6,06	6,69	7,07	7,36	7,57	7,69	7,79	7,87	7,94	8,00	8,06	8,12	8,15	8,17	8,22

Tabelle 3.4: Evaluationskriterien der Prognose mit einem linearen Regressionsmodell für positive Regelenergie

3.4. DAS LINEARE REGRESSIONSMODELL

RMSE		Negative Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	7,30	9,48	10,56	11,28	11,99	12,45	12,73	12,93	13,10	13,24	13,34	13,43	13,50	13,55	13,60	13,65
WLS I	7,30	9,48	10,56	11,28	12,00	12,45	12,73	12,93	13,10	13,24	13,34	13,43	13,50	13,55	13,60	13,65
WLS II	7,37	9,59	10,63	11,32	12,04	12,48	12,75	12,93	13,09	13,22	13,33	13,41	13,48	13,54	13,58	13,63
WLS III	7,37	9,59	10,62	11,32	12,03	12,48	12,75	12,93	13,09	13,23	13,33	13,41	13,49	13,54	13,59	13,64
Prais-Winsten	7,30	12,98	11,90	12,39	13,37	13,37	13,35	13,40	13,53	13,60	13,62	13,69	13,72	13,74	13,76	13,80
Yeo-Johnson	10,56	12,22	12,83	13,31	13,92	14,36	14,55	14,69	14,80	14,91	14,98	15,04	15,09	15,11	15,16	15,22
Differenzen	7,46	9,78	10,90	11,77	12,64	13,24	13,66	13,98	14,29	14,54	14,75	14,93	15,06	15,17	15,29	15,39
Zensiert	7,17	9,37	10,49	11,24	11,95	12,41	12,71	12,91	13,08	13,22	13,33	13,42	13,49	13,54	13,59	13,64
96 Modelle	7,60	10,18	11,50	12,40	13,11	13,56	13,87	14,13	14,28	14,36	14,41	14,55	14,61	14,67	14,71	14,79
96 Modelle WLS II	7,44	9,92	11,13	11,99	12,64	13,10	13,45	13,72	13,89	14,00	14,03	14,12	14,15	14,17	14,23	14,29
96 Modelle WLS III	7,41	9,93	11,16	12,02	12,69	13,15	13,45	13,72	13,91	14,08	14,07	14,19	14,26	14,29	14,31	14,35
96 Modelle Yeo-Johnson	11,63	13,49	14,00	14,50	14,91	15,17	15,40	15,52	15,58	15,71	15,84	15,90	15,94	16,10	16,13	16,16
96 Modelle Differenzen	7,73	10,47	11,84	12,88	13,80	14,54	15,01	15,44	15,81	16,15	16,45	16,75	16,99	17,20	17,43	17,67
96 Modelle zensiert	7,43	9,96	11,27	12,17	12,87	13,31	13,61	13,83	13,97	14,08	14,14	14,27	14,35	14,43	14,48	14,56
MAE		Negative Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	5,07	6,63	7,26	7,70	8,24	8,55	8,75	8,90	9,05	9,18	9,26	9,33	9,39	9,44	9,48	9,53
WLS I	5,06	6,63	7,26	7,70	8,24	8,56	8,76	8,91	9,06	9,19	9,27	9,34	9,40	9,45	9,49	9,53
WLS II	4,98	6,57	7,21	7,68	8,21	8,52	8,73	8,87	9,01	9,14	9,23	9,30	9,36	9,41	9,45	9,49
WLS III	4,96	6,56	7,21	7,67	8,20	8,52	8,72	8,86	9,01	9,13	9,22	9,29	9,36	9,40	9,44	9,49
Prais-Winsten	5,06	9,18	8,32	8,66	9,35	9,35	9,34	9,37	9,48	9,54	9,55	9,60	9,63	9,65	9,66	9,70
Yeo-Johnson	5,43	6,59	7,00	7,32	7,63	7,86	7,98	8,07	8,14	8,21	8,25	8,28	8,31	8,33	8,36	8,39
Differenzen	5,16	6,85	7,52	8,04	8,69	9,09	9,34	9,55	9,77	9,96	10,11	10,26	10,37	10,46	10,54	10,63
Zensiert	4,71	6,31	7,07	7,58	8,12	8,46	8,68	8,85	9,00	9,13	9,21	9,29	9,36	9,41	9,45	9,49
96 Modelle	5,10	6,94	7,83	8,44	8,90	9,21	9,45	9,62	9,75	9,85	9,92	10,02	10,09	10,14	10,19	10,22
96 Modelle WLS II	4,88	6,63	7,45	8,02	8,46	8,77	9,01	9,20	9,33	9,44	9,48	9,54	9,60	9,65	9,69	9,72
96 Modelle WLS III	4,84	6,59	7,41	7,99	8,43	8,74	8,97	9,15	9,30	9,42	9,47	9,55	9,62	9,66	9,68	9,73
96 Modelle Yeo-Johnson	5,77	7,02	7,42	7,78	8,03	8,20	8,35	8,44	8,51	8,59	8,66	8,72	8,74	8,81	8,81	8,83
96 Modelle Differenzen	5,24	7,25	8,21	8,95	9,58	10,09	10,48	10,77	11,08	11,36	11,60	11,84	12,04	12,21	12,39	12,58
96 Modelle zensiert	4,73	6,52	7,43	8,07	8,55	8,87	9,13	9,31	9,44	9,55	9,62	9,72	9,80	9,85	9,90	9,93

Tabelle 3.5: Evaluationskriterien der Prognose mit einem linearen Regressionsmodell für negative Regelenergie

Aus den berechneten Fehlerwerten wird ersichtlich, dass die eben vorgestellten alternativen Schätzmethoden großteils schlechter abschneiden, als die „gewöhnliche“ OLS-Schätzung der untransformierten Zeitreihe, mit der

Zensierung bei Null. Einzig die Schätzung mit WLS II liefert marginal bessere Ergebnisse für gewisse Schrittweiten. Ab einem Prognosehorizont von elf übertrifft diese Methode die OLS-Schätzung im Sinne des RMSE sowohl für positive als auch für negative Regelenergie. Die OLS-Schätzung liefert jedoch für „kleine“ Schrittweiten auch ohne Zensierung bessere Ergebnisse. Dies deutet nicht nur auf Heteroskedastizität in den OLS-Residuen hin, sondern auch auf eine schwankende Varianz der Zeitreihe der Abrufmengen an Regelenergie, die zum Beispiel auch in Abbildung 3.6 beziehungsweise A.6 ersichtlich ist. Auch wenn die Modellierung der genannten Eigenschaft durch WLS II keineswegs optimal ist, scheint die Berücksichtigung dieser Tatsache eine Verbesserung der Prognose für gewisse Schrittweiten zu ermöglichen. Die Prognose der Zeitreihe in Differenzen schneidet schlechter ab als die Prognose der untransformierten Daten, was wiederum gegen einen positiven Integrationsgrad des datengenerierenden Prozesses der Abrufmengen spricht.

Bei der Modellierung anhand 96 separater Regressionsmodelle wird nicht berücksichtigt, dass die Fehlerterme der Modelle korreliert sein könnten. Insgesamt schneidet diese Variante schlechter ab als die gemeinsame Schätzung der Daten. Jedem Modell stehen hier weniger Datenpunkte zur Verfügung, weswegen teils sehr extreme Werte prognostiziert werden, welche die Modellevaluierung verzerren. Um eine Verbesserung der Prognose in diesem Kontext zu ermöglichen sollten mehr Daten herangezogen werden beziehungsweise können die Regressionsmodelle als interdependente Mehrgleichungsmodelle aufgefasst und modelliert werden.

Beim Betrachten der MAE-Werte ist auffällig, dass die Bewertung der Prognosegüte der verschiedenen Modellspezifikationen unterschiedlich zu der der RMSE-Werte ausfällt. Insbesondere stechen die Ergebnisse der Prognose mit Hilfe einer Yeo-Johnson-Transformation hervor. Diese Variante erzeugt zwar nicht für die Ein-Schritt-Prognose, jedoch bereits ab einem Prognosehorizont von drei konsequent niedrigere MAE-Werte als andere Spezifikationen. Bei positiver Regelenergie wird durch die Prognose mit 96 Modellen und der Zensierung der Werte für eine Schrittweite von Eins ein besseres Ergebnis erzielt, jedoch wird diese Variante für die Mehrzahl der Prognosehorizonte übertroffen.

Für die vielversprechendsten Schätzmethode der Evaluation wird in der folgenden Tabelle der Anteil der korrekt prognostizierten Nullen zusammengefasst. Ein korrekt prognostizierter Null-Aufruf entspricht hier einer Prognose von einem negativen Wert respektive Null. Da Null-Aufrufe einen wesentlichen Bestandteil der gegebenen Daten darstellen, ist die korrekte Prognose hiervon ein weiteres wertvolles Kriterium zur Beurteilung der Prognosegüte der vorgestellten Modellspezifikationen.

Nullen – Anteil in Prozent	Positive Regelenergie																
	Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	47,52	37,82	28,02	21,34	18,67	16,67	13,59	11,48	10,91	10,04	9,07	7,98	7,83	7,59	7,11	6,56	
WLS II	39,20	24,97	17,15	12,81	10,74	9,39	7,86	6,47	6,11	5,78	5,20	4,55	4,22	4,15	3,97	3,84	
Yeo Johnson	30,63	19,33	12,78	8,79	7,97	6,27	4,93	3,90	3,61	3,59	3,30	2,71	2,37	2,33	2,16	1,84	
Nullen – Anteil in Prozent	Negative Regelenergie																
	Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	44,07	37,46	25,14	18,03	15,48	13,81	10,43	8,91	8,02	8,01	6,96	6,56	6,35	6,22	5,79	5,91	
WLS II	36,86	25,24	14,50	9,18	7,52	6,33	4,68	4,27	4,18	3,81	3,46	3,26	3,15	3,12	2,78	2,63	
Yeo Johnson	20,98	11,03	5,12	3,01	2,47	1,96	1,33	1,03	0,99	0,89	0,68	0,45	0,43	0,44	0,33	0,33	

Tabelle 3.6: Anteil der korrekt prognostizierten Null-Aufrufe für ausgewählte Spezifikationen des linearen Regressionsmodells - positive und negative Regelenergie

Die Null-Aufrufe werden durch die gewöhnliche OLS-Schätzung am präzisesten modelliert. Jedoch nimmt der Anteil der korrekt prognostizierten Werte rapide mit dem Prognosehorizont ab und pendelt sich in einem knappen Bereich um Null ein. Insbesondere die Yeo-Johnson-Transformation weist schon für niedrige Schrittweiten einen vergleichsweise geringen Anteil an korrekt prognostizierten Werten vor.

Ergänzend zu obigen Ergebnissen ist zu erwähnen, dass analog zu Abschnitt 3.3.1 Monate, welche eine erhöhte Streuung der Daten aufweisen, auch tendenziell höhere RMSE- und MAE-Werte hervorbringen - sowohl bei positiver als auch bei negativer Regelenergie. Dies kann ein Hinweis darauf sein, dass die Dynamik der Zusammenhänge zwischen den Daten durch das lineare Regressionsmodell zu Zeiten erhöhter Volatilität nur suboptimal beschrieben wird. Es hat nicht zur Folge, dass das postulierte Modell völlig falsch ist. Allerdings wird die Dynamik in Zeiten mit einer erhöhten Streuung der Daten dadurch schlechter beschrieben, was zu einer Verschlechterung der Ergebnisse führen kann. Ferner lässt sich erkennen, dass die Fehlermaße für größere Prognosehorizonte klarerweise ansteigen, wobei die Zwei-Schritt-Prognose schon eine wesentliche Verschlechterung der Ergebnisse liefert. Zuzüglich ist zu erwähnen, dass die Fehlermaße von Abrufmengen negativer Regelenergie im Allgemeinen höher sind als die Werte positiver Regelenergie. Dies lässt sich unter anderem durch die Skalenabhängigkeit von RMSE- und MAE-Werten in Verbindung mit höheren statistischen Kennzahlen bei Abrufmengen negativer Regelenergie (siehe Abschnitt 3.1) erklären.

3.4.4 Evaluation der Modellannahmen

In diesem Abschnitt sollen die Annahmen des linearen Regressionsmodells und der dafür verwendeten Schätzverfahren kurz angeführt und anschließend, soweit dies möglich ist, für wichtige Modelle aus diesem Abschnitt überprüft werden. In diesem Kontext ist anzumerken: die verwendeten Regressoren sind streng genommen ebenfalls als Realisationen von Zufallsvariablen aufzufassen. Des Weiteren handelt es sich bei sämtlichen Variablen um Zeitreihen-Daten. In diesem Zusammenhang sind Annahmen des klassischen linearen Regressionsmodells, wie es zum Beispiel in Hayashi (2000) zu finden ist, oft verletzt. Allerdings hat sich als Konsequenz hieraus die asymptotische - oder große-Stichproben - Theorie für lineare Regressionsmodelle entwickelt, welche ein breites Anwendungsspektrum in der Ökonomie besitzt. Es werden nun kurz die Annahmen der asymptotischen Theorie für lineare Regressionsmodelle aus Hayashi (2000) vorgestellt.

$$\text{LM 1. Linearität} \quad y_t = X_t \beta + \varepsilon_t \quad (t = 1, \dots, n) \quad (3.1)$$

$$\text{LM 2. Ergodische Stationarität} \quad \text{Der } (K+1)\text{-dimensionale Zufallsvektor } (y_t, X_t) \text{ ist gemeinsam stationär und ergodisch} \quad (3.2)$$

$$\text{LM 3. Prädeterminierte Regressoren} \quad \mathbb{E}(x_{k,t} \varepsilon_t) = 0 \quad (t = 1, \dots, n, k = 1, \dots, K) \quad (3.3)$$

$$\text{LM 4. Rangbedingung} \quad \Sigma_{XX} = \mathbb{E}(X_t X_t') \text{ in } \mathbb{R}^{K \times K} \text{ ist nicht singulär (und somit endlich) } t = 1, \dots, n \quad (3.4)$$

$$\text{LM 5.} \quad g_t = X_t \varepsilon_t \text{ ist eine Martingaldifferenzenfolge mit endlichen zweiten Momenten, die } K \times K\text{-Matrix } \mathbb{E}(g_t g_t') \text{ ist nicht singulär} \quad (3.5)$$

Hierbei wird angenommen, dass die Beobachtungen, welche in der Regression verwendet werden, durch einen $(K + 1)$ -dimensionalen stochastischen Prozess - eine Folge von Zufallsvektoren in diskreter Zeit - erzeugt wurden, an welchen die obigen Annahmen gerichtet werden. Allerdings ist das einzige Instrument um diese zu überprüfen die gegebene Stichprobe.

Die Linearitätsbedingung ist analog zum klassischen linearen Regressionsmodell zu verstehen. Sie postuliert einen linearen Zusammenhang zwischen den Komponenten des Zufallsvektors wobei β wieder einen unbekanntem K -dimensionalen Koeffizientenvektor und ε_t den unbeobachteten Fehlerterm bezeichnet. Die Annahme der ergodischen Stationarität erfordert, dass der stochastische Prozess, welcher die Stichprobe erzeugt hat, einem Zufallsvektor entspricht, der gemeinsam stationär und ergodisch ist. Dies zu überprüfen ist oft nicht leicht. Klarerweise lassen sich klassische Tests auf Stationarität der einzelnen Zeitreihen anwenden, allerdings muss ein Zufallsvektor mit ausschließlich stationären Komponenten nicht gemeinsam

stationär sein.²¹ In manchen Fällen lässt sich diese Annahme heuristisch begründen, wie zum Beispiel bei Mikrodaten von Haushalten, wo oft angenommen wird, dass eine Stichprobe unabhängig und identisch verteilt - *i.i.d.* - ist. Im Kontext dieser Analyse wird die Voraussetzung der Stationarität durch ADF-Tests und KPSS-Tests überprüft. Die dritte Annahme impliziert, dass der Fehlerterm orthogonal zu allen kontemporären Regressoren ist.²² Falls die Regression eine Konstante enthält, impliziert dies außerdem, dass der Fehlerterm Erwartungswert Null besitzt. Diese Bedingung wird durch die Residuen der Regression bei OLS-Schätzung durch die Konstruktion des Schätzers eingehalten.²³ Die angeführte Rangbedingung impliziert, dass die Datenmatrix, die Zeitreihen der gegebenen Stichprobe, vollen Spaltenrang besitzt.²⁴ Die fünfte Bedingung impliziert, bei der Regression mit einer Konstante, dass der Fehlerterm selbst eine Folge von Martingaldifferenzen ist und daher keine Autokorrelation vorweist.

Die vorgestellten Bedingungen ermöglichen gewisse Aussagen über die Schätzung des linearen Zusammenhangs. Der Parametervektor β und die Varianz des Fehlerterms werden unter den ersten vier Annahmen konsistent durch den OLS-Schätzer geschätzt. Eine Folge von Schätzern ist konsistent, wenn sie sich mit wachsender Stichprobengröße mehr und mehr dem wahren Parameter annähert. Falls die dritte Annahme durch die fünfte ersetzt wird, so lässt sich sogar zeigen, dass der OLS-Schätzer asymptotisch normalverteilt ist.²⁵ Dies ermöglicht auch eine Reihe von Resultaten für statistische Tests. Falls zusätzlich die bedingte Homoskedastizität des Fehlerterms gegeben ist, so ergeben sich sehr praktische Resultate für die bekannten t - und F -Statistiken.

LM 6. Bedingte Homoskedastizität $\mathbb{E}(\varepsilon_t^2 | X_t) = \sigma^2 > 0$ (3.6)

Diese Bedingung ist nicht notwendig für die Konsistenz des OLS-Schätzers. Falls bedingte Heteroskedastizität des Fehlerterms vorliegt, jedoch keine Autokorrelation, und die funktionale Form des Zusammenhangs korrekt spezifiziert und bekannt ist, so ist der WLS-Schätzer, unter den übrigen Annah-

²¹Siehe zum Beispiel Hayashi (2000: Beispiel 2.3)).

²²Seien X und Y zwei Zufallsvariable mit endlichen zweiten Momenten. Sie sind orthogonal wenn $\mathbb{E}(XY) = 0$ gilt.

²³Der OLS-Schätzer ergibt sich aus der Lösung der sogenannten Normalgleichungen. Falls die Rangbedingung erfüllt ist, ergibt er sich unmittelbar aus einer Matrix-Vektor-Multiplikation. Die Residuen, welche bei dieser Schätzung entstehen, besitzen keine empirische Korrelation zu den Regressoren, aufgrund der Gestalt der Normalgleichungen. Nachzulesen beispielsweise in Hayashi (2000: Abschnitt 1.2).

²⁴Die Rangbedingung fordert vom zugrunde liegenden stochastischen Prozess die lineare Unabhängigkeit seiner Komponenten.

²⁵Hier sollte noch einmal explizit erwähnt werden, dass der OLS-Schätzer eine Funktion der beobachteten Werte und somit selbst eine Zufallsvariable mit einer gewissen Verteilung ist. Das vorgestellte Resultat ist auch ohne die Normalverteilungsannahme an den Fehlerterm gültig.

men, konsistent, asymptotisch normalverteilt und effizienter als der OLS-Schätzer. Dies bedeutet, dass seine asymptotische Varianz kleiner als die des OLS-Schätzers ist, wodurch sich genauere Schätzungen des Parameters und präzisere Prognosen ergeben können. Im Fall, dass der Zusammenhang nicht bekannt ist, sondern geschätzt werden muss, sind zusätzliche Bedingungen an den Schätzer der Varianz-Kovarianz-Matrix des Fehlerterms zu stellen, sodass der WLS-Schätzer konsistent und asymptotisch normalverteilt ist. Zusätzlich ist zu bemerken, dass die Effizienz des WLS-Schätzers wesentlich von der Spezifizierung der funktionalen Form der Heteroskedastizität abhängt. Für Genaueres siehe beispielsweise Hayashi (2000). Für wünschenswerte Eigenschaften des Parameterschätzers bei einer Prais-Winsten-Transformation ist klarerweise die korrekte Spezifikation der autoregressiven Struktur des Fehlerterms ebenso eine essenzielle Voraussetzung. Bei Mehr-Schritt-Prognosen sind Fehlerterme typischerweise korreliert.

Da für die Messung des Einflusses der verschiedenen Variablen und die Prognose der Abrufmengen eine Vielzahl an Modellen geschätzt wurde, sollen einige der vorgestellten Annahmen hier für wenige repräsentative Modelle angeführt werden. Namentlich werden die Voraussetzungen im Folgenden für das Modell mit allen Variablen, deren Einfluss auf die Abrufmengen von Regelenergie überprüft wurde, sowie sämtliche Varianten der Prognosemodelle überprüft, ausgenommen den Modellen für die unterschiedlichen Tageszeiten. Die Schätzung basiert hierbei auf dem gesamten Datensatz und bei der Prognose werden lediglich Ein-Schritt-Prognose-Modelle betrachtet.

In der Tabelle auf Seite 45 sind die Teststatistiken und Quantile der ADF- und KPSS-Tests sämtlicher verwendeter Variablen im linearen Regressionsmodell eingetragen, mit Ausnahme der deterministischen Dummies. Die Tests wurden für Zeitreihen durchgeführt, welche den gesamten Datensatz umfassen, nach demselben Schema, welches in Abschnitt 3.1 auf die Abrufmengen angewendet wurde.

Das Ergebnis der Tests ergibt ein ähnliches Bild wie bei den Regelenergieabrufmengen. Die Nullhypothese des ADF-Tests, ohne Konstante und Trend, kann nur für die Lastprognose für gewisse angeführte Signifikanzniveaus nicht abgelehnt werden. Sobald eine Konstante - beziehungsweise ein linearer Trend - in das Testverfahren inkludiert wird, wird die Nullhypothese selbst zu einem Signifikanzniveau von 1% stets verworfen. Die Zeitreihe wird also von einem, im Sinne dieses Tests, stationären Prozess erzeugt. Die Ergebnisse des KPSS-Tests lassen wiederum keine eindeutigen Schlüsse zu. Lediglich für den Windprognosefehler liefert der Test in beiden Varianten zu einem Signifikanzniveau von 1% das Ergebnis, dass die Nullhypothese bei den gegebenen Daten nicht ausgeschlossen werden kann. Die Handels-Volumina am Intraday-Markt werden durch den Test zu einem

<i>Test</i>	<i>ADF</i>	<i>ADF</i>	<i>ADF</i>	<i>KPSS</i>	<i>KPSS</i>
<i>Typ</i>	<i>Nichts</i>	<i>Konstante</i>	<i>Trend</i>	<i>Konstante</i>	<i>Trend</i>
1%-Quantil	-2.58	-3.43	-3.96	0.739	0.216
5%-Quantil	-1.95	-2.86	-3.41	0.463	0.146
10%-Quantil	-1.62	-2.57	-3.12	0.347	0.119
Ungewollter Stromimport	-58,42	-103,70	-105,26	11,40	4,08
Ungewollter Stromexport	-70,60	-72,44	-72,57	1,82	0,42
Windeinspeisung	-10,88	-15,95	-16,12	2,12	0,72
Windprognose	-4,98	-7,78	-7,87	2,31	1,06
Windprognose-Fehler	-33,05	-33,26	-33,32	0,59	0,19
Windprognose MA	-32,32	-52,06	-52,63	2,36	1,08
PV-Prognose	-42,41	-52,67	-52,67	5,03	5,03
PV-Prognose MA	-132,22	-207,64	-207,65	5,78	5,79
Last	-2,70	-13,75	-13,78	3,32	2,84
Lastprognose	-2,45	-14,38	-14,48	6,06	4,58
Lastprognose-Fehler	-16,68	-17,08	-17,14	1,00	0,55
Lastprognose MA	-13,24	-94,51	-95,49	6,45	4,88
Intraday-Kaufvolumen	-41,66	-87,00	-87,74	4,12	0,19
Intraday-Verkaufsvolumen	-41,74	-87,08	-87,80	4,03	0,19
Nicht geplante Nicht-Verf.	-11,82	-12,58	-12,67	1,88	0,53

Tabelle 3.7: ADF- und KPSS-Statistiken der Variablen mit möglichem Einfluss auf Abrufmengen von Regelenergie

Signifikanzniveau von 1% als stationär um einen linearen Trend befunden.

Aufgrund der Diskrepanzen dieser Einheitswurzel-Tests wurde ein Test auf Kointegration sämtlicher angeführter Variablen durchgeführt. Dabei wurde auf einen Johansen-Test zurückgegriffen, wobei dieser mit Hilfe der R-Funktion *ca.jo* des R-Pakets *urca* realisiert wurde (23). Sowohl für positive, als auch für negative Regelenergie wird durch den Test die Hypothese der Singularität der relevanten Matrix zu einem Signifikanzniveau von 1% abgelehnt. Dies deutet darauf hin, dass keine Kointegrations-Beziehung zwischen den Variablen vorliegt beziehungsweise sämtliche Variablen stationär sind. Für eine genaue Beschreibung zum Johansen-Test siehe beispielsweise Hamilton (1994).

Die Residuen sämtlicher Regressionsmodelle, welche mit OLS geschätzt wurden, besitzen einen empirischen Mittelwert von Null und eine vernachlässig-

bare empirische Korrelationen zu den Regressoren der verschiedenen Modelle. Dies ergibt sich als direkte Konsequenz der Inklusion einer Konstanten und des verwendeten Schätzverfahrens. Prognosemodelle, bei welchen WLS als Schätzverfahren verwendet wurde, weisen empirische Korrelation zwischen den Modellresiduen und verschiedenen Regressoren vor, insbesondere gelagten Werten der abhängigen Variable. Die höchsten derartigen Werte befinden sich im Bereich von 10^{-2} .

In den Autokorrelogrammen der Residuen der Modelle, mit Hilfe derer der Einfluss der exogenen Variablen auf die Abrufmengen überprüft wurde, sind signifikante Abhängigkeiten von unmittelbar vergangenen Werten erkennbar. Ein Breusch-Godfrey-Test ergibt sowohl für positive als auch negative Regelenenergie schon für einen Lag ein signifikantes Ergebnis, also eine vorhandene Autokorrelation in den Residuen, zu einem Signifikanzniveau von 5%. Die empirische Autokorrelationsfunktion der Residuen der Prognosemodelle ist insgesamt kleiner, dennoch liefert der Breusch-Godfrey-Test auch hier bereits bei einem Lag für sämtliche Modelle dasselbe Ergebnis. Theoretisch gesehen sind die Annahmen dieses Tests nicht exakt erfüllt, wobei der Breusch-Godfrey-Test im Falle, dass die strikte Exogenität der Regressoren nicht gegeben ist, trotzdem anwendbar ist. Für eine genauere Diskussion siehe Hayashi (2000: Abschnitt 2.10). Der Test wurde mit Hilfe der R-Funktionen *bgtest* aus dem Paket *lmtest* durchgeführt (18).

Die Matrizen der unabhängigen Variablen besitzen in sämtlichen Modellen vollen Spaltenrang. Ferner wurden Tests auf bedingte Homoskedastizität der Residuen durchgeführt, namentlich Breusch-Pagan-Tests. Hierbei wird die Nullhypothese der Homoskedastizität in jedem Modell zu einem Signifikanzniveau von 5% abgelehnt, wobei dies mit Hilfe der R-Funktion *bptest* aus dem Paket *lmtest* überprüft wurde (18). Die Modellresiduen wurden außerdem auf Normalität überprüft. Neben der Betrachtung von Histogrammen und QQ-Plots wurden ein Jarque-Bera-Test und ein Chi-Quadrat-Anpassungstest nach Pearson durchgeführt. Hierfür wurden die R-Funktionen *jarque.bera.test* und *pearson.test* aus den Paketen *tseries* und *nortest* verwendet (22, 19). Die Tests lehnen die Normalverteilungsannahme in sämtlichen Modellen zu einem Signifikanzniveau von 5% ab. Bedingte Homoskedastizität sowie Normalität der Fehlerterme der Regression sind jedoch keine notwendigen Annahmen für die Konsistenz der OLS-Schätzung.

Um einen besseren Einblick in die Schätzung zu gewinnen ist im Folgenden das lineare Regressionsmodell der Ein-Schritt-Prognose von Abrufmengen positiver Regelenenergie abgebildet, wobei die Schätzung auf dem gesamten Datensatz basiert. Für jede unabhängige Variable sind jeweils der entsprechende Koeffizientenschätzer, eine Schätzung der Standardabweichung des Koeffizientenschätzers und der daraus resultierende *t*-Wert notiert.

3.4. DAS LINEARE REGRESSIONSMODELL

	Koeffizienten	<i>t</i> -Werte
(Intercept)	-3,09 (0,45)***	-6,81
Abrufmenge positiver Regelenergie_1	0,75 (0,01)***	88,53
Abrufmenge positiver Regelenergie_2	-0,18 (0,01)***	-20,34
Abrufmenge positiver Regelenergie_3	0,10 (0,01)***	12,12
Abrufmenge positiver Regelenergie_4	0,08 (0,01)***	8,01
Abrufmenge positiver Regelenergie_5	-0,04 (0,01)***	-4,59
Abrufmenge positive Regelenergie_6	0,02 (0,01)**	2,39
Abrufmenge positiver Regelenergie_7	-0,00 (0,01)	-0,39
Abrufmenge positiver Regelenergie_8	0,03 (0,01)***	4,51
Windprognose_0	0,01 (0,00)**	3,10
Windprognose_1	-0,04 (0,01)***	-5,66
Windprognose_2	0,02 (0,00)***	6,71
Lastprognose_0	-0,01 (0,00)***	-8,13
Lastprognose_1	0,01 (0,00)***	9,39
Lastprognose_2	0,00 (0,00)	1,47
Lastprognose_3	-0,01 (0,00)***	-8,23
Photovoltaikprognose_0	-0,07 (0,02)**	-3,17
Photovoltaikprognose_1	0,17 (0,05)***	3,26
Photovoltaikprognose_2	-0,11 (0,05)**	-2,48
Photovoltaikprognose_3	0,01 (0,02)	0,50
Ungewollter Stromimport_1	0,25 (0,01)***	24,92
Ungewollter Stromimport_2	-0,04 (0,01)***	-4,22
Ungewollter Stromimport_3	0,03 (0,01)***	3,50
Windprognosefehler_1	0,04 (0,00)***	20,92
Windprognosefehler_2	-0,03 (0,00)***	-11,28
Windprognosefehler_3	-0,00 (0,00)**	-2,83
Abrufmenge positiver Regelenergie_96	0,07 (0,01)***	11,02
Abrufmenge positiver Regelenergie_97	-0,05 (0,01)***	-9,23
Abrufmenge positiver Regelenergie_MA	0,07 (0,01)***	6,55
Windprognose_MA	-0,00 (0,00)	-1,19
Lastprognose_MA	0,00 (0,00)	1,41
Photovoltaikprognose_MA	0,01 (0,00)***	5,69
Ungewollter Stromexport_1	0,05 (0,01)***	6,13
Lastprognosefehler_1	-0,00 (0,00)**	-2,80
Kaufvolumen Intraday_1	-0,00 (0,00)	-1,04
Nicht verfügbare Kapazitäten_1	0,00 (0,00)**	2,54
R ²	0,68	
Adj. R ²	0,68	
Num. obs.	34938	
RMSE	6,97	

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$

Tabelle 3.8: Lineares Regressionsmodell der Ein-Schritt-Prognose: Positive Regelenergie

Die angeführten Zahlen zu erklärenden Variablen entsprechen dem Lag der betroffenen Variablen. Beispielsweise entspricht `Windprognose_0` der prognostizierten Einspeisung aus Windenergie zu dem Zeitpunkt, welcher prognostiziert werden soll. Dahingegen entspricht `Windprognose_1` dem Wert der Vorperiode. `Windprognose_MA` bezeichnet einen einseitigen Moving Average der Ordnung 24 und ist analog für die anderen Variablen zu interpretieren. Bei dem Moving Average der Abrufmengen werden klarerweise nur die letzten bekannten Werte verwendet. Auf die Darstellung der Koeffizienten sämtlicher Dummy-Variablen wurde aus Platzgründen verzichtet. Die Standardabweichung der Koeffizientenschätzer wurde mit Newey-West geschätzt um möglichen Verletzungen der Annahmen an den Fehlerterm entgegenzuwirken. Hierfür wurde die Funktion *NeweyWest* aus dem R-Paket *sandwich* verwendet (20).

Die Sterne bei Koeffizienten deuten an, dass der assoziierte t -Wert unter beziehungsweise über dem üblichen Signifikanzniveau des entsprechenden t -Tests liegt.²⁶ Allerdings ist nicht davon auszugehen, dass die Annahmen ebendieses Tests erfüllt sind. Der t -Wert entspricht dem Quotient aus Schätzer und geschätzter Standardabweichung des Schätzers. Trotz Schätzungen der entsprechenden Standardabweichungen durch Newey-West sollte hier nicht von deren Exaktheit ausgegangen werden. Ein hoher t -Wert kann jedoch nach wie vor auf einen vorhandenen Einfluss hindeuten.

Die Schätzer der Koeffizienten der gelagerten Werte der abhängigen Variablen erzeugen fast gänzlich hohe t -Werte. Dasselbe gilt für die Prognosevariablen sowie ungewollten Stromimport und den Prognosefehler der Windeinspeisung. Die Moving-Average-Werte der Wind- und Lastprognose sowie die anderen Variablen deren Einfluss überprüft wurde, wirken nebensächlich für die Prognose, mit Ausnahme des ungewollten Stromexports. Die nicht dargestellten OLS-Schätzer der Koeffizienten der Dummy-Variablen haben vergleichsweise hohe geschätzte Standardabweichungen und gelegentlich dementsprechend niedrige t -Werte.

Die Vorzeichen der Koeffizienten decken sich teilweise nicht mit den heuristischen Überlegungen in Abschnitt 3.3.1. Die Koeffizienten der Prognosevariablen und deren gelagerten Werten nehmen abwechselnd positive und negative Vorzeichen an. Damit lässt sich nicht eindeutig darauf schließen ob hohe Werte der Variablen zu einem erhöhten Bedarf an positiver Regelernergie führen. Der ungewollte Stromimport der Vorperiode besitzt sowohl ein positives Vorzeichen als auch einen der höchsten t -Werte des Modells. Ein ähnlich hoher t -Wert ist beim Windprognosefehler der Vorperiode zu finden.

²⁶Der entsprechende Koeffizientenschätzer wird bei diesem Test auf Null getestet. Man spricht in diesem Zusammenhang auch oft von einem Test auf statistische Signifikanz.

Ein positiver Prognosefehler bedeutet, dass die Prognose die tatsächliche Einspeisung übersteigt, also weniger als geplant eingespeist wurde. Ein positiver Zusammenhang erscheint demnach sinnvoll. Allerdings besitzt der Windprognosefehler der zweiten Vorperiode ein negatives Vorzeichen, was wiederum einen komplexeren Zusammenhang als vermutet suggeriert. Der ungewollte Stromexport der Vorperiode besitzt einen positiven Koeffizienten, der Rest der Variablen deren Einfluss überprüft wurde, scheint im Gegensatz zu den bereits erwähnten einen geringen Erklärungswert zu liefern.

Das Bestimmtheitsmaß der Regression R^2 beträgt im obigen Modell 0,68. Es misst den Anteil der Variabilität der abhängigen Variablen, welcher durch die Regression auf die exogenen Variablen erklärt wird. Der Wert liegt beim geschätzten Modell sehr nahe am adjustierten Bestimmtheitsmaß R_{adj}^2 , was sich durch die hohen Anzahl an Beobachtungen begründen lässt. Ein wesentlicher Anteil des Wertes ergibt sich aus der Inklusion gelagter Werte der abhängigen Variablen. Das Modell der Abrufmengen positiver Regelenergie, bei dem lediglich exogene Variablen als Regressoren verwendet werden, ergibt ein Bestimmtheitsmaß von 0,336.

Bei einer Untersuchung der Residuen des Modells, wirkt die Annahme der Normalverteilung bei einem Blick auf das Histogramm in Abbildung 3.14 nicht völlig unpassend, obwohl ein QQ-Plot und Tests ein anderes Ergebnis liefern. Des Weiteren sind nach wie vor signifikante Werte in der Autokorrelationsstruktur zu erkennen. Es ist ersichtlich, dass die Residuen eine hohe Schwankungsbreite in Bezug auf die Tageszeit aufweisen, wie schon die Abrufmengen an Regelenergie selbst. Im Appendix sind das lineare Regressionsmodell der Ein-Schritt-Prognose der Abrufmengen negativer Regelenergie sowie die entsprechenden Plots der Residuen zu finden.

Zusammenfassend lässt sich sagen: Nicht alle Annahmen des linearen Regressionsmodells sind erfüllt. Die Frage nach der Stationarität der Regressoren lässt sich, wie schon bei den Abrufmengen von Regelenergie, auf Basis der durchgeführten Tests nicht eindeutig beantworten. Ein stochastischer Prozess, welcher nicht stationär ist, muss jedoch nicht integriert sein. Einige der Argumente, welche gegen einen positiven Integrationsgrad der Regelenergieabruflmenge sprechen, lassen sich auch auf Variablen aus diesem Kontext anwenden. Der Johansen-Test würde ebenfalls dagegen sprechen. Jedoch ist zu erwarten, dass die Zeitreihen der Variablen streng genommen nicht durch stationäre stochastische Prozesse erzeugt wurden. Variablen wie Last und Einspeisung aus erneuerbaren Energiequellen sind stark abhängig von Tageszeiten (6), wodurch davon auszugehen ist, dass Mittelwert und Varianz des zugrunde liegenden Prozesses nicht konstant sind. Allerdings scheint die Annahme eines integrierten Prozesses auch nicht unbedingt passend.

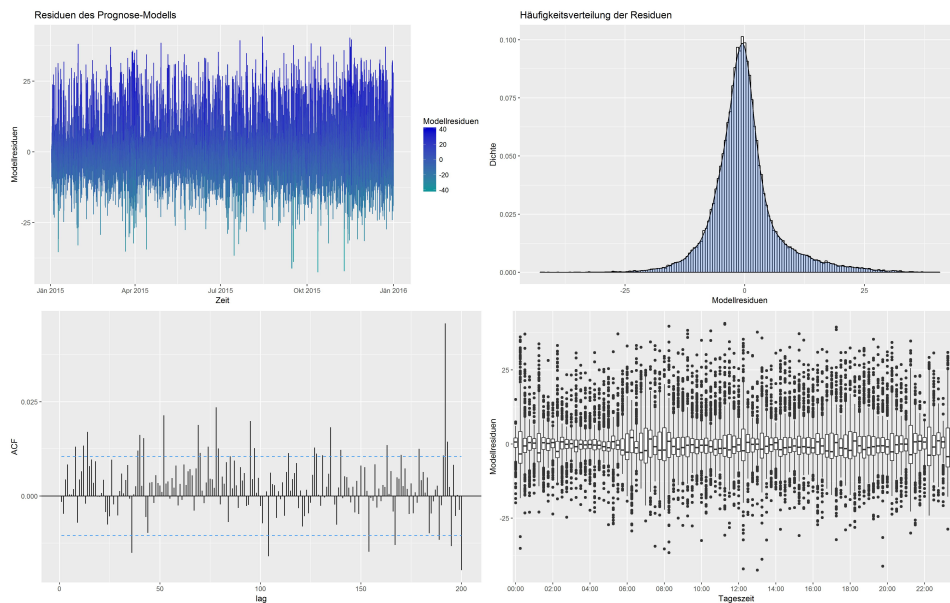


Abbildung 3.14: Residuen des linearen Regressionsmodells der Ein-Schritt-Prognose: Abrufmengen positiver Regelenergie

Des Weiteren weisen die Modellresiduen der verschiedenen Prognoseansätze Eigenschaften auf, die gegen die Annahme eines White-Noise-Prozesses für den Fehlerterm sprechen, wie beispielsweise bei den durchgeführten Tests auf Autokorrelation ersichtlich wird. Dies ist ein Hinweis darauf, dass sie noch Information enthalten, welche die Güte der Prognose der Zeitreihe verbessern könnte. Somit sollte im linearen Regressionsmodell nicht von der Konsistenz des OLS- beziehungsweise WLS-Schätzers, und noch weniger von deren asymptotischer Normalität, ausgegangen werden. Natürlich ist zu erwähnen, dass Variable sehr wohl einen Einfluss auf die Abrufmengen von Regelenergie haben können, welcher jedoch in diesem Kontext nicht registriert wurde, da die Spezifikation des vorgestellten Ansatzes dies nicht zulässt. Ein großes Manko des linearen Regressionsmodells im Kontext der Abrufmengen von Regelenergie ist, dass bei der Schätzung die Nichtnegativität der Zeitreihe nicht explizit berücksichtigt wird. Dies wird beispielsweise durch ein zensiertes lineares Regressionsmodell - ein Tobit Modell - berücksichtigt. Modelle der untransformierten Zeitreihe beziehungsweise der Yeo-Johnson-Transformation, welche keine negativen Werte erzeugt, erzielen die besten Prognosewerte. Auch wenn Tobit Modelle üblicherweise für Querschnittsdaten verwendet werden, bieten sie sich hier als logischer Anknüpfungspunkt. Das Tobit Modell soll deshalb im nächsten Abschnitt dieser Arbeit kurz vorgestellt, auf die Daten angewendet und anschließend die Ergebnisse zusammengefasst werden.

3.5 Das Tobit Modell

Das Tobit Modell versucht den Zusammenhang zwischen Variablen zu beschreiben, wobei die abhängige Variable in einem gewissen Sinne eingeschränkt ist. Die üblichen Einschränkungsmechanismen hierbei sind „Stutzen“ und „Zensieren“. Eine gestutzte Variable ist nur in einem bestimmten Bereich beobachtbar (zum Beispiel Anteil der Einkommenssteuer am Einkommen in Österreich), zensierte Variablen nur bis zu einem gewissen Ausmaß (beispielsweise Lebenszeit von Maschinenteilen). Im Zusammenhang mit Tobit Modellen werden oft latente Variable verwendet: y^* ist eine latente Variable, wenn ihre Werte nicht direkt beobachtet werden. Allerdings kann eine Funktion der latenten Variablen, y , beobachtet werden. Ein Beispiel für eine derartige Variable ist das Wissen von Studierenden in einer bestimmten Fachrichtung. Es lässt sich weder beobachten noch ist es exakt quantifizierbar, allerdings können Beurteilungen von Prüfungen und verfassten Arbeiten als Schätzungen davon aufgefasst werden.

Sei y^* eine latente Zufallsvariable und y beobachtet. y heißt bei L linkszensiert, wenn

$$y = \begin{cases} y^* & \text{für } y^* > L \\ L & \text{für } y^* \leq L \end{cases}$$

beziehungsweise bei L linksgestutzt, falls gilt

$$y = y^* \quad \text{für } y^* > L$$

Es gibt eine Fülle an Tobit Modellen, welche unterschiedliche Modellierungen der Zusammenhänge beziehungsweise der Daten selbst ermöglichen. Das erste Tobit Modell wurde für die Analyse von Querschnittsdaten von Haushalten entwickelt, allerdings haben derartige Modelle auch schon Anwendungen im Kontext der Zeitreihenanalyse gefunden. Im Folgenden wird das Standard Tobit Modell im Fokus der Betrachtung stehen, wobei die Ausführungen hierzu Amemiya (1985) folgen.

3.5.1 Das Modell

Das Standard Tobit Modell, welches auch als Typ 1 bezeichnet wird, lässt sich als lineares Regressionsmodell mit einer eingeschränkten Variablen beschreiben. Im Falle der Abrufmengen von Regelenergie, welche bei Null linkszensiert sind, lässt sich dies folgendermaßen zusammenfassen.

$$y_t^* = X_t \beta + \varepsilon_t$$

$$y_t = \begin{cases} y_t^* & \text{für } y_t^* > 0 \\ 0 & \text{für } y_t^* \leq 0 \end{cases}$$

Die einzelnen Komponenten des Modells sind analog zum linearen Regressionsmodell interpretierbar, wobei die latente Variable klarerweise nicht beobachtet wird. Dieser Ansatz birgt Vorteile gegenüber dem vorhergehenden Verfahren: die OLS-Schätzung des linearen Regressionsmodells aus Abschnitt 3.4 erzeugt verzerrte Schätzer des Parametervektors β , da die Nullen das Ergebnis verfälschen.²⁷ Die durch das Tobit Modell postulierte Beziehung muss wiederum durch eine Stichprobe geschätzt werden, wobei hierfür unterschiedliche Verfahren existieren. In dieser Arbeit wird die übliche Maximum-Likelihood-Methode betrachtet.

3.5.2 Einfluss der Variablen im Modell

Wie im Abschnitt 3.3.1 erläutert, wurde der Einfluss verschiedener Variablen auf die Abrufmengen von Regelenergie überprüft. Die Abbildungen 3.15 und 3.16 stellen die Ergebnisse für positive und negative Regelenergie dar. Die durchschnittlichen Werte der Evaluationskriterien, gemittelt über Monate, sind in einer Tabelle im Appendix zu finden. Als Maximalanzahl der verwendeten Lags wurde wieder acht festgelegt, wobei diese Grenze bei der Schätzung stets eingehalten wurde.

Die einflussreichsten Variablen im Tobit Modell, relativ gesehen unter den betrachteten, sind dieselben wie im linearen Regressionsmodell. Ungewollter Stromimport, der Windprognosefehler und dahinter die Windeinspeisung üben im Kontext des Modells und des verwendeten Verfahrens den größten Einfluss auf Abrufmengen positiver Regelenergie aus. Dasselbe trifft bei negativer Regelenergie zu, wobei ungewollter Stromexport anstatt -import ausschlaggebend ist. Als geschätzter Wert für die Abrufmengen wurde der entsprechende Erwartungswert verwendet, welcher im nächsten Abschnitt näher erläutert wird. Die Schätzung der Modelle für die Überprüfung des Einflusses und die Erstellung der Intraday-Prognose wurde mit der R-Funktion *tobit* des Pakets *AER* durchgeführt (14). Diese greift wiederum auf die *survreg*-Funktion des Pakets *survival* zu (21).

²⁷Für Genaueres siehe beispielsweise Amemiya (1985: Abschnitt 10.4.2).




Abbildung 3.15: RMSE/MAE-Vergleich gemittelt: Einfluss der Variablen: Tobit Modell - abgerufene positive Regelenergie

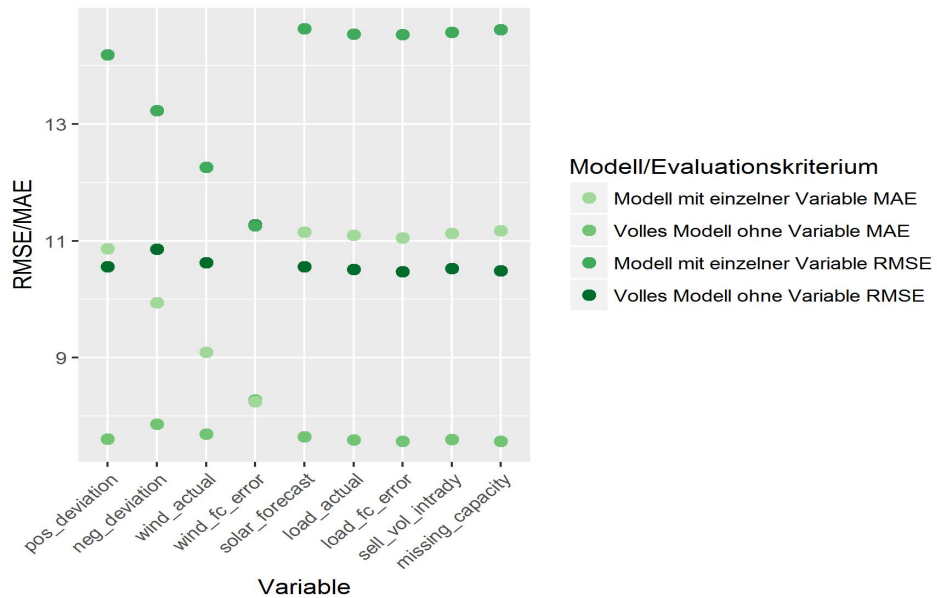


Abbildung 3.16: RMSE/MAE-Vergleich gemittelt: Einfluss der Variablen: Tobit Modell - abgerufene negative Regelenergie

3.5.3 Prognose

Die Prognose im Tobit Modell verläuft analog zum linearen Regressionsmodell, wie in Abschnitt 3.3.2 beschrieben. Allerdings wurden weniger Varianten als zuvor implementiert. Die Ergebnisse des linearen Regressionsmodells deuten darauf hin, dass die Prognose der untransformierten Zeitreihe beziehungsweise der Werte nach einer Yeo-Johnson-Transformation die besten Ergebnisse liefert. Das Tobit Modell bietet sich daher als nächster, logischer Schritt für die Modellierung der Daten an. Eine wesentliche Eigenschaft der Abrufmengen ist, dass sie keine negativen Werte umfassen. Dieses Merkmal wird durch das Tobit Modell berücksichtigt, wodurch intuitiv der Zusammenhang der Daten besser beschrieben wird und eine präzisere Prognose möglich ist.

Im linearen Regressionsmodell wird der bedingte Erwartungswert der abhängigen Variablen, bedingt auf die Realisationen der Regressoren, als Linearkombination der unabhängigen Variablen modelliert. Der bedingte Erwartungswert einer Zufallsvariablen Z bedingt auf X ist der Minimierer der erwarteten quadratischen Fehlerabweichung unter allen messbaren Funktionen von X . (Scherrer: 2015)

$$\mathbb{E}(Z|X) = \arg \min_{g \text{ messbar}} \mathbb{E}((Z - g(X))^2)$$

Der bedingte Erwartungswert im Tobit Modell besitzt eine andere Gestalt. Sei y_t durch das vorgestellte Tobit Modell erzeugt, wobei der Fehlerterm, bedingt auf die Regressoren, einer Normalverteilung folgt. Dann gilt für den Erwartungswert von y_t bedingt auf die Realisation der Regressoren X_t das auf Seite 55 Gezeigte.

In den dargestellten Zwischenschritten wird angenommen, dass der Fehlerterm des Modells, bedingt auf die Realisationen der Regressoren, normalverteilt mit Erwartungswert Null ist. Außerdem werden Formeln für die Normalverteilung und die zensierte Normalverteilung verwendet, wie sie beispielsweise in Greene (2008) zu finden sind. ϕ , f , Φ und F stehen in diesem Zusammenhang für die Dichte und Verteilungsfunktion der Standardnormalverteilung respektive einer Zufallsvariablen. Würden Abrufmengen von Regelenergie durch ein Tobit Modell erzeugt werden, so wäre der obige Ausdruck der Minimierer der erwarteten quadratischen Fehlerabweichung. Deswegen wird der dargestellte bedingte Erwartungswert als Prognosewert verwendet. Des Weiteren eignet sich die Linearkombination der exogenen Variablen $X_t\beta$, zensiert bei Null, als weiterer simpler Prognosewert, welcher im Folgenden als lineare Prädiktoren bezeichnet wird. Ergänzend werden diese Arten der Prognose auch für die Zeitreihe nach einer Yeo-Johnson-Transformation evaluiert.

$$\begin{aligned}
\mathbb{E}(y_t|X_t) &= \mathbb{E}(y_t|X_t, y_t^* > 0)\mathbb{P}(y_t^* > 0|X_t) + \mathbb{E}(y_t|X_t, y_t^* \leq 0)\mathbb{P}(y_t^* \leq 0|X_t) = \\
&= (X_t\beta + \mathbb{E}(\varepsilon_t|X_t, y_t^* > 0))\mathbb{P}(y_t^* > 0|X_t) = \\
&= (X_t\beta + \mathbb{E}(\varepsilon_t|X_t, \varepsilon_t > -X_t\beta))\mathbb{P}(\varepsilon_t > -X_t\beta|X_t) = \\
&= (X_t\beta + \mathbb{E}(\varepsilon_t|X_t, \varepsilon_t > -X_t\beta))(1 - \mathbb{P}(\varepsilon_t \leq -X_t\beta|X_t)) = \\
&= \left(X_t\beta + \int_{-X_t\beta}^{\infty} x f_{\varepsilon_t|X_t}(x|x > -X_t\beta) dx \right) (1 - F_{\varepsilon_t|X_t}(-X_t\beta)) = \\
&= \left(X_t\beta + \int_{-X_t\beta}^{\infty} x \frac{1}{1 - \Phi\left(\frac{-X_t\beta}{\sigma}\right)} f_{\varepsilon_t|X_t}(x) dx \right) \left(1 - \Phi\left(\frac{-X_t\beta}{\sigma}\right) \right) \\
&= \left(X_t\beta + \frac{1}{\Phi\left(\frac{X_t\beta}{\sigma}\right)} \int_{-X_t\beta}^{\infty} x \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}} dx \right) \Phi\left(\frac{X_t\beta}{\sigma}\right) = \\
&= \left(X_t\beta + \frac{1}{\Phi\left(\frac{X_t\beta}{\sigma}\right)} \int_{-\frac{X_t\beta}{\sigma}}^{\infty} z \sigma \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{z^2}{2}} \sigma dz \right) \Phi\left(\frac{X_t\beta}{\sigma}\right) = \\
&= \left(X_t\beta + \sigma \frac{1}{\Phi\left(\frac{X_t\beta}{\sigma}\right)} \int_{-\frac{X_t\beta}{\sigma}}^{\infty} z \phi(z) dz \right) \Phi\left(\frac{X_t\beta}{\sigma}\right) = \\
&= \left(X_t\beta + \sigma \frac{1}{\Phi\left(\frac{X_t\beta}{\sigma}\right)} \int_{-\frac{X_t\beta}{\sigma}}^{\infty} -\phi'(z) dz \right) \Phi\left(\frac{X_t\beta}{\sigma}\right) = \\
&= \left(X_t\beta + \sigma \frac{\phi\left(\frac{X_t\beta}{\sigma}\right)}{\Phi\left(\frac{X_t\beta}{\sigma}\right)} \right) \Phi\left(\frac{X_t\beta}{\sigma}\right)
\end{aligned}$$

Die Ergebnisse der Prognose sind in der Tabelle auf Seite 56 zusammengefasst, wobei abermals lediglich die Durchschnittswerte der Fehlermaße über die Monate angeführt sind. Die Regressoren beziehungsweise die Anzahl der Lags der verwendeten Variablen wurde von der Prognose anhand dem linearen Regressionsmodell übernommen. Der Grund hierfür ist, dass das Schätzen sämtlicher Modellvarianten für jeden Prognosehorizont schon beim linearen Regressionsmodell einen erheblichen Zeitaufwand darstellt, beim Tobit Modell jedoch noch um ein Vielfaches rechenintensiver ist.²⁸ Aus den Fehlermaßen der Prognose ist ersichtlich, dass die Linearkombination der exogenen Variablen als Prognosewert fast gänzlich niedrigere Fehlermaße erzeugt als der angeführte Erwartungswert. Hierzu ist zu bemerken, dass der wahre datengenerierende Prozess keinem Tobit Modell entspricht und in der Herleitung des bedingten Erwartungswertes einige Annahmen getroffen wurden, welche voraussichtlich nicht erfüllt sind.

²⁸Für jeden Prognosehorizont müssen 4608 Modelle geschätzt und evaluiert werden.

RMSE		Positive Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
EW	6,81	8,98	9,80	10,26	10,64	10,89	11,05	11,15	11,25	11,32	11,38	11,43	11,47	11,51	11,54	11,57
Lineare Prädiktoren	6,71	8,89	9,74	10,22	10,62	10,87	11,05	11,17	11,27	11,35	11,41	11,46	11,51	11,55	11,59	11,62
YJ - EW	11,59	12,03	11,92	11,95	12,17	12,34	12,43	12,45	12,51	12,55	12,60	12,65	12,67	12,70	12,73	12,75
YJ - Lineare Prädiktoren	11,60	12,06	11,97	12,01	12,25	12,44	12,53	12,56	12,62	12,67	12,72	12,77	12,80	12,83	12,85	12,88
MAE		Positive Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
EW	4,65	6,35	7,02	7,39	7,73	7,96	8,11	8,21	8,30	8,38	8,44	8,48	8,53	8,57	8,61	8,63
Lineare Prädiktoren	3,95	5,39	5,88	6,16	6,44	6,63	6,76	6,85	6,94	7,00	7,05	7,10	7,15	7,19	7,22	7,25
YJ - EW	5,29	6,01	6,12	6,22	6,39	6,50	6,57	6,62	6,66	6,70	6,73	6,75	6,78	6,80	6,82	6,83
YJ - Lineare Prädiktoren	5,27	5,98	6,09	6,19	6,36	6,47	6,54	6,58	6,63	6,67	6,69	6,72	6,75	6,77	6,79	6,80
RMSE		Negative Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
EW	7,17	9,36	10,55	11,34	12,07	12,54	12,85	13,06	13,23	13,37	13,48	13,57	13,64	13,69	13,74	13,78
Lineare Prädiktoren	7,10	9,30	10,50	11,30	12,02	12,50	12,81	13,03	13,21	13,35	13,47	13,56	13,63	13,69	13,73	13,78
YJ - EW	12,00	13,14	13,31	13,65	14,24	14,60	14,67	14,81	14,88	14,98	15,04	15,07	15,11	15,14	15,18	15,25
YJ - Lineare Prädiktoren	12,00	13,17	13,36	13,70	14,31	14,68	14,77	14,91	14,98	15,09	15,16	15,19	15,23	15,26	15,31	15,37
MAE		Negative Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
EW	5,01	6,74	7,66	8,28	8,86	9,22	9,47	9,65	9,81	9,94	10,03	10,10	10,17	10,22	10,26	10,31
Lineare Prädiktoren	4,36	5,83	6,55	7,03	7,52	7,82	8,02	8,18	8,32	8,43	8,51	8,57	8,64	8,69	8,72	8,76
YJ - EW	5,87	6,89	7,14	7,40	7,74	7,94	8,02	8,10	8,17	8,23	8,27	8,29	8,31	8,33	8,36	8,39
YJ - Lineare Prädiktoren	5,85	6,86	7,11	7,38	7,71	7,92	8,00	8,09	8,15	8,21	8,25	8,28	8,30	8,32	8,35	8,38

Tabelle 3.9: Evaluationskriterien der Prognose mit einem Tobit Model für positive und negative Regelenenergie

Allerdings sind die Fehlermaße der Prognose des Tobit Modells für „kurze“ Prognosehorizonte niedriger als die des linearen Regressionsmodells. Beispielsweise ergeben sich für einen Prognosehorizont von einem oder zwei Zeitschritten niedrigere RMSE-Werte für Abrufmengen positiver und negativer Regelenenergie. Die Prognose mit Hilfe des Tobit Modells erzeugt für positive Regelenenergie sogar durchgehend niedrigere MAE-Werte für die betrachteten Horizonte. Bei negativer Regelenenergie ergeben sich bis zu einer Schrittweite von sechs niedrigere MAE-Werte. Die Modellierung der Nichtnegativität der Abrufmengen durch ein Tobit Modell scheint daher, zumindest für die beschriebenen Prognosehorizonte und im Sinne der erwähnten Fehlermaße, Verbesserungen zu liefern. In der folgenden Tabelle sind die Anteile der korrekt prognostizierten Null-Aufrufe zusammengefasst.

<i>Nullen – Anteil in Prozent</i>	Positive Regelenergie															
	<i>Horizont</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Lineare Prädiktoren	78,12	70,34	64,35	60,55	56,02	52,10	49,73	48,24	46,61	45,64	44,19	44,00	43,32	42,18	41,47	41,51
YJ - Lineare Prädiktoren	64,40	49,56	41,98	38,41	33,02	28,87	26,20	25,33	24,13	22,55	21,45	21,42	20,82	20,13	19,35	19,42
<i>Nullen – Anteil in Prozent</i>	Negative Regelenergie															
	<i>Horizont</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Lineare Prädiktoren	75,78	68,10	61,17	54,97	50,61	46,97	44,58	41,29	39,49	38,22	36,76	35,71	35,16	34,60	33,69	32,87
YJ - Lineare Prädiktoren	54,62	33,67	25,04	20,89	17,33	15,05	12,97	11,52	10,03	9,17	8,66	7,86	7,31	7,24	6,84	6,67

Tabelle 3.10: Anteil der korrekt prognostizierten Null-Aufrufe für ausgewählte Spezifikationen des Tobit Modells - positive und negative Regelenergie

Null-Aufrufe werden in diesem Kontext korrekt prognostiziert, falls die entsprechende Linearkombination der erklärenden Variablen $X_t\beta$ kleiner oder gleich Null ist. Da durch das Tobit Modell unter anderem die Linkszensierung der Daten berücksichtigt wird, werden Null-Aufrufe signifikant besser prognostiziert als im linearen Regressionsmodell. Für die Ein-Schritt-Vorhersage ergeben sich sowohl für positive als auch negative Regelenergie Werte über 75%. Selbst größere Schrittweiten erzeugen wesentlich höhere Anteile als beim linearen Regressionsmodell. Die Yeo-Johnson-Transformation führt in diesem Zusammenhang wiederum zu einem niedrigeren Anteil an korrekt prognostizierten Nullen. In der Tabelle sind keine Werte für die Prognose mit Hilfe des bedingten Erwartungswertes angeführt, da hierbei nur strikt positive Werte erzeugt werden.

3.5.4 Evaluation der Modellannahmen

Tobit Modelle haben Anwendungen in der Zeitreihenanalyse gefunden, ursprünglich wurden sie jedoch für die Analyse von Querschnittsdaten verwendet. Es existiert daher auch mehr Literatur im Kontext von Querschnittsdaten, wobei hier oftmals andere Merkmale im Vordergrund stehen. Übliche Annahmen, wie sie zum Beispiel in Amemiya (1985) zu finden sind, wirken nicht passend im Kontext der vorgestellten Anwendung. Wie im linearen Regressionsmodell sind die Regressoren streng genommen als Trajektorien von stochastischen Prozessen aufzufassen. Dadurch sind zusätzliche Annahmen, wie die Stationarität der Prozesse, für die Konsistenz verschiedener Schätzverfahren nötig. De Jong und Herrera (2011) leiten hinreichen-

de Annahmen für die Konsistenz und asymptotische Normalität von zwei Schätzern her, darunter ist auch der übliche Maximum-Likelihood-Schätzer. Hierbei wird explizit berücksichtigt, dass sich gelaggte Werte der abhängigen Variablen unter den Regressoren befinden. Darin folgt y_t dem folgenden Modell, welches äquivalent zu dem anfangs erwähnten ist.

$$y_t = \max \left(0, \sum_{j=1}^p \rho_j y_{t-j} + \gamma' X_t + \varepsilon_t \right)$$

Fasst man die Parameter des Modells in einem Vektor zusammen, nämlich $\beta = (\rho', \gamma', \sigma)'$ so lässt sich als geschätztes Pendant hierzu $b = (r', c', s)'$ definieren. Hiermit ergibt sich als Likelihood-Funktion des Modells, beziehungsweise Log-Likelihood-Funktion, folgender Ausdruck.

$$\begin{aligned} \ell(b) = & \mathbf{1}(y_t > 0) \log \left(s^{-1} \phi \left(\frac{y_t - \sum_{j=1}^p r_j y_{t-j} - c' X_t}{s} \right) \right) \\ & + \mathbf{1}(y_t = 0) \log \left(\Phi \left(\frac{-\sum_{j=1}^p r_j y_{t-j} - c' X_t}{s} \right) \right) \end{aligned}$$

Dabei bezeichnen ϕ und Φ die Dichte- respektive Verteilungsfunktion der Standardnormalverteilung. Der Parametervektor, welcher diese Funktion für eine gegebene Stichprobe maximiert wird Maximum-Likelihood-Schätzer genannt. Die folgenden Annahmen werden an die verschiedenen Komponenten des Modells gerichtet.

T 1. $(X'_t, \varepsilon_t)'$ ist eine Folge von strikt stationären „strong mixing“ (3.7)

Zufallsvariablen mit „mixing number“ $\alpha(M)$ und $\mathbb{E}|X_t|^2 < \infty$

T 2. ε_t ist bedingt auf (X_1, \dots, X_T) unabhängig und identisch (3.8)

normalverteilt mit Erwartungswert 0 und Varianz σ^2 .

T 3. Der Parametervektor des Modells $\beta = (\rho', \gamma', \sigma)'$ ist in einer (3.9)

Menge B enthalten, welche ein kompakter Unterraum von \mathbb{R}^{p+q+1} ist.

T 4. $\mathbb{E} w_t w'_t \mathbf{1} \left(\sum_{j=1}^p r_j y_{t-j} + c' X_t > \delta \right)$ ist positiv definit für ein (3.10)

positives δ . $w_t = (y_{t-1}, \dots, y_{t-p}, X'_t, 1)$

T 5. Der Parametervektor des Modells $\beta = (\rho', \gamma', \sigma)'$ liegt im (3.11)

Inneren von B .

T 6. $I = \mathbb{E} \left(\frac{\partial}{\partial b} \right) l_t(\beta) \left(\frac{\partial}{\partial b'} \right) l_t(\beta) = -\mathbb{E} \left(\frac{\partial}{\partial b} \right) \left(\frac{\partial}{\partial b'} \right) l_t(\beta)$ (3.12)

ist invertierbar.

Die Annahme 3.7 impliziert, dass die einzelnen Komponenten des Zufallsvektors X_t sowie der Fehlerterm schwach stationär sind. 3.8 besagt, dass die Residuen des Modells normalverteilt sowie unkorreliert zu vergangenen Werten sind. Allerdings sind Fehler bei der Schätzung von Tobit Modellen nicht so einfach greifbar wie bei linearen Regressionsmodellen. Da angenommen wird, dass der Prozess y_t^* nicht zu jeder Zeit beobachtet wird, geht somit auch Information über den Fehlerterm verloren, welcher durch die Residuen geschätzt wird. Eine Möglichkeit Residuen für jeden Zeitpunkt zu erhalten, ist die Differenz der gefitteten Werte und den Beobachtungen zu verwenden, auch wenn die Beobachtungen zensiert sind. Eine andere Variante wäre, nur bei Beobachtungen größer Null Residuen zu berechnen. Die vierte Annahme erfordert, dass eine Matrix der unabhängigen Variablen der Regressionsgleichung vollen Spaltenrang besitzt. Die letzte Annahme impliziert, dass die Hesse-Matrix der Log-Likelihood-Funktion invertierbar ist. Die dritte und die fünfte Annahme stellen Forderungen an das Optimierungsproblem, welches zur Auffindung des Maximum-Likelihood-Schätzers gelöst wird - auf welches in dieser Arbeit nicht eingegangen wird.

In De Jong und Herrera (2011) wurde gezeigt, dass der Maximum-Likelihood-Schätzer $\hat{\beta}_{ML}$ unter den ersten vier Annahmen konsistent ist. Sind auch die zwei darauffolgenden Voraussetzungen erfüllt, so ist er sogar asymptotisch normalverteilt.

Die Stationarität der abhängigen Variablen und der Regressoren wurde bereits in vorhergehenden Abschnitten untersucht, nämlich 3.1 und 3.4.4. Dabei wurde jedoch kein eindeutiges Ergebnis erzielt, weswegen die Stationarität der einzelnen Prozesse nicht vorausgesetzt werden kann. Bereits die erste Annahme fordert jedoch eine wesentlich stärkere Eigenschaft des datengenerierenden Prozesses. Des Weiteren erscheinen die Annahmen an den Fehlerterm, insbesondere die der Unabhängigkeit, in diesem Kontext nicht passend. Da diese Folgerungen bereits einigen der angeführten Voraussetzungen widersprechen lässt dies die Überprüfung sämtlicher Annahmen redundant erscheinen. Aus diesem Grund wird an dieser Stelle auf das Anführen statistischer Tests verzichtet.

Zusammenfassend lässt sich sagen, dass das Tobit Modell zumindest für „kurze“ Prognosehorizonte eine Verbesserung gegenüber dem linearen Regressionsmodell im Sinne des RMSE liefert. MAE-Werte sind für positive Regenergie sogar durchwegs niedriger. Außerdem werden Null-Aufrufe durch das Tobit Modell wesentlich besser modelliert. Allerdings unterscheiden sich die Evaluationskriterien teilweise nur marginal und das lineare Regressionsmodell erzielt für größere Schrittweiten zum größten Teil bessere Ergebnisse. Die Resultate des Tobit Modells können als Benchmark für das lineare Regressionsmodell und weitere Analysen verwendet werden.

Eine häufig verwendete Klasse von Modellen für Zeitreihen sind ARIMA Modelle. Auch wenn statistische Zusammenhänge in der Realität oft komplexer sind, liefern sie teilweise gute Vorhersagen, insbesondere für kurze Horizonte. Die Prognose von negativen Werten wird zwar durch ARIMA Modelle nicht verhindert, allerdings hat die Berücksichtigung der Nichtnegativität der Abrufmengen durch das Tobit Modell nur bedingt Verbesserungen der Prognose ermöglicht. Des Weiteren scheint das Inkorporieren von Struktur im Fehlerterm in ein Modell zu einer präziseren Schätzung zu führen, wie beispielsweise bei der WLS-Schätzung des linearen Regressionsmodells ersichtlich wird.

3.6 SARIMA

Neben der Analyse der Abrufmengen durch Regressionsmodelle wird die Zeitreihe durch einen eindimensionalen SARIMA-Prozess modelliert. Hierbei handelt es sich um ein Modell für stochastische Prozesse, welches seine Entwicklung lediglich durch seine eigene Vergangenheit und die des assoziierten Fehlerterms zu erklären versucht. In diesem Zusammenhang lässt sich der Einfluss anderer Variablen auf die Abrufmengen an Regelenergie nicht überprüfen, allerdings eignen sich derartige Modelle für Prognosen von Zeitreihendaten.

3.6.1 Das Modell

SARIMA - oder Seasonal ARIMA - ist ein Modell, welches sich aus verschiedenen Bausteinen zusammensetzt, die im Folgenden kurz vorgestellt werden sollen. Die Ausführungen folgen hier Hamilton (1994). Das Fundament dieser Modellklasse bildet der sogenannte White Noise Prozess. Hierbei handelt es sich um eine Folge von Zufallsvariablen in diskreter Zeit ε_t - also um einen stochastischen Prozess. Für diesen gilt

$$\begin{aligned} \mathbb{E}(\varepsilon_t) &= 0, & \mathbb{E}(\varepsilon_t^2) &= \sigma^2 \quad \forall t \in \mathbb{Z} \\ \text{Cov}(\varepsilon_t, \varepsilon_{t+h}) &= \mathbb{E}(\varepsilon_t \varepsilon_{t+h}) = 0 \quad \forall t, h \neq 0 \end{aligned}$$

Es handelt sich somit um einen Prozess mit konstantem Erwartungswert gleich Null und konstanter Varianz, welcher unkorreliert zu seiner Vergangenheit ist - und somit um einen schwach stationären Prozess. Im linearen Regressionsmodell und im Tobit Modell wird üblicherweise vorausgesetzt, dass der Fehlerterm einem White Noise Prozess entspricht. Ein Prozess der Gestalt

$$y_t = \mu + \varepsilon_t + \theta \varepsilon_{t-1}$$

wird Moving Average Prozess der Ordnung Eins, oder MA(1)-Prozess genannt, wobei μ und θ Konstanten entsprechen. Der Wert des Prozesses zum Zeitpunkt t ergibt sich also aus einer Konstanten - seinem Mittelwert μ - und einer gewichteten Summe der zwei letzten Werte eines White Noise Prozesses. Daher stammt auch der Name Moving Average.

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Der obige Prozess bezieht noch mehr vergangene Werte eines White Noise Prozesses in die gewichtete Summe mit ein und wird als MA(q)-Prozess bezeichnet. Ein derartiger Prozess ist für alle reellen Werte von $(\theta_1, \theta_2, \dots, \theta_q)$ schwach stationär. Ein weitere wichtige Prozessklasse sind autoregressive Prozesse.

$$y_t = c + \phi_1 y_{t-1} + \varepsilon_t$$

Die obige Gleichung beschreibt ein autoregressives System. Ein stationärer Prozess, welcher diese Gleichung für alle betrachteten Zeitpunkte $t \in \mathbb{Z}$ erfüllt, wird als AR(1)-Prozess bezeichnet. Der Wert der Variablen zum Zeitpunkt t setzt sich aus seiner eigenen Vergangenheit, einer Konstanten und einem Fehlerterm zusammen, welcher wie gehabt einen White Noise Prozess darstellt. Ein AR(p)-Prozess ist eine stationäre Lösung des folgenden Systems

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

Bei autoregressiven Systemen ist die Frage nach der Existenz einer stationären Lösung nicht so leicht zu beantworten wie bei Moving Average Prozessen und hängt eng mit dem Koeffizienten-Vektor $(\phi_1, \phi_2, \dots, \phi_p)$ zusammen. Diese Eigenschaft überträgt sich auf Autoregressive Moving Average Prozesse [ARMA], welche folgendermaßen charakterisiert sind

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

ARMA(p, q)-Prozesse stellen eine Kombination der beiden vorhergehenden Ideen dar. Der Prozess lässt sich jedoch auch alternativ darstellen, mit Hilfe des Backshift-Operators für stochastische Prozesse. Hierbei handelt es sich um einen Filter. Filter sind Funktionen, welche, vereinfacht gesagt, Prozesse auf Prozesse abbilden. Der Backshift-Operator ist ein besonders einfacher Filter und folgendermaßen definiert.²⁹

$$B y_t = y_{t-1}, \quad B^k y_t = y_{t-k}$$

Der Operator kann im Folgenden mit den üblichen algebraischen Rechenregeln behandelt werden. Mit diesem Konzept lässt sich ein ARMA(p, q)-Prozess äquivalent durch die folgende Gleichung charakterisieren.

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) y_t = c + (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \varepsilon_t$$

Der Backshift-Operator kann auch verwendet werden um Differenzen eines Prozesses zu notieren.

$$(1 - B)y_t = y_t - y_{t-1}, \quad (1 - B)^2 y_t = y_t - 2y_{t-1} + y_{t-2}, \quad \dots$$

In Abschnitt 3.1 wurden Integrierte Prozesse vorgestellt. Die d -ten Differenzen eines integrierten Prozesses der Ordnung d sind stationär, wodurch ebensolche Prozesse existieren, welche sich durch ein ARMA(p, q)-Modell beschreiben lassen.

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d y_t = c + (1 + \theta_1 B + \dots + \theta_q B^q) \varepsilon_t$$

Ein stationärer Prozess, welcher die obigen Gleichung erfüllt, wird somit als ARIMA(p, d, q)-Prozess bezeichnet, wobei das I für Integrated steht. Bei d handelt es sich um den Integrationsgrad des zugrunde liegenden Prozesses. In der Praxis wird dieser üblicherweise durch sukzessive Einheitswurzeltests

²⁹Die Notation in diesem Zusammenhang ist etwas schlampig.

bestimmt. ARIMA-Modelle sind in der Lage eine Vielzahl an Prozessen zu beschreiben. Jedoch existieren Anwendungen, welche das Modellieren einer saisonalen Komponente erfordern, was zu Seasonal-ARIMA, also SARIMA-Modellen führt.

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps})(1 - B)^d(1 - B^s)^D y_t = c + (1 + \theta_1 B + \dots + \theta_q B^q)(1 + \Theta_1 B^s + \dots + \Theta_Q B^{Qs}) \varepsilon_t$$

Die zusätzlichen saisonalen Terme werden lediglich mit den vorhandenen multipliziert. Das Modell lässt sich als $ARIMA(p, d, q)(P, D, Q)_s$ notieren. Der saisonale Teil lässt sich analog zum Vorhergehenden interpretieren, wobei der Backshift-Operator lediglich zu Vielfachheiten der saisonalen Periode auftritt, welche hier als s bezeichnet wird.

SARIMA-Modelle sind eine weitreichende Modellklasse mit einer Fülle an möglichen Anwendungen. Auch wenn Zeitreihen der Realität üblicherweise nicht durch einen derartigen Prozess erzeugt werden, liefern sie oft gute Approximationen an den datengenerierenden Prozess und ermöglichen dadurch unter anderem Prognosen beziehungsweise Benchmarks für Prognosen anderer Modelle.

3.6.2 Prognose

Zur Modellierung der Abrufmengen von Regelenergie wird ein SARIMA-Modell verwendet. Dafür wurden die R-Funktionen *Arima* und *auto.arima* des Pakets *forecast* verwendet (16). Hiermit wurden alle möglichen Modelle bis zu einer gewissen Ordnung über dem gesamten Datensatz geschätzt und anhand von AIC gegenübergestellt. Die Ordnung setzt sich in diesem Kontext aus der Summe der Ordnungen sämtlicher Teile des Prozesses zusammen - in der obigen Notation entspricht dies der Summe aus p , q , P und Q . Als maximale Ordnung für jedes Modell wurde Zehn festgelegt. Die Länge der saisonalen Periode wurde auf 96 fixiert. Aufgrund der Ergebnisse der Einheitswurzel-Tests in vorhergehenden Abschnitten, wurde jeweils für die Zeitreihe und die ersten Differenzen der Zeitreihe ein Modell geschätzt. Tests auf saisonale Einheitswurzeln im Prozess, welche durch *auto.arima* aufgerufen werden, ergeben stets ein negatives Ergebnis, weshalb keine saisonalen Differenzen in der Modellierung berücksichtigt wurden.

Nach der Bestimmung der Ordnungen für jedes Modell wurde das bereits vorgestellte Kreuzvalidierungsverfahren angewendet. Die Modelle - genauer gesagt die Koeffizienten der Modelle - wurden jeweils auf 11 Monaten des Datensatzes geschätzt. Anschließend wurden auf dem verbliebenen Monat Prognosen für verschiedene Schrittweiten berechnet und evaluiert. Die Ergebnisse sind der folgenden Tabelle zu entnehmen.

RMSE		Positive Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
SARMA	7,56	9,76	10,28	10,52	10,92	11,17	11,26	11,31	11,43	11,52	11,56	11,60	11,65	11,69	11,73	11,76
SARIMA	7,48	9,70	10,26	10,53	10,88	11,10	11,21	11,27	11,38	11,46	11,51	11,55	11,60	11,64	11,68	11,72
MAE		Positive Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
SARMA	4,85	6,55	6,98	7,17	7,56	7,80	7,90	7,96	8,09	8,20	8,25	8,29	8,35	8,40	8,43	8,46
SARIMA	4,81	6,43	6,83	7,01	7,31	7,50	7,60	7,66	7,76	7,84	7,90	7,94	7,99	8,03	8,06	8,09
RMSE		Negative Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
SARMA	8,23	10,68	11,55	12,04	12,83	13,25	13,44	13,56	13,78	13,94	14,02	14,09	14,18	14,25	14,30	14,34
SARIMA	8,98	11,89	12,69	12,87	13,59	14,26	14,57	14,64	14,72	14,93	15,17	15,32	15,31	15,32	15,45	15,63
MAE		Negative Regelenenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
SARMA	5,42	7,28	7,92	8,30	9,01	9,40	9,59	9,71	9,92	10,08	10,15	10,22	10,30	10,37	10,41	10,45
SARIMA	6,07	8,27	8,81	8,89	9,46	9,97	10,21	10,26	10,32	10,48	10,67	10,8	10,78	10,78	10,89	11,05

Tabelle 3.11: Evaluationskriterien der Prognose mit einem SARIMA-Modell für positive und negative Regelenenergie

Die Ergebnisse sind ausschließlich schlechter als beim linearen Regressionsmodell und beim Tobit Modell. Mit steigendem Prognosehorizont nähern sich die Evaluationskriterien den Werten der erwähnten Alternativen. Allerdings deutet dies wohl auf die mangelnde Prognosefähigkeit der verschiedenen Modellansätze hin. Überraschenderweise schneidet bei positiver Regelenenergie die Vorhersage der Zeitreihe in Differenzen besser ab als die der Untransformierten, jedoch nur marginal. Es ist zu erwähnen, dass es sich beim Parameterschätzer des SARIMA-Modells bei Abrufmengen negativer Regelenenergie nicht um den üblichen ML-Schätzer handelt. Aufgrund von Problemen mit Optimierungsalgorithmen in R konnten die Parameter dieser Modellspezifikation für einige Monate bei der Kreuzvalidierung nur mit Hilfe von Conditional Sum of Squares geschätzt werden.

Der Anteil der korrekt prognostizierten Null-Aufrufe ist der Tabelle auf Seite 65 zu entnehmen. Hierbei kann sich die Prognose der Zeitreihe in Differenzen ein weiteres Mal und deutlicher abheben. Insbesondere bei Abrufmengen negativer Regelenenergie wird hierdurch eine deutliche Verbesserung erzielt. Dies kann unter anderem durch die erwähnte alternative Schätzmethode begründet sein. Es ist zu erwarten, dass die Modellierung durch ein SARIMA-Modell aufgrund der Vernachlässigung exogener Einflussfaktoren gewisse Nachteile birgt. Um dies zu berücksichtigen würde sich ein SARIMAX-Modell anbieten. Hierbei würden sowohl exogene Faktoren als auch Struktur im Fehlerterm berücksichtigt werden.

Nullen – Anteil in Prozent	Positive Regelenergie															
	Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
SARMA	9,55	2,77	0,99	0,55	0,30	0,14	0,09	0,04	0,01	0	0	0	0	0	0	0
SARIMA	24,44	15,73	9,61	4,88	4,36	3,82	2,76	1,43	0,83	0,64	0,40	0,19	0,10	0,04	0,01	0
Nullen – Anteil in Prozent	Negative Regelenergie															
	Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
SARMA	13,27	6,06	2,04	0,87	0,28	0,06	0	0	0	0	0	0	0	0	0	0
SARIMA	28,43	22,83	19	16	14,74	14,19	13,34	12,45	12,06	11,89	11,86	11,45	11,34	11,04	10,79	10,69

Tabelle 3.12: Anteil der korrekt prognostizierten Null-Aufrufe für das SARIMA-Modell - positive und negative Regelenergie

Zuzüglich ist zu erwähnen, dass systematische Probleme in die Prognose der Abrufmengen von Regelenergie durch einen SARIMA-Prozess miteinfließen. Die gewählte Obergrenze für die Summe der Ordnungen ist mit Zehn womöglich zu niedrig gesetzt um das Benehmen der Zeitreihe adäquat vorherzusagen. Außerdem entsteht ein Problem durch das verwendete Kreuzvalidierungsverfahren. Wird ein Monat bei der Schätzung des Modells ausgeschlossen und anschließend zur Evaluation verwendet, so wird das Modell in manchen Fällen auf einer diskontinuierlichen Zeitreihe geschätzt. Diese Sprünge können zu einer schlechteren Schätzung der Parameter und somit zu einer Benachteiligung für die Prognose mit Hilfe eines SARIMA-Prozesses führen.

3.6.3 Evaluation der Modellannahmen

In diesem Abschnitt soll überprüft werden, ob die geschätzten Modelle die üblichen Annahmen eines SARMA-Prozesses erfüllen. Die Lösungen der Gleichungen in Abschnitt 3.6.1 sind stochastische Prozesse und besitzen gewisse Eigenschaften. Diese Gleichungen lassen sich auch mit Hilfe von Backshift-Operatoren, also Filtern darstellen. Beispielsweise lässt sich der autoregressive Teil eines ARMA-Prozesses folgendermaßen als Filter notieren.

$$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$$

Dies entspricht einem endlichen Filter, also einem Filter mit endlich vielen Koeffizienten (ϕ_1, \dots, ϕ_p) . Mit dieser Schreibweise lässt sich die charakterisierende Gleichung eines SARIMA-Modells folgendermaßen abkürzen.

$$\phi(B)\Phi(B^s)(1 - B)^d(1 - B^s)^D y_t = \theta(B)\Theta(B^s)\varepsilon_t$$

Die entsprechenden Differenzen $x_t = (1 - B)^d(1 - B^s)^D y_t$ eines SARIMA-Prozesses bilden einen ARMA-Prozess der Ordnung $(p + sP, q + sQ)$, bei wel-

chem einige Koeffizienten Null entsprechen. Deswegen kann zur Evaluation der Modellannahmen eines SARIMA-Prozesses der theoretische Kontext für ARMA-Prozesse herangezogen werden. Die entsprechenden Resultate ergeben sich dann aus dem beschriebenen Zusammenhang, die Ausführungen hierzu folgen Brockwell und Davis (2013).

Die z -Transformation eines Filters entspricht seiner Darstellung als Potenzreihe einer komplexen Zahl $z \in \mathbb{C}$ anstatt des Backshift-Operators. Dies entspricht einem komplexwertigen Polynom. Die z -Transformationen der Filter eines ARMA-Systems besitzen die folgenden Gestalt.

$$\begin{aligned}\phi(z) &= (1 - \phi_1 z - \dots - \phi_p z^p) \\ \theta(z) &= (1 + \theta_1 z + \dots + \theta_p z^p)\end{aligned}$$

Die Nullstellen dieser Polynome sind komplexe Zahlen und maßgeblich für die Eigenschaften von ARMA-Prozessen. Ein ARMA-System besitzt eine eindeutige stationäre Lösung, falls $\phi(z) \neq 0 \forall |z| = 1$ gilt, also falls das AR-Polynom keine Nullstelle am komplexen Einheitskreis besitzt. Falls sogar $\phi(z) \neq 0 \forall |z| \leq 1$ gilt, also keine Nullstelle innerhalb des Einheitskreises liegt, so besitzt die Lösung des ARMA-Systems eine Darstellung als kausaler MA(∞)-Prozess. Falls zusätzlich $\theta(z) \neq 0 \forall |z| \leq 1$ gilt, dann besitzt die Lösung eine AR(∞)-Darstellung.

Eine übliche Schätzmethode für ARMA-Systeme ist die Maximum-Likelihood-Schätzung [ML]. Diese Methode wurde auch für die erstellten Prognose-Modelle verwendet. Dabei muss eine Verteilung für den White Noise Term des ARMA-Systems angenommen werden, was in den meisten Fällen der Normalverteilung entspricht. Mit dieser Annahme ist die Likelihood-Funktion eines ARMA-Systems, beziehungsweise die Log-Likelihood, folgendermaßen charakterisiert.

$$\ell(\phi, \theta, \sigma^2) = -\frac{T}{2}(\log(2\pi) + \log(\sigma^2)) - \sum_{t=1}^T \frac{\varepsilon_t^2}{2\sigma^2}$$

Der Parametervektor (ϕ, θ, σ^2) welcher die Funktion für die gegebenen Daten maximiert, wird ML-Schätzer genannt. Wie der OLS-Schätzer hat auch dieser gewisse Eigenschaften. Sei ein ARMA-System gegeben, welches zusätzlich zu den bereits angeführten Annahmen erfüllt, dass die Polynome $\phi(z)$ und $\theta(z)$ keine gemeinsamen Nullstellen haben, sowie der Fehlerterm unabhängig und identisch normalverteilt mit Varianz σ^2 ist. Dann ist der ML-Schätzer konsistent und asymptotisch normalverteilt. Dieses Resultat bleibt im Übrigen auch für andere Verteilungen der Fehler gültig, solange sie *i.i.d.* sind. Das Modell für die Prognose von Abrufmengen positiver Regelenergie ist auf Seite 67 dargestellt. Die Schätzung basiert hierbei auf dem gesamten Datensatz.

Die linken Werte beziehen sich auf die Schätzer der Koeffizienten, die Zahlen in Klammern auf die geschätzte Standardabweichung der entsprechenden Koeffizientenschätzer. Die AR-Koeffizienten weisen deutliche Unterschiede zu den Koeffizienten der gelagten Werte beim linearen Regressionsmodell auf, welches in Abschnitt 3.4.4 zu finden ist. Der erste Koeffizient ist kleiner als zuvor und die ersten drei weisen höhere Schätzer für die assoziierte Standardabweichung vor. Die R-Funktion *Arima* betrachtet bei der Schätzung lediglich Parameter, welche den oben gestellten Bedingungen an die entsprechenden Polynome genügen. Dadurch sind lediglich die Annahmen an den Fehlerterm zu überprüfen.

	Koeffizienten
AR	
ar1	0,37 (0,07)
ar2	0,11 (0,06)
ar3	0,04 (0,04)
ar4	0,22 (0,01)
ar5	-0,06 (0,02)
ar6	-0,02 (0,01)
ar7	0,00 (0,01)
ar8	0,08 (0,01)
MA	
ma1	0,42 (0,11)
SAR	
sar1	0,03 (0,12)
Mittelwert	
(Intercept)	7,33 (0,24)
AIC	243102,03
AICc	243102,04
BIC	243203,60
Log Likelihood	-121539,01

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$

Tabelle 3.13: SARMA(8, 0, 1)(1, 0, 0)₉₆: Positive Regelenergie

Abbildung 3.17 beinhaltet einen Plot, ein Histogramm, die ACF und Boxplots der Tageszeiten der Residuen des angeführten Modells. Das Histogramm beinhaltet eine große Menge an Ausreißern, ein Jarque-Bera- und ein Pearson-Test verwerfen die Nullhypothese der Normalverteilung zu dem üblichen Signifikanzniveau von 5% (22, 19). Aus der ACF wird ersichtlich, dass die *i.i.d.*-Annahme nicht erfüllt ist. In den Boxplots ist erkennbar, dass die Streuung der Residuen wieder mit der Tageszeit schwankt, allerdings erscheint sie auch insgesamt breiter als beim linearen Regressionsmodell. Aufgrund dieser Tatsachen sollte nicht von der Konsistenz des ML-Schätzers ausgegangen werden.

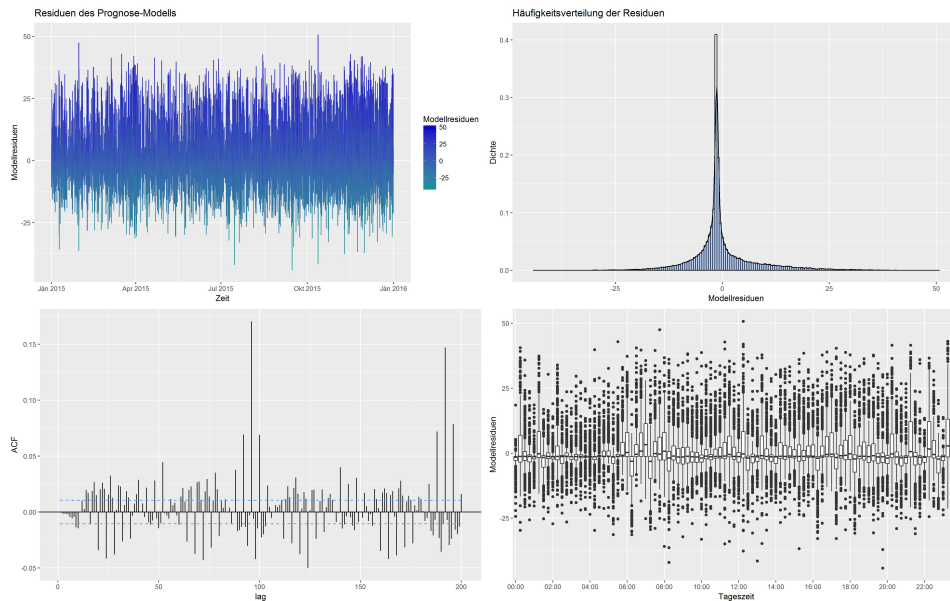


Abbildung 3.17: Residuen des SARMA(8, 0, 1)(1, 0, 0)₉₆ Modells: Abrufmengen positiver Regelenergie

Abrufmengen von Regelenergie werden klarerweise nicht durch ein ARMA System generiert. Allerdings liefern Prognosen durch ein derartiges Modell vergleichbare Ergebnisse zu den vorgestellten Resultaten eines linearen Regressionsmodells. Jedoch benötigt man für die Modellierung des Prozesses keinerlei exogene Variable, wodurch sich eine einfachere Modellstruktur ergibt und somit weniger Annahmen gestellt werden müssen. Das SARMA Modell für Abrufmengen negativer Regelenergie ist im Appendix zu finden. Abbildung A.9 ist eine Darstellung der entsprechenden Modellresiduen. Aus dem Plot ist ersichtlich, dass bei dem genannten Modell ebenfalls Annahmen verletzt sind, wodurch gleichermaßen nicht von der Konsistenz der Parameterschätzer ausgegangen werden kann.

Alle bisher vorgestellten Modelle postulieren einen linearen Zusammenhang zwischen Abrufmengen und erklärenden Variablen. Des Weiteren werden stets Parameter geschätzt um die genannten Abhängigkeiten zu beschreiben. Um weitere Relationen aufzudecken, beziehungsweise zu modellieren, soll im Folgenden eine Variante des Nearest Neighbour Verfahrens auf die Daten angewendet werden.

3.7 Nearest Neighbour Regression

Nearest Neighbour Regression ist ein nicht-parametrisches Verfahren zur Prognose von metrischen Daten, welches zu Machine Learning gezählt wird. Es leitet sich von Nearest Neighbour Algorithmen ab. Dabei werden Beobachtungen einer Variablen in Abhängigkeit von anderen Variablen gesetzt, was sich analog zu einem Regressionsmodell darstellen lässt - eine Beobachtung der abhängigen Variable wird jeweils einem Datenvektor an Kovariaten zugeordnet. Dies geschieht auf einem Trainings- oder Lerndatensatz. Werden nun neue Beobachtungen der unabhängigen Variablen verfügbar so werden die „nächsten Nachbarn“ dieser Einträge gesucht. Diese Nachbarn sind Datenvektoren unabhängiger Variablen aus dem Trainingsdatensatz, welche eine hohe Ähnlichkeit zu den neuen Beobachtungen aufweisen. Diese Ähnlichkeit wird durch eine Abstandsfunktion oder Metrik ermittelt. Dadurch lassen sich die „nächsten Nachbarn“ und die zugehörigen Werte der abhängigen Variablen aus dem Lerndatensatz berechnen. Eine Funktion dieser Beobachtungen bildet die Schätzung für den unbekanntem Wert der abhängigen Variablen der neuen Beobachtungen.

Im Prinzip versucht das Verfahren Prognosen zu erstellen indem neue erklärende Variablen mit alten verglichen werden. Dabei wird davon ausgegangen, dass Ähnlichkeiten der unabhängigen Variablen mit Ähnlichkeiten der abhängigen Variablen koinzidieren. Es handelt sich, wie erwähnt, um ein parameterfreies Verfahren, allerdings sind gewisse Rahmenbedingungen festzulegen, welche im nächsten Abschnitt näher erläutert werden. Das Nearest Neighbour Verfahren eignet sich besonders zur Prognose von unabhängig identisch verteilten Daten wie Mikrodaten von Haushalten. Hierbei wird davon ausgegangen, dass ähnliche Situationen in verschiedenen Umgebungen zu ähnlichen Ergebnissen führen. Das Verfahren würde sich hier bei der Prognose an den Haushalten mit den ähnlichsten Voraussetzungen orientieren, was intuitiv sinnvoll scheint. Im Kontext von Zeitreihenanalysen wird oft eine Autokorrelationsstruktur der Prozesse modelliert, welche bei der Prognose wie bisher durch gelaggte Werte der abhängigen Variable in dem Vektor der erklärenden Variablen erfasst werden soll. Das Verfahren wurde zur Modellierung von Abrufmengen von Regelenergie ausgewählt, da die bisherigen Methoden ausschließlich eine lineare Abhängigkeitsstruktur der Variablen beziehungsweise ihrer Transformationen abbilden.

Ein RESET-Test nach Ramsey prüft ob nichtlineare Kombinationen von erklärenden Variablen Einfluss auf die abhängige Variable haben. Die Anwendung der Funktion `resettest` des R-Pakets `lmtest` auf die linearen Regressionsmodelle der Ein-Schritt-Prognose liefert ein signifikantes Ergebnis

(18). Die Modellierung der Daten durch ein Verfahren, welches keine lineare Abhängigkeitsstruktur postuliert erscheint somit sinnvoll.

3.7.1 Das Modell

Die Ausführungen zum Nearest Neighbour Verfahren folgen hier Hechenbichler und Schliep (2004). Dabei wird eine abhängige Variable mit einer Menge an unabhängigen Variablen oder Regressoren assoziiert und als Paar (y_t, X_t) betrachtet. X_t entspricht hier formal einem Zeilenvektor. Die Zuordnungen von y_t zu X_t sind auf einem Testdatensatz bekannt. Anschließend sollen durch neue Werte von X_t die zugehörigen Werte der abhängigen Variablen prognostiziert werden. Formal lässt sich dies folgendermaßen notieren: Sei L die Menge an bekannten Paaren (y_t, X_t) des Lerndatensatzes. Also

$$L = \{(y_t, X_t), t = 1, \dots, T_1\}$$

Für ein neues X_{neu} aus dem zu prognostizierendem Datensatz wird nun der nächste Nachbar des Lerndatensatzes gesucht. Dieser wird durch eine Abstandsfunktion $d(.,.)$ ermittelt.

$$d(X_{neu}, X_{NN}) = \min_{t=1, \dots, T_1} d(X_{neu}, X_t)$$

Handelt es sich bei den Daten um reelle Zahlen, so können bekannte Abstandsmaße wie die durch die euklidische Norm induzierte Metrik verwendet werden. Allgemeiner eignen sich beispielsweise Minkowski-Distanzen. Für $p = 2$ entspricht dies der euklidischen Metrik.

$$d(X_i, X_j) = \left(\sum_{n=1}^N |X_{i,n} - X_{j,n}|^p \right)^{\frac{1}{p}}$$

Sind die Daten nominal- oder ordinalskaliert, können Dummies verwendet werden. Ferner muss festgelegt werden, wie viele Nachbarn ermittelt werden sollen. Wird nur einer verwendet, so ist die damit assoziierte abhängige Variable gleichzeitig die Prognose für den neuen Datenvektor. Eine Erweiterung hiervon ist die sogenannte k -Nearest Neighbour Methode. Hierbei werden die k nächsten Nachbarn im Sinne der verwendeten Metrik ermittelt. Eine Funktion der entsprechenden Werte der abhängigen Variablen wird anschließend als Prognose verwendet. Ist die abhängige Variable nominal, so kann die häufigste Klasse der abhängigen Variablen der k nächsten Nachbarn als Prognose verwendet werden. Hierbei handelt es sich um ein Klassifizierungsproblem. Ist die abhängige Variable metrischer Natur, so spricht man von Nearest Neighbour Regression. Hierbei kann beispielsweise ein Durchschnitt der entsprechenden Werte der abhängigen Variablen des Lerndatensatzes als Prognose verwendet werden.

Das beschriebene Verfahren lässt sich durch eine Gewichtung erweitern, sodass bei der Prognose besonders ähnliche Nachbarn stärker berücksichtigt

werden. Zu diesem Zweck kann es sinnvoll sein, jedem Eintrag des Datenvektors X_t durch geeignetes Standardisieren dasselbe Gewicht zu verleihen. Für nominal- und ordinalskalierte Variablen eignen sich Dummies, welche anschließend durch geeignete Schätzer der entsprechenden Standardabweichung dividiert werden. Dadurch wird unter anderem verhindert, dass erklärende kategoriale Variable, welche mehr Klassen umfassen, stärker ins Gewicht fallen. Metrische Variable können zur Standardisierung durch eine Schätzung ihrer Standardabweichung dividiert werden. Das Standardisieren von erklärenden Variablen ist immer sinnvoll und wird im Kontext von gewichteter k -Nearest Neighbour Regression oft explizit empfohlen. Für eine ausführlichere Beschreibung siehe Hechenbichler und Schliep (2004).

Um Abstände zwischen standardisierten erklärenden Variablen des Lerndatensatzes und neuen Beobachtungen zu Gewichten zu transformieren, wird eine Kern-Funktion $K(\cdot)$ verwendet. Die wesentlichen Eigenschaften einer derartigen Funktion umfassen die folgenden Punkte.

$$K(d) \geq 0, \quad \arg \max_{d \geq 0} K(d) = 0,$$

$$K(d) \text{ fällt monoton in } d \text{ und } \lim_{d \rightarrow \infty} K(d) = 0$$

Beispiele für solche Funktionen sind ein Rechteckskern $\frac{1}{2} \mathbb{1}(|d| \leq 1)$, welcher alle Nachbarn gleich gewichtet, oder die Dichte einer Standardnormalverteilung. Da Distanzen lediglich nichtnegative Werte annehmen ist der positive Definitionsbereich der Kern-Funktionen ausreichend. Für eine gegebene Beobachtung X_{neu} sei $X_{(k+1)}$ der erste Nachbar, welcher nicht mehr in die Schätzung miteinfließt. Die Distanzen der k nächsten Nachbarn werden folgendermaßen transformiert.

$$D(X_{neu}, X_{(i)}) = \frac{d(X_{neu}, X_{(i)})}{d(X_{neu}, X_{(k+1)})} \quad i = 1, \dots, k$$

Diese standardisierten Distanzen nehmen Werte auf $[0, 1]$ an. Eine Kern-Funktion der Werte liefert schließlich Gewichte für die Schätzung.

$$\hat{y}_{neu} = \frac{\sum_{i=1}^k K(D(X_{neu}, X_{(i)})) y_{(i)}}{\sum_{i=1}^k K(D(X_{neu}, X_{(i)}))}$$

Dieser Schätzer wird als Nadaraya-Watson-Schätzer bezeichnet und bildet den Schnittpunkt dieses Verfahrens zu LOESS Regression. Das Ziel dieser gewichteten k -Nearest Neighbour Regression ist unter anderem, dass eine suboptimale Wahl von k nicht zu einer wesentlichen Verschlechterung der Ergebnisse führt. Durch die verwendete Gewichtung wird ein überschätztes k implizit auf einen niedrigeren Wert reduziert, indem ähnliche Werte stärker in die Schätzung einfließen.

Die gefitteten Werte bei der Modellierung der vorgestellten k -Nearest Neigh-

bour Regression, ergeben sich aus einer Linearkombination der Abrufmengen, jedoch werden diese Werte durch ein nicht lineares Vergleichsverfahren ausgewählt. Hierdurch können eventuell Zusammenhänge aufgedeckt werden, welche durch die bisher vorgestellten Modelle und deren Spezifikationen nicht registriert wurden. Die „Parameter“ des Verfahrens sind die Anzahl der betrachteten Nachbarn k , die Distanzfunktion beziehungsweise p und die Kern-Funktion $K(\cdot)$. Für p wird im Folgenden stets 2 verwendet.

3.7.2 Einfluss der Variablen im Modell

Der Einfluss verschiedener Variablen im Kontext von gewichteter k -Nearest Neighbour Regression wird analog zum Bisherigen untersucht. Das Verfahren wird für jede Variable und für jeden Monat im Rahmen eines Kreuzvalidierungsverfahrens durchgeführt. Die unabhängigen Variablen in der Regressionsgleichung beziehungsweise Schätzgleichung des gewichteten k -Nearest Neighbour Verfahrens entsprechen den Variablen bei der Messung des Einflusses im linearen Regressionsmodell. Da in diesem Kontext kein Pendant zu AIC existiert, wurde die Anzahl der Lags durch ein Leave-One-Out-Kreuzvalidierungsverfahren des gesamten Datensatzes bestimmt, wobei RMSE als Evaluationskriterium verwendet wurde. Dabei wurde ebenfalls die optimale Anzahl an Nachbarn festgelegt, die Obergrenze hierfür ist mit 15 gesetzt. Als Optimum ergeben sich ein gelagter Wert jeder Variablen und 15 Nachbarn. Des Weiteren wurde auch über die verwendeten Kernfunktionen variiert, wobei „optimal“ ausgewählt wurde.³⁰ Bei der Messung des Einflusses verschiedener Variablen ergeben sich wiederum RMSE- beziehungsweise MAE-Werte, welche in den Abbildungen auf der Seite 73 dargestellt sind. Tabellen mit exakten Werten finden sich im Appendix.

Die resultierenden Werte sind hier im Schnitt höher als bei anderen Modellen. Allerdings lassen sich wieder dieselben Variablen als einflussreich identifizieren, nämlich: Ungewollter Stromaustausch, -import bei positiver Regelenergie, -export bei negativer sowie der Windprognosefehler und dahinter die Einspeisung durch Windenergie. Allerdings erscheint in diesem Kontext der Effekt von ungewolltem Stromimport auf negative Regelenergie sowie der Effekt von ungewolltem Stromexport auf positive vergleichsweise größer. Die Schätzung erfolgt hier und bei der Prognose mit Hilfe der R-Funktion *kknn* des Pakets *kknn* (17).

³⁰Die Kern-Funktion „optimal“ der R-Funktion *kknn* wird beispielsweise in Samworth (2012) exakter beschrieben.

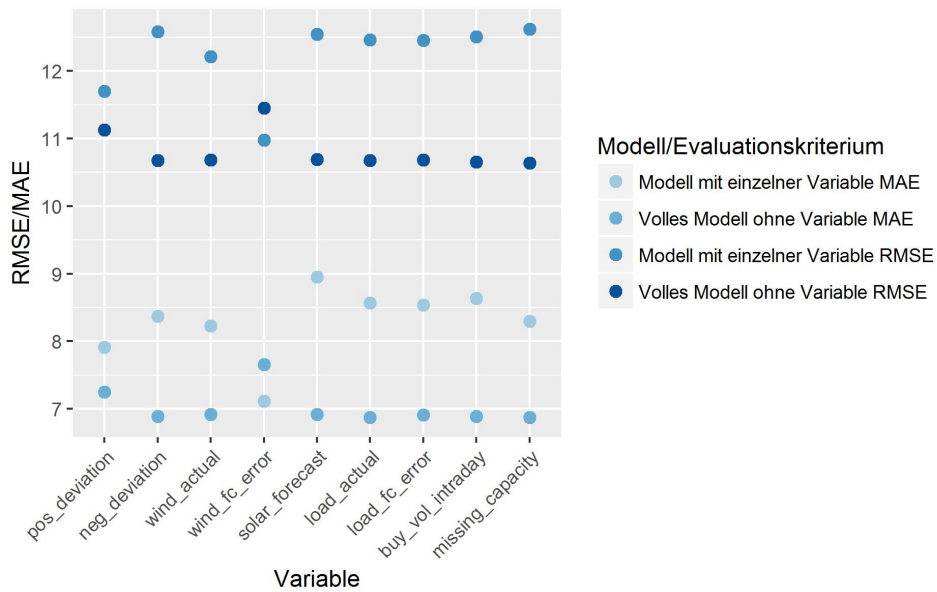


Abbildung 3.18: RMSE/MAE-Vergleich gemittelt: Einfluss der Variablen: Gewichtete k -Nearest Neighbour Regression - abgerufene positive Regelernergie




Abbildung 3.19: RMSE/MAE-Vergleich gemittelt: Einfluss der Variablen: Gewichtete k -Nearest Neighbour Regression - abgerufene negative Regelernergie

3.7.3 Prognose

Auch die Prognose verläuft analog zu den anderen Modellen. Bei der Auswahl der Variablen für die h -Schritt Prognose wurden die vom linearen Regressionsmodell durch AIC ausgewählten Variablen verwendet. Um die optimale Anzahl an Nachbarn beziehungsweise die optimale Kern-Funktion zu bestimmen, wurde wiederum ein Leave-One-Out-Kreuzvalidierungsverfahren über den gesamten Datensatz durchgeführt. Als Evaluationskriterium wurden RMSE-Werte verglichen. Daraus ergeben sich für jeden Prognosehorizont eine in diesem Sinne optimale Anzahl an Nachbarn sowie die passende Kern-Funktion. Meist handelt es sich hierbei um 15 verwendete Nachbarn und stets um den „optimal“-Kern der R-Funktion *kknn*. Diese wurden anschließend für das bekannte Kreuzvalidierungsverfahren der Prognose verwendet.

Ein bekanntes Problem bei k -Nearest Neighbour Regression ist die Dimension der unabhängigen Variablen X_t wie beispielsweise in Beyer et al. (1999) beschrieben wird. Unter sehr allgemeinen Voraussetzungen konvergiert bei einer hohen Anzahl an verwendeten Merkmalen die euklidische Distanz zum nächsten Nachbarn gegen die Distanz zum fernsten Datenpunkt. Der Vergleich der Abstände zu verschiedenen Nachbarn ist hierdurch nur mehr bedingt sinnvoll beziehungsweise aussagekräftig. Werden also zu viele erklärende Variablen verwendet, so kann dies das Ergebnis des Verfahrens erheblich verschlechtern. Man spricht in diesem Zusammenhang auch von dem „Fluch der Dimensionalität“. Aus diesem Grund wurden bei der Prognose einige Alternativen zu dem bereits vorgestellten Ansatz implementiert.

Einmal wird auf die im Rahmen des linearen Regressionsmodells verwendeten Variablen eine Hauptkomponentenanalyse angewendet. Hier wird bei der Kreuzvalidierung jeweils auf elf Monaten des Datensatzes eine Hauptkomponentenanalyse der unabhängigen Variablen durchgeführt. Anschließend werden die Komponenten für das zwölfte, zu evaluierende Monat nach demselben Schema berechnet. Die zehn aussagekräftigsten Linearkombinationen werden anschließend als erklärende Variable für die Nearest Neighbour Regression verwendet. Hierfür wurde die R-Funktion *prcomp* des *stats*-Pakets verwendet (13).

Weiters werden bei einer alternativen Variante lediglich vergangene Werte der Zeitreihe selbst als erklärende Variable verwendet. Diese belaufen sich auf die letzten acht bekannten Werte sowie Werte mit einem zeitlichen Abstand von 96 und 97 Perioden. Schließlich wurde noch eine dritte Modifikation implementiert, bei welcher Regressionsmodelle mit den gewohnten Variablen geschätzt wurden. Anschließend werden im Rahmen der Kreuzvalidierung bei jedem linearen Regressionsmodell die zehn Variablen mit

den höchsten t -Werten ausgewählt und als erklärende Variable für das k -Nearest Neighbour Verfahren verwendet. Hierbei werden saisonale Dummies ausgeschlossen. Außerdem werden bei einer vierten Möglichkeit anstatt der üblichen Variablen die gefitteten Werte der entsprechenden linearen Regressionsmodelle als einziges Merkmal für das weitere Vorgehen verwendet. Die Ergebnisse sämtlicher Verfahren sind nun in der folgenden Tabelle zusammengefasst.

RMSE		Positive Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	8,98	10,21	10,70	11,00	11,26	11,39	11,50	11,61	11,70	11,77	11,85	11,89	11,94	11,97	12,00	12,03
Hauptk.-analyse	9,18	10,52	10,87	11,27	11,54	11,74	11,82	11,96	12,04	12,18	12,23	12,33	12,36	12,44	12,41	12,45
Vergangene Werte	7,98	10,18	10,73	11,01	11,45	11,71	11,79	11,87	12,02	12,12	12,17	12,22	12,25	12,31	12,34	12,37
t -Werte	7,85	10,04	10,73	11,22	11,60	11,88	11,90	12,10	12,20	12,25	12,34	12,44	12,48	12,54	12,57	12,63
Gefittete Werte	7,08	9,30	10,11	10,52	10,93	11,18	11,34	11,48	11,54	11,68	11,75	11,75	11,82	11,83	11,90	11,88
MAE		Positive Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	5,46	6,36	6,76	7,00	7,24	7,39	7,49	7,58	7,66	7,73	7,80	7,85	7,90	7,93	7,97	8,02
Hauptk.-analyse	5,83	6,88	7,09	7,44	7,63	7,86	7,93	8,06	8,07	8,24	8,26	8,35	8,34	8,46	8,45	8,50
Vergangene Werte	4,92	6,55	6,96	7,19	7,60	7,85	7,91	8,01	8,15	8,25	8,29	8,34	8,39	8,43	8,47	8,51
t -Werte	4,85	6,49	6,96	7,36	7,66	7,94	7,97	8,16	8,33	8,30	8,38	8,44	8,48	8,55	8,59	8,63
Gefittete Werte	4,33	5,96	6,56	6,89	7,25	7,47	7,61	7,74	7,84	7,93	7,99	8,04	8,08	8,12	8,18	8,18
RMSE		Negative Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	9,75	11,15	11,92	12,53	13,00	13,36	13,55	13,70	13,85	13,92	14,00	14,10	14,18	14,24	14,32	14,38
Hauptk.-analyse	10,35	11,57	12,31	12,86	13,40	13,81	14,00	14,13	14,25	14,51	14,48	14,60	14,72	14,89	14,88	14,89
Vergangene Werte	8,67	11,10	12,04	12,60	13,42	13,94	14,12	14,27	14,46	14,63	14,71	14,76	14,85	14,92	14,94	15,01
t -Werte	8,91	11,17	11,96	12,49	13,38	13,96	14,35	14,39	14,62	14,81	14,94	15,02	15,08	15,23	15,27	15,15
Gefittete Werte	7,40	9,62	10,83	11,66	12,38	12,89	13,22	13,42	13,56	13,71	13,86	13,97	14,02	14,08	14,12	14,18
MAE		Negative Regelenergie														
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Normal	6,14	7,12	7,65	8,07	8,41	8,66	8,82	8,95	9,09	9,19	9,26	9,34	9,43	9,48	9,54	9,60
Hauptk.-analyse	6,76	7,65	8,12	8,55	8,91	9,21	9,38	9,46	9,56	9,79	9,78	9,87	9,95	10,11	10,10	10,10
Vergangene Werte	5,50	7,34	8,00	8,41	9,06	9,49	9,66	9,79	9,96	10,10	10,17	10,22	10,30	10,38	10,40	10,47
t -Werte	5,71	7,41	7,93	8,28	8,97	9,42	9,72	9,74	9,93	10,11	10,16	10,22	10,27	10,40	10,41	10,34
Gefittete Werte	4,69	6,32	7,19	7,76	8,30	8,66	8,93	9,08	9,20	9,34	9,46	9,55	9,59	9,65	9,68	9,75

Die angeführten Fehlermaße sind ausschließlich höher als die niedrigsten des Tobit Modells und des linearen Regressionsmodells, wodurch keine Verbesserung der Prognose durch die angeführte Methode möglich ist. Unter den vorgestellten Varianten sticht die Verwendung der gefitteten Werte eines linearen Regressionsmodells als erklärende Variable hervor. Lediglich ab einem Prognosehorizont von sechs erzeugt das Grundverfahren niedrigere MAE-Werte.

Der Anteil der korrekt prognostizierten Nullen ist bei der gewichteten k -Nearest Neighbour Regression durchgängig sehr niedrig und wird deswegen an dieser Stelle nicht angeführt. Der Grund hierfür ist, dass Prognosewerte aus einem gewichteten Mittel der abhängigen Variablen gebildet werden. Enthält die Linearkombination zumindest einen Wert größer Null, so erfüllt auch der prognostizierte Wert diese Eigenschaft.

3.7.4 Evaluation der Modellannahmen

Der theoretische Hintergrund von k -Nearest Neighbour Verfahren wurde bereits umfangreich im Kontext von Klassifizierungsproblemen untersucht. Beispielsweise beschäftigt sich Samworth (2008) mit der optimalen Wahl der Gewichte bei einem Klassifizierungsproblem dieser Verfahrensklasse. Eine häufige Annahme im Kontext von Nearest Neighbour Verfahren ist die identische und unabhängige Verteilung der gegebenen Daten, was in einem Zeitreihenkontext unpassend scheint. Es gibt Arbeiten, welche sich mit gewichteter k -Nearest Neighbour Regression im Zusammenhang mit Zeitreihen beschäftigen, wie beispielsweise Guégan und Rakotomaroahy (2009). Hierbei wird allerdings beispielsweise die strikte Stationarität der involvierten Daten vorausgesetzt. Überlegungen hierzu finden sich in vorhergehenden Abschnitten dieser Arbeit, wobei diese Eigenschaft bei den gegebenen Zeitreihen nicht vorausgesetzt werden sollte, was das Verifizieren weiterer Annahmen redundant erscheinen lässt. In der Folge wird an dieser Stelle auf die Überprüfung weiterer Annahmen des Verfahrens verzichtet.

3.8 Zusammenfassung und Vergleich der Intraday-Prognosen

Im Rahmen dieser Arbeit werden vier Modellklassen auf Abrufmengen von Regelenergie angewendet. Für die entsprechenden Intraday-Prognosen wurden außerdem verschiedene Spezifikationen der jeweiligen Modelle geschätzt. Diese wurden im Rahmen eines Kreuzvalidierungsverfahrens anhand von RMSE- und MAE-Werten evaluiert. Eine Zusammenfassung jener Evaluationskriterien ist in Abbildung 3.20 für positive sowie in Abbildung 3.21 für negative Regelenergie zu finden. Hierbei wird auch die naive Prognose abgebildet, welche der Verwendung des letzten bekannten Wertes als Vorhersage entspricht.

Die besten Resultate im Sinne des RMSE werden sowohl für positive als auch für negative Regelenergie durch das Tobit Modell und das lineare Regressionsmodell erzielt. Bis zu einer Schrittweite von drei liefert das Tobit Modell, bei der Verwendung der Linearkombination aus den erklärenden Variablen als Vorhersagewert, das niedrigste Fehlermaß. Für einen größeren Prognosehorizont folgt zunächst das gewöhnliche lineare Regressionsmodell, mit der Zensierung bei Null, und schließlich das lineare Regressionsmodell, welches mit Hilfe von WLS geschätzt wird. Hierbei hebt sich die Spezifikation II ab.

Die niedrigsten MAE-Werte ergeben sich bei der Prognose ebenfalls für das lineare Regressionsmodell und für das Tobit Modell. Wiederum ist das Tobit Modell, mit der Spezifikation der linearen Prädiktoren, für Schrittweiten bis zu vier das Verfahren, welches am besten abschneidet. Für größere Prognosehorizonte liefert die Yeo-Johnson-Transformation im linearen Regressionsmodell und im Tobit Modell die niedrigsten Fehlermaße. Diese heben sich mit steigender Schrittweite deutlich von anderen Spezifikationen ab. Hier ist allerdings nochmals anzumerken, dass bei der entsprechenden Rücktransformation das globale Maximum der Zeitreihe als Obergrenze festgelegt wurde, was einer Zensierung der Ergebnisse entspricht.

Unter der Annahme, dass sich die Abrufmengen von Regelenergie in Österreich im Jahr 2016 ähnlich zum vorhergehenden Jahr verhalten, ermöglichen die Ergebnisse folgende Schlüsse: Versucht man die Abrufmengen an Regelenergie für die nächste Stunde vorherzusagen und ist die in dieser Arbeit beschriebene Datengrundlage gegeben, so wäre durch das Tobit Modell beispielsweise ein mittlerer absoluter Fehler von etwa 6,159 für positive sowie 7,025 für negative Regelenergie zu erwarten. Für andere Prognosehorizonte gilt Analoges.




Abbildung 3.20: 24 RMSE- und MAE-Werte für Intraday-Prognosen verschiedener Modellspezifikationen: Abrufmengen positiver Regelenergie

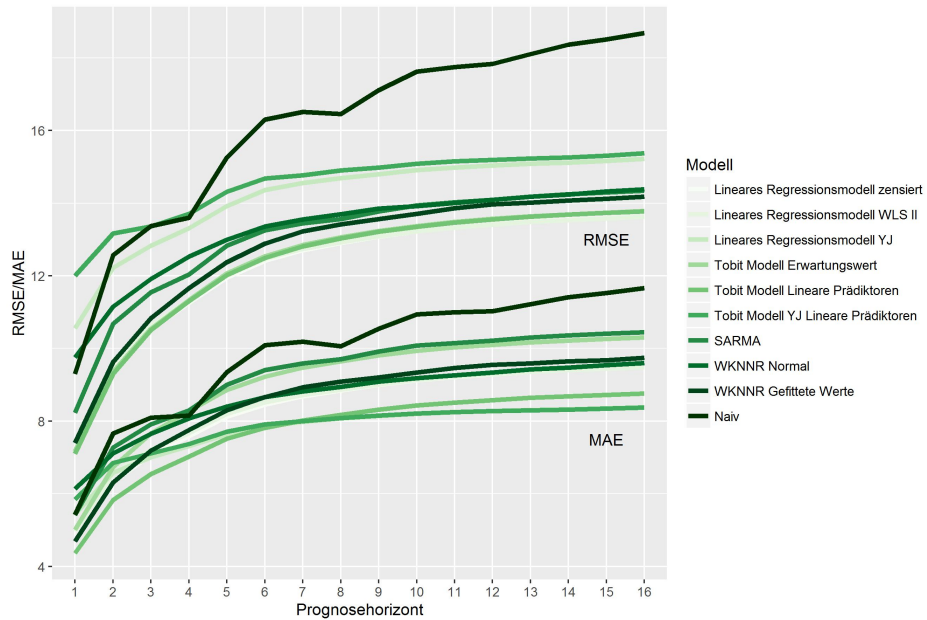


Abbildung 3.21: RMSE- und MAE-Werte für Intraday-Prognosen verschiedener Modellspezifikationen: Abrufmengen negativer Regelenergie

Null-Aufrufe werden ebenfalls durch das Tobit Modell am präzisesten beschrieben. Vorhersagen hiervon liefern bei einem Horizont von einer Stunde in etwa 61% der Fälle bei positiver beziehungsweise 55% bei negativer Regenergie das richtige Ergebnis. Ferner ist es möglich diese Thematik separat mit Hilfe eines Binary Response Modells zu behandeln.

Die RMSE-Werte der vielversprechendsten Modellspezifikationen liegen stets unter der empirischen Standardabweichung der Zeitreihen. Selbst für einen Prognosehorizont von vier Stunden sind durch die vorgestellten Modelle bessere Ergebnisse zu erzielen.³¹ Es ist jedoch zu erwähnen, dass die naive Prognose vergleichsweise gut abschneidet. Für kurze Prognosehorizonte liefert sie Fehlermaße, welche durchaus vergleichbar mit den geschätzten Modellen sind. Hierbei ergeben sich teilweise sogar niedrigere Werte. Mit steigender Schrittweite hebt sie sich dennoch negativ ab und erzeugt deutlich höhere RMSE- und MAE-Werte. Die exakten Evaluationskriterien der naiven Prognose sind im Appendix zu finden.

Ein wesentlicher Nachteil der in dieser Arbeit verwendeten Evaluationskriterien ist ihre Skalenabhängigkeit. Vorhersagen von Zeitreihen mit großen Einträgen erzeugen dementsprechend hohe RMSE- und MAE-Werte, auch bei präzisen Prognosen. Es existiert eine Fülle an Fehlermaßen, welche eine dimensionslose Beschreibung der Güte einer Vorhersage ermöglichen. Auch hierbei sollte man sich den Daten anpassen. Beispielsweise sollte ein Mean Absolute Percentage Error [MAPE] nicht bei Daten mit Nulleinträgen verwendet werden. Um den erstellten Prognosen der viel versprechendsten Modellspezifikationen ein derartiges Kriterium zuzuordnen, wird im Folgenden kurz der Index of Agreement [IOA] vorgestellt, wie er zum Beispiel in Willmott et al. (2012) zu finden ist. Die Grundidee hinter vielen derartigen dimensionslosen Fehlermaßen, einschließlich dem IOA, ist folgende. Sei d das entsprechende Evaluationskriterium mit der Form

$$d = 1 - \frac{\delta}{\eta}$$

δ bezeichnet in diesem Zusammenhang ein Maß der durchschnittlichen Fehlergröße und η eine Vergleichsbasis.³² Die ursprüngliche Form des IOA von Willmott verwendet für δ die Summe der quadrierten Prognosefehler und η entspricht der Summe aus den quadrierten absoluten Differenzen zwischen den Prognosen respektive beobachteten Werten und dem entsprechenden Mittelwert. Der Index wird im Folgenden als IOA_2 notiert.

$$IOA_2 = 1 - \frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{\sum_{t=1}^n (|\hat{y}_t - \bar{y}| + |y_t - \bar{y}|)^2}$$

³¹Die empirische Standardabweichung einer Zeitreihe lässt sich als RMSE der einfachen Prognose interpretieren, wo stets der Mittelwert verwendet wird.

³²Das Bestimmtheitsmaß einer linearen Regression folgt ebenfalls diesem Schema.

y_t bezeichnet in diesem Zusammenhang den wahren Wert, \hat{y}_t den Vorhersagewert und \bar{y} den geschätzten Mittelwert der zu prognostizierenden Werte. IOA_2 evaluiert die Fähigkeit eines Modells Variationen um den Mittelwert vorherzusagen. Um dies zu verdeutlichen eignet sich die Dreiecksungleichung. Für eine eindimensionale Zeitreihe und entsprechende Prognosewerte gilt

$$\begin{aligned} (\hat{y}_t - y_t)^2 &= (\hat{y}_t - \bar{y} + \bar{y} - y_t)^2 \leq (\hat{y}_t - \bar{y})^2 + (\bar{y} - y_t)^2 \\ |\hat{y}_t - y_t| &= |\hat{y}_t - \bar{y} + \bar{y} - y_t| \leq |\hat{y}_t - \bar{y}| + |\bar{y} - y_t| \end{aligned}$$

Der Unterschied zwischen den prognostizierten und den tatsächlichen Werten ist stets kleiner gleich den summierten Abständen der einzelnen Werte zum Mittelwert. Handelt es sich bei sämtlichen Prognosen um den Mittelwert beziehungsweise liegen Prognosen und beobachtete Werte stets auf gegenüberliegenden Seiten des geschätzten Mittelwerts, so ergibt sich $IOA_2 = 0$. Situationen in welchen Prognosen über dem Mittelwert, die wahren Abrufmengen jedoch darunter liegen, oder umgekehrt, bedeuten, dass das Ausmaß des Bedarfs an Regelenergie grob falsch kategorisiert wurde und wird durch das Kriterium dementsprechend bestraft. Willmott hat außerdem eine alternative Version des Index of Agreement dargelegt, welche hier als IOA_1 bezeichnet wird.

$$IOA_1 = 1 - \frac{\sum_{t=1}^n |\hat{y}_t - y_t|}{\sum_{t=1}^n (|\hat{y}_t - \bar{y}| + |y_t - \bar{y}|)}$$

Beide vorgestellten Indizes nehmen Werte zwischen Null und Eins an, wobei ein höherer Wert einer besseren Prognose im Sinne dieser Kriterien entspricht. Der Vorteil von IOA_1 gegenüber IOA_2 ist, dass er mit zunehmend präziseren Prognosen langsamer gegen Eins strebt, wodurch Unterschiede zwischen präzisen Prognosemodellen deutlicher werden. Außerdem reagiert er weniger sensitiv auf Ausreißer unter den Fehlern. IOA_1 -Werte der in diesem Abschnitt behandelten Modellspezifikationen finden sich in der Tabelle auf Seite 81, entsprechende IOA_2 -Werte sind im Appendix zu finden.

Bei der Betrachtung der Indizes ist erkennbar, dass IOA_2 -Werte im Schnitt höher sind als IOA_1 -Werte. Für die Prognose von Abrufmengen positiver Regelenergie ergeben sich bei einer Schrittweite von Eins IOA_2 -Werte über 0,8, für negative Regelenergie sogar bis zu einem Prognosehorizont von drei Perioden, was auf eine einigermaßen präzise Vorhersage hindeutet. Allerdings fallen beide Indizes schnell ab und pendeln sich in den besten Fällen bei Werten um 0,5 ein, was auf ein schlechtes bis mittelmäßiges Ergebnis hindeutet.

Neuerlich ist anzumerken, dass die naive Prognose vergleichsweise sehr gut abschneidet. In einigen Fällen sind die IOA-Werte hierfür höher als bei anderen Modellen der Vorhersage. Insgesamt erzeugt das Tobit Modell die

besten Evaluationskriterien. Bei IOA_2 -Werten ergeben sich bei der Verwendung der Linearkombination als Prognosevariable in diesem Modell sowohl für positive als auch für negative Regelenergie die höchsten Werte. IOA_1 ist für das Tobit Modell der Zeitreihe nach einer Yeo-Johnson-Transformation zum größten Teil am niedrigsten.

IOA_1	Positive Regelenergie															
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
LM: Zensiert	0,71	0,57	0,52	0,49	0,46	0,43	0,42	0,40	0,39	0,38	0,38	0,37	0,36	0,36	0,36	0,35
LM: WLS II	0,69	0,55	0,50	0,48	0,44	0,41	0,40	0,39	0,38	0,37	0,36	0,36	0,35	0,35	0,34	0,34
LM: YJ	0,69	0,61	0,58	0,56	0,55	0,54	0,53	0,53	0,53	0,52	0,52	0,52	0,52	0,52	0,51	0,51
Tobit: EW	0,68	0,53	0,47	0,43	0,39	0,36	0,34	0,33	0,32	0,31	0,31	0,30	0,29	0,29	0,29	0,28
Tobit: LP	0,75	0,64	0,60	0,57	0,55	0,52	0,51	0,50	0,49	0,48	0,48	0,47	0,47	0,46	0,46	0,45
Tobit: YJ LP	0,69	0,63	0,60	0,58	0,57	0,56	0,55	0,55	0,54	0,54	0,54	0,54	0,53	0,53	0,53	0,53
SARMA	0,68	0,51	0,46	0,43	0,37	0,33	0,32	0,31	0,29	0,26	0,25	0,25	0,23	0,23	0,22	0,21
WKNNR: Normal	0,61	0,54	0,50	0,48	0,46	0,45	0,44	0,43	0,42	0,42	0,41	0,41	0,40	0,40	0,40	0,39
WKNNR: Gefittet	0,72	0,60	0,54	0,51	0,47	0,45	0,44	0,42	0,41	0,40	0,40	0,39	0,38	0,38	0,37	0,37
Naiv	0,72	0,59	0,58	0,58	0,54	0,50	0,50	0,51	0,49	0,47	0,47	0,47	0,47	0,46	0,45	0,45
IOA_1	Negative Regelenergie															
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
LM: Zensiert	0,75	0,65	0,60	0,56	0,52	0,49	0,47	0,45	0,44	0,43	0,42	0,41	0,40	0,40	0,39	0,39
LM: WLS II	0,74	0,63	0,58	0,55	0,50	0,47	0,45	0,44	0,43	0,41	0,41	0,40	0,39	0,38	0,38	0,38
LM: YJ	0,73	0,66	0,63	0,60	0,58	0,56	0,55	0,54	0,54	0,54	0,53	0,53	0,53	0,53	0,52	0,52
Tobit: EW	0,72	0,61	0,54	0,49	0,44	0,41	0,39	0,37	0,36	0,35	0,34	0,33	0,32	0,32	0,32	0,31
Tobit: LP	0,78	0,70	0,65	0,62	0,59	0,56	0,55	0,53	0,52	0,51	0,50	0,50	0,49	0,49	0,48	0,48
Tobit: YJ LP	0,73	0,67	0,64	0,61	0,59	0,58	0,57	0,56	0,55	0,55	0,55	0,54	0,54	0,54	0,54	0,54
SARMA	0,71	0,58	0,53	0,49	0,42	0,37	0,34	0,33	0,30	0,28	0,27	0,26	0,25	0,24	0,23	0,23
WKNNR: Normal	0,66	0,59	0,56	0,53	0,50	0,49	0,47	0,46	0,45	0,45	0,44	0,43	0,43	0,42	0,42	0,42
WKNNR: Gefittet	0,76	0,66	0,60	0,56	0,52	0,50	0,48	0,46	0,45	0,44	0,43	0,42	0,42	0,41	0,41	0,40
Naiv	0,74	0,63	0,61	0,61	0,56	0,52	0,52	0,53	0,50	0,48	0,48	0,48	0,47	0,46	0,46	0,45

Tabelle 3.14: IOA_1 ausgewählter Modellspezifikationen für die Prognose von Regelenergieabrufmengen

Die präziseste Modellspezifikation dieser Arbeit zur Prognose von Abrufmengen an Regelenergie hängt vom Evaluationskriterium ab. Allerdings kann sich das Tobit Modell mehrmals positiv abheben, im Speziellen in Verbindung mit einer Yeo-Johnson-Transformation der gegebenen Zeitreihen. Außerdem ergeben sich durch das lineare Regressionsmodell optimale Werte für bestimmte Kriterien. Die Prognose mit Hilfe eines SARIMA-Modells beziehungsweise gewichteter k -Nearest Neighbour Regression liefert leider keine präzisere Vorhersage.

Conclusio

Ziel dieser Arbeit war es, den Einfluss verschiedener Variablen auf Abrufmengen von Regelenergie zu untersuchen. Außerdem sollten Intraday-Prognosen erstellt und evaluiert werden. Für diese Aufgabenstellung wurde zuerst ein lineares Regressionsmodell gewählt, mit welchem ein Verfahren zur Erfassung des Einflusses verschiedener Variablen erarbeitet wurde. Außerdem wurde hiermit versucht relevante Variablen und funktionale Zusammenhänge für die Prognose zu erarbeiten, welche in der Folge auch in anderen Modellklassen verwendet wurden. Das Tobit Modell berücksichtigt die Zensierung der Daten und liefert somit teilweise präzisere Prognosen. Ein SARIMA-Modell wurde als zusätzlicher Benchmark implementiert. Schließlich wurde durch gewichtete k -Nearest Neighbour Regression versucht, auch mögliche in den vorhergehenden Ansätzen vernachlässigte Abhängigkeiten aufzudecken. Allerdings konnten hiermit keine Prognosen erarbeitet werden, welche die Ergebnisse des linearen Regressionsmodells respektive des Tobit Modells überbieten konnten. Eine genaue Aufschlüsselung hierzu findet sich in Abschnitt 3.8.

In sämtlichen vorgestellten Modellansätzen und im Sinne des vorgestellten Verfahrens lassen sich dieselben untersuchten Variablen als einflussreich auf die Abrufmengen von Regelenergie klassifizieren. Hierbei handelt es sich um den ungewollten Stromaustausch mit Nachbarnetzwerken, den Prognosefehler der Windeinspeisung und die Windeinspeisung an sich. Ergänzend ist zu erwähnen, dass ungewollter Import in diesem Kontext Erklärungsgüte für positive Abrufmengen liefert und ungewollter Export dies für negative Abrufmengen bietet. Die erwähnten Zusammenhänge gehen mit einer positiven Korrelation einher, die Koeffizienten der Variablen in verschiedenen Modellen besitzen dementsprechend mehrfach positive Vorzeichen. Dies widerspricht der ursprünglichen Interpretation des Zusammenhangs.

Eine alternative Erklärung könnte die folgende sein: Zumal zu ungewolltem Stromaustausch auch Primärregelenergie gezählt wird (2), kann eine hohe

Menge an ungewolltem Import auf einen Bedarf an positiver Primärregelleistung hinweisen. In der Folge kann dies die Aktivierung weiterer Regelenergieserven nach sich ziehen, da sich eventuell zu wenig Strom im Netz befindet und nach und nach durch Regelenergie substituiert wird. Der Einfluss des Prognosefehlers der Windeinspeisung weist auf einen bereits vermuteten Zusammenhang hin. Volatilität in der Stromeinspeisung kann zu der Aktivierung von Regelenergieserven führen. Hingegen hat sich der Lastprognosefehler, welcher das Pendant der Nachfrageseite darstellt und sogar umfassender ist, da er sich nicht auf erneuerbare Energien beschränkt, als weniger einflussreich im Sinne des vorgestellten Verfahrens herausgestellt. Auch bei Intraday-Prognosen liefert er keinen wesentlichen Beitrag. Das Niveau der Einspeisung aus Windenergie hat sich im vorgestellten Verfahren ebenfalls als aussagekräftig erweisen: Hätte man lediglich eine exogene Variable zur Erklärung des Regelenergiebedarfs zur Verfügung, so würde die Windeinspeisung vergleichsweise gut abschneiden. Im Kontext mit weiteren Variablen scheint sie jedoch ebenso kein treibender Faktor zu sein.

Bedauerlicherweise wurde bei der durchgeführten Analyse, aufgrund fehlender Datengrundlage, eine Fülle an Variablen vernachlässigt, welche eine hohe Erklärungsgüte beisteuern könnten. Insbesondere fällt die Absenz von wetter- und klimabezogenen Größen auf. Temperatur, Windgeschwindigkeit sowie solare Einstrahlung könnten zusätzliche Erklärungsgüte liefern, somit aber auch den Einfluss anderer Variablen im Kontext des vorgestellten Verfahrens mindern. Die Daten sollten hierfür geeignet gewichtet werden. Beispielsweise ist die Temperatur einer ländlichen Region nur bedingt repräsentativ für den Stromverbrauch eines Großteils der Bevölkerung. Ferner wird ein hoher Anteil der Elektrizität in Österreich durch Wasserkraftwerke erzeugt. Daten zu Speicherpegelständen respektive Flusspegelständen könnten einen merkbaren Einfluss auf Abrufmengen von Regelenergie ausüben beziehungsweise das Ergebnis von Vorhersagen entsprechend verbessern.

Die Intraday-Prognosen von Abrufmengen liefern wie erwartet suboptimale Ergebnisse. Die Vorhersagen der jeweils folgenden Periode führen zu einigermaßen niedrigen Fehlermaßen. Hervorstechende Prognosen werden hierbei, wie bereits erwähnt, durch das lineare Regressionsmodell und das Tobit Modell erzielt. Allerdings steigt mit dem Prognosehorizont auch das assoziierte Fehlermaß rapide an. Anschließend pendeln sich die Werte auf einem Niveau ein, welches bedingt zufriedenstellend für Punktprognosen der gegebenen Zeitreihe ist. Es ist anzumerken, dass Regelenergie als letzte Instanz zum sicheren Betrieb eines Stromnetzes fungiert. Wäre der Bedarf hiernach vorhersagbar, würde dies dem Zweck des Apparats widersprechen. Unter anderem finden sich deswegen häufiger Arbeiten zu Schätzungen von Sicherheitsniveaus anstatt Punktprognosen im Kontext von Regelenergiea-

brufmengen, wie beispielsweise Jost et al. (2015) und Ohsenbrügge (2015). Auch für Übertragungsnetzbetreiber ist diese Art der Prognose gehaltvoller, da die geschätzten Sicherheitsniveaus, vorerst zumindest in der Theorie, tatsächlich zur Vorhaltung von Regelenergie verwendet werden können.

Ziel dieser Arbeit war es unter anderem die Schwierigkeiten der Prognose von Abrufmengen von Regelenergie besser quantifizierbar zu machen, was durch die erstellten Ergebnisse möglich ist. Es ist jedoch anzumerken, dass die entsprechenden Annahmen der Prognosemodelle streng genommen nicht erfüllt sind, weswegen auch nicht von der Optimalität der Prognosen ausgegangen werden kann. Weitere Modellansätze, wie ein dynamisches Mehrgleichungsmodell oder ein SARIMAX-Modell könnten die Vorhersagegenauigkeit eventuell noch verfeinern. Ferner existieren eine Reihe an vernachlässigten Faktoren: Auch wenn es bei Regelenergie um den sicheren Betrieb eines Stromnetzes geht, existieren wirtschaftliche Anreize, welche den Abruf hiervon beeinflussen können, jedoch in dieser Arbeit nicht berücksichtigt wurden. Beispielsweise kann eine Situation herrschen, in der Intraday-Preise von Elektrizität über den prognostizierten Ausgleichsenergiepreisen liegen. Bilanzkreisverantwortliche hätten somit einen Anreiz unausgeglichene Fahrpläne zu gestalten, um Strom kostengünstiger beschaffen. Änderungen im regulatorischen Umfeld des Marktes für Regelenergie sind Usus in den letzten Jahren und können ebenso nachhaltige Effekte haben. Ferner könnten Intraday-Prognosen von exogenen Faktoren wie der Last, der Einspeisung aus Windenergie sowie Photovoltaik die Prognosegüte der bereits vorgestellten Ansätze verbessern.

Abbildungen

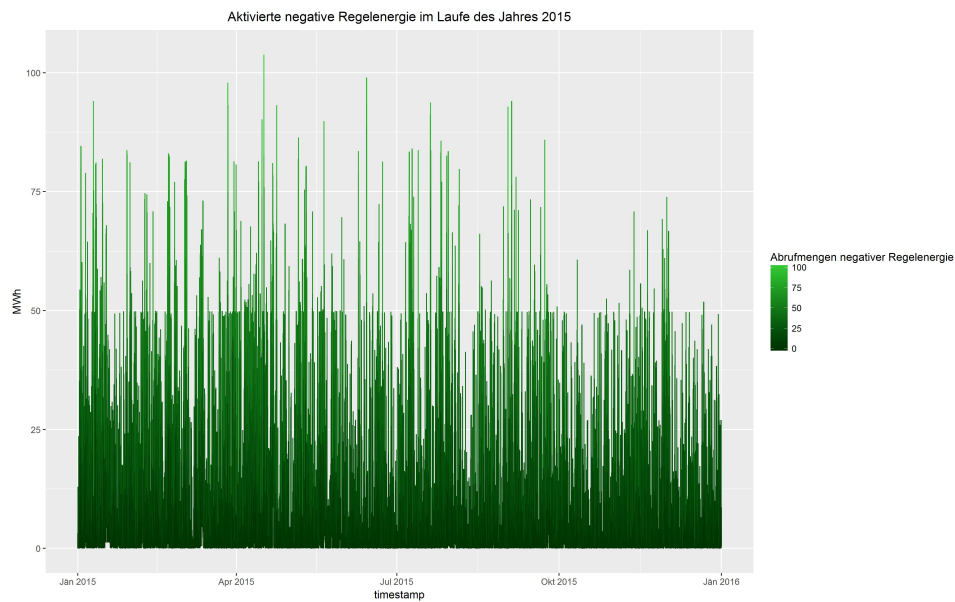


Abbildung A.1: Abgerufene Menge an negativer Regelennergie für jede Viertelstunde des Jahres 2015




Abbildung A.2: Häufigkeitsverteilung der aktivierten Menge an negativer Regelleistung des Jahres 2015




Abbildung A.3: ACF und PACF der Abrufmengen negativer Regelleistung 2015

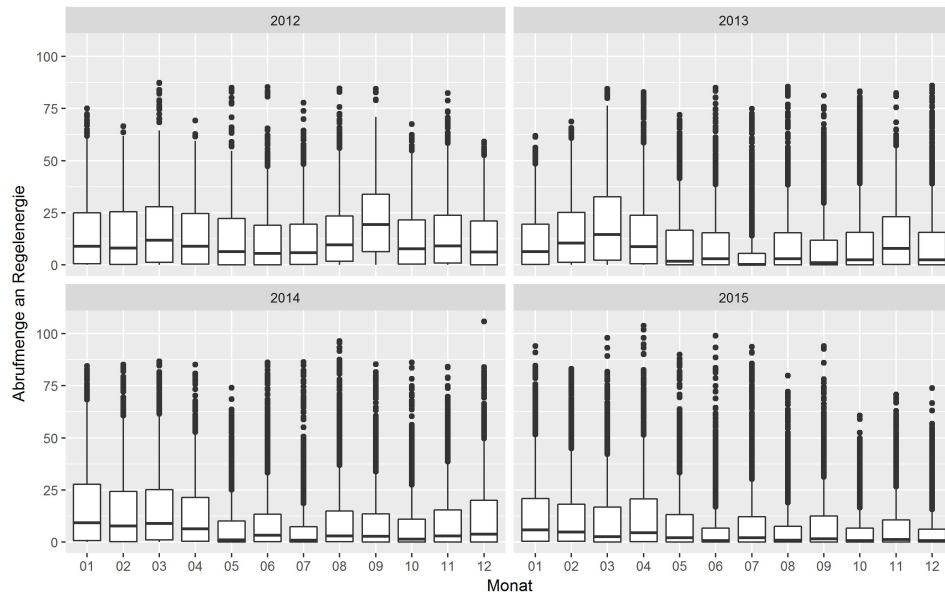


Abbildung A.4: Boxplots der Abrufmenge negativer Regelenergie für Monate in 2012-2015




Abbildung A.5: Boxplots der Abrufmenge negativer Regelenergie für Wochentage in 2015




Abbildung A.6: Boxplots der Abrufmenge negativer Regelenergie für Tageszeiten in 2015




Abbildung A.7: Mittelwert und Standardabweichung der Abrufmenge negativer Regelenergie zu verschiedenen Tageszeiten im Jahr 2015

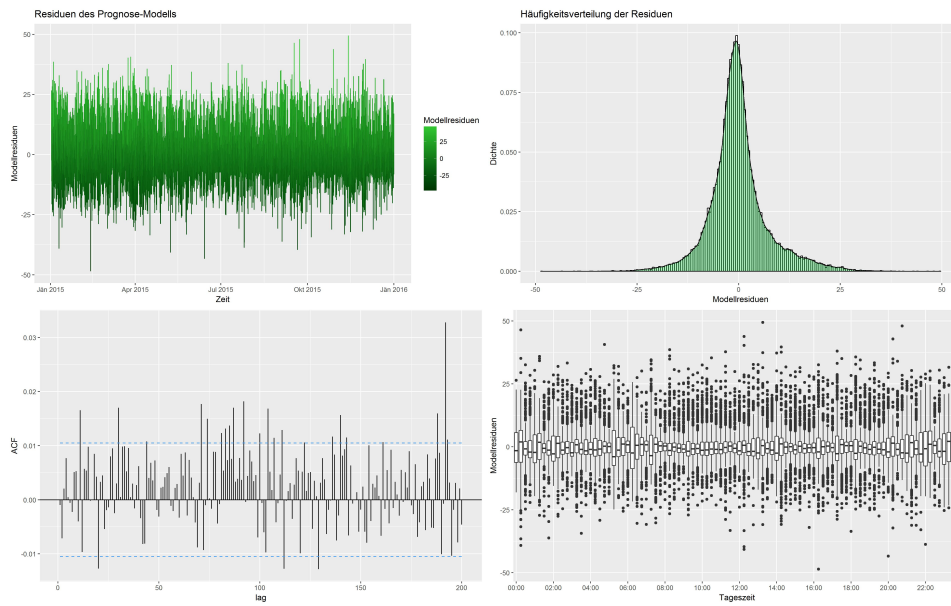


Abbildung A.8: Residuen des linearen Regressionsmodells der Ein-Schritt-Prognose: Abrufmengen negativer Regelennergie

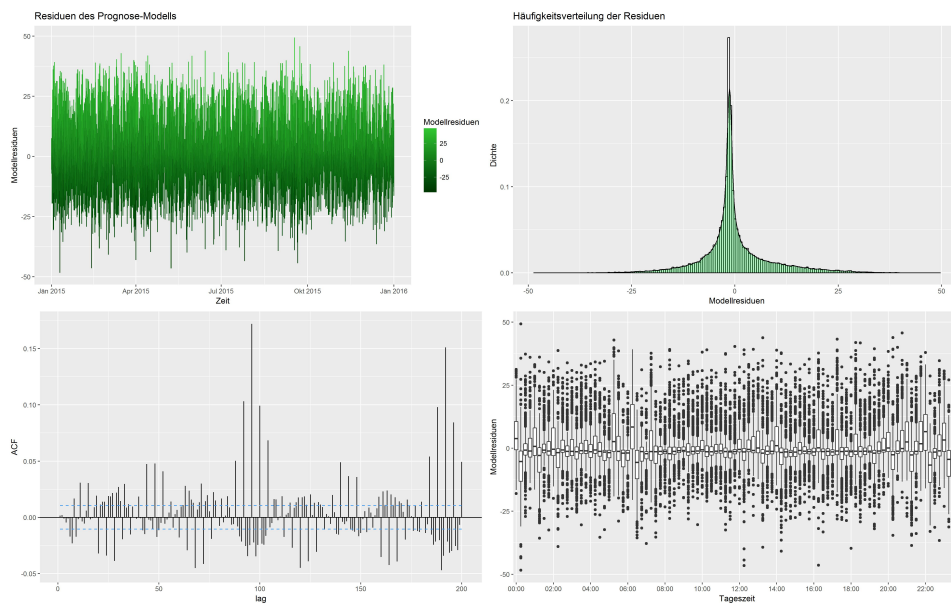


Abbildung A.9: Residuen des SARMA(4, 0, 4)(0, 0, 2)₉₆ Modells: Abrufmengen negativer Regelennergie

ANHANG B

Tabellen und Modelle

RMSE	Positive Regelennergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	11,12	11,81	11,34	10,75	11,84	11,78	11,80	11,83	11,81
Volles Modell ohne Variable	10,68	10,36	10,25	10,73	10,25	10,27	10,24	10,24	10,25
MAE	Positive Regelennergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	7,95	8,34	8,03	7,76	8,36	8,30	8,32	8,36	8,34
Volles Modell ohne Variable	7,73	7,60	7,52	7,76	7,49	7,51	7,48	7,50	7,50
RMSE	Negative Regelennergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	14,16	12,92	12,28	11,64	14,48	14,39	14,38	14,41	14,46
Volles Modell ohne Variable	10,67	11,25	10,88	11,29	10,71	10,68	10,64	10,69	10,65
MAE	Negative Regelennergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	10,27	9,23	8,63	8,46	10,38	10,34	10,28	10,34	10,40
Volles Modell ohne Variable	7,55	8,06	7,80	7,96	7,59	7,57	7,54	7,57	7,55

Tabelle B.1: Einfluss der Variablen im linearen Regressionsmodell

	Koeffizienten	<i>t</i> -Werte
(Intercept)	8,59 (0,63)***	13,61
Abrufmenge negativer Regelenergie_1	0,71 (0,01)***	83,91
Abrufmenge negativer Regelenergie_2	-0,11 (0,01)***	-13,35
Abrufmenge negativer Regelenergie_3	0,09 (0,01)***	11,37
Abrufmenge negativer Regelenergie_4	0,10 (0,01)***	11,46
Abrufmenge negativer Regelenergie_5	-0,08 (0,01)***	-9,49
Abrufmenge negativer Regelenergie_6	0,02 (0,01)***	3,33
Abrufmenge negativer Regelenergie_7	-0,01 (0,01)	-1,11
Abrufmenge negativer Regelenergie_8	0,03 (0,01)***	5,09
Windprognose_0	-0,02 (0,00)***	-5,58
Windprognose_1	0,08 (0,01)***	12,39
Windprognose_2	-0,06 (0,00)***	-15,56
Lastprognose_0	0,01 (0,00)***	6,36
Lastprognose_1	-0,01 (0,00)***	-7,00
Lastprognose_2	-0,00 (0,00)	-2,03
Lastprognose_3	0,01 (0,00)***	7,91
Photovoltaikprognose_0	0,07 (0,02)**	2,98
Photovoltaikprognose_1	-0,16 (0,05)***	-3,05
Photovoltaikprognose_2	0,12 (0,05)*	2,47
Photovoltaikprognose_3	-0,03 (0,02)	-1,38
Ungewollter Stromexport_1	0,14 (0,02)***	5,73
Ungewollter Stromexport_2	-0,02 (0,01)	-1,22
Ungewollter Stromexport_3	0,07 (0,01)***	4,67
Windprognosefehler_1	-0,06 (0,00)***	-31,20
Windprognosefehler_2	0,06 (0,00)***	29,56
Abrufmenge negativer Regelenergie_96	0,05 (0,01)***	8,06
Abrufmenge negativer Regelenergie_97	-0,04 (0,01)***	-5,99
Abrufmenge negativer Regelenergie_MA	0,05 (0,01)***	6,37
Windprognose_MA	0,00 (0,00)*	2,09
Lastprognose_MA	-0,00 (0,00)*	-2,39
Photovoltaikprognose_MA	-0,01 (0,00)***	-3,37
Ungewollter Stromimport_1	-0,09 (0,01)***	-8,84
Lastprognosefehler_1	0,00 (0,00)***	3,16
Verkaufsvolumen Intraday_1	0,00 (0,00)**	2,75
Nicht verfügbare Kapazitäten_1	-0,00 (0,00)	-0,24
R ²	0,77	
Adj. R ²	0,77	
Num. obs.	34938	
RMSE	7,28	

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$

Tabelle B.2: Lineares Regressionsmodell der Ein-Schritt-Prognose: Negative Regelenergie

ANHANG B. TABELLEN UND MODELLE

RMSE	Positive Regelenergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	11,15	11,88	11,27	10,37	11,94	11,87	11,89	11,94	11,92
Volles Modell ohne Variable	10,35	9,89	9,89	10,62	9,91	9,94	9,89	9,90	9,90
MAE	Positive Regelenergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	8,40	8,89	8,30	7,50	9,01	8,94	8,96	9,01	9,00
Volles Modell ohne Variable	7,48	7,17	7,17	7,82	7,19	7,21	7,16	7,17	7,17
RMSE	Negative Regelenergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	14,18	13,23	12,26	11,25	14,63	14,54	14,53	14,57	14,62
Volles Modell ohne Variable	10,56	10,86	10,63	11,28	10,56	10,52	10,47	10,53	10,49
MAE	Negative Regelenergie								
<i>Variable</i>	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	10,86	9,95	9,10	8,25	11,15	11,10	11,05	11,13	11,18
Volles Modell ohne Variable	7,61	7,87	7,69	8,28	7,65	7,60	7,57	7,60	7,57

Tabelle B.3: Einfluss der Variablen im Tobit Modell

	Koeffizienten
AR	
ar1	0,27 (0,03)
ar2	-0,03 (0,03)
ar3	-0,04 (0,02)
ar4	0,52 (0,01)
MA	
ma1	-0,23 (0,05)
ma2	0,25 (0,05)
ma3	0,19 (0,04)
ma4	-0,23 (0,02)
SMA	
sma1	0,78 (0,03)
sma2	0,26 (0,02)
mean	
intercept	9,36 (0,32)
AIC	248604,21
AICc	248604,22
BIC	248705,78
Log Likelihood	-124290,11

Tabelle B.4: SARMA(4, 0, 4)(0, 0, 2)₉₆: Negative Regelenergie

ANHANG B. TABELLEN UND MODELLE

RMSE		Positive Regelenergie							
Variable	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	11,70	12,58	12,21	10,98	12,55	12,46	12,46	12,50	12,62
Volles Modell ohne Variable	11,13	10,67	10,68	11,45	10,69	10,68	10,68	10,66	10,64
MAE		Positive Regelenergie							
Variable	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	7,92	8,37	8,23	7,12	8,95	8,57	8,54	8,64	8,30
Volles Modell ohne Variable	7,25	6,89	6,92	7,66	6,92	6,87	6,91	6,89	6,87
RMSE		Negative Regelenergie							
Variable	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	14,37	14,55	13,56	11,92	15,55	15,13	14,96	15,27	18,10
Volles Modell ohne Variable	11,32	11,69	11,33	12,15	11,24	11,16	11,20	11,22	11,23
MAE		Negative Regelenergie							
Variable	Ungew. Imp.	Ungew. Exp.	Wind-Einsp.	Wind-fehler	PV-Progn.	Last	Last-fehler	Intrad.-KV	Ungepl. Ausf.
Modell mit einzelner Variable	9,95	11,32	9,12	7,79	11,32	10,48	10,40	10,68	14,97
Volles Modell ohne Variable	7,46	7,67	7,41	8,16	7,40	7,34	7,36	7,40	7,37

Tabelle B.5: Einfluss der Variablen bei gewichteter k -Nearest Neighbour Regression

RMSE		Positive Regelenergie															
Horizont		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Naive Prognose		8,65	11,87	12,49	12,54	13,61	14,38	14,47	14,34	14,73	15,08	15,16	15,15	15,26	15,37	15,51	15,64
MAE		Positive Regelenergie															
Horizont		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Naive Prognose		4,86	7,03	7,36	7,26	8,05	8,66	8,69	8,53	8,86	9,17	9,22	9,19	9,30	9,41	9,54	9,63
RMSE		Negative Regelenergie															
Horizont		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Naive Prognose		9,30	12,57	13,37	13,60	15,26	16,30	16,51	16,46	17,11	17,62	17,75	17,83	18,10	18,36	18,51	18,69
MAE		Negative Regelenergie															
Horizont		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Naive Prognose		5,43	7,66	8,10	8,16	9,35	10,09	10,19	10,06	10,55	10,94	11,00	11,03	11,22	11,42	11,53	11,66

Tabelle B.6: Evaluationskriterien der naiven Prognose

IOA_2	Positive Regelernergie															
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
LM: Zensiert	0,89	0,76	0,69	0,65	0,60	0,56	0,54	0,52	0,51	0,49	0,48	0,47	0,46	0,46	0,45	0,45
LM: WLS II	0,88	0,72	0,66	0,63	0,57	0,54	0,52	0,51	0,49	0,48	0,47	0,46	0,45	0,44	0,44	0,43
LM: YJ	0,79	0,66	0,58	0,53	0,48	0,45	0,43	0,42	0,40	0,40	0,39	0,39	0,39	0,38	0,38	0,38
Tobit: EW	0,89	0,76	0,69	0,64	0,59	0,55	0,52	0,51	0,49	0,47	0,46	0,46	0,45	0,44	0,43	0,43
Tobit: LP	<i>0,90</i>	<i>0,79</i>	<i>0,72</i>	<i>0,68</i>	<i>0,63</i>	<i>0,59</i>	<i>0,57</i>	<i>0,55</i>	<i>0,54</i>	<i>0,52</i>	<i>0,52</i>	<i>0,51</i>	<i>0,50</i>	<i>0,49</i>	<i>0,49</i>	<i>0,48</i>
Tobit: YJ LP	0,79	0,69	0,63	0,58	0,53	0,49	0,46	0,45	0,43	0,42	0,41	0,41	0,40	0,40	0,40	0,39
SARMA	0,86	0,69	0,62	0,59	0,51	0,46	0,44	0,43	0,40	0,37	0,35	0,34	0,32	0,31	0,30	0,29
WKNNR: Normal	0,75	0,65	0,60	0,57	0,55	0,53	0,52	0,50	0,49	0,48	0,47	0,47	0,46	0,46	0,45	0,45
WKNNR: Gefittet	0,89	0,76	0,69	0,65	0,60	0,57	0,55	0,53	0,51	0,50	0,49	0,48	0,47	0,47	0,46	0,46
Naiv	0,85	0,71	0,67	0,67	0,60	0,55	0,54	0,55	0,52	0,50	0,49	0,49	0,48	0,48	0,47	0,46
IOA_2	Negative Regelernergie															
Horizont	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
LM: Zensiert	0,92	0,85	0,79	0,75	0,70	0,65	0,62	0,60	0,58	0,56	0,55	0,53	0,52	0,52	0,51	0,50
LM: WLS II	0,91	0,83	0,77	0,73	0,67	0,63	0,60	0,58	0,56	0,54	0,53	0,52	0,51	0,50	0,49	0,48
LM: YJ	0,86	0,78	0,72	0,66	0,61	0,55	0,52	0,49	0,48	0,47	0,46	0,45	0,45	0,44	0,44	0,43
Tobit: EW	0,92	0,84	0,79	0,74	0,68	0,63	0,60	0,58	0,56	0,54	0,52	0,51	0,50	0,49	0,49	0,48
Tobit: LP	<i>0,93</i>	<i>0,86</i>	<i>0,81</i>	<i>0,77</i>	<i>0,72</i>	<i>0,68</i>	<i>0,65</i>	<i>0,63</i>	<i>0,61</i>	<i>0,59</i>	<i>0,58</i>	<i>0,57</i>	<i>0,56</i>	<i>0,55</i>	<i>0,54</i>	<i>0,54</i>
Tobit: YJ LP	0,85	0,78	0,73	0,68	0,63	0,58	0,55	0,52	0,51	0,49	0,48	0,48	0,47	0,46	0,46	0,45
SARMA	0,89	0,77	0,72	0,68	0,58	0,52	0,48	0,46	0,42	0,38	0,37	0,35	0,33	0,32	0,31	0,30
WKNNR: Normal	0,82	0,75	0,70	0,66	0,62	0,59	0,57	0,56	0,55	0,54	0,53	0,52	0,51	0,50	0,49	0,49
WKNNR: Gefittet	0,92	0,84	0,79	0,74	0,69	0,65	0,62	0,60	0,58	0,56	0,55	0,53	0,53	0,52	0,51	0,51
Naiv	0,88	0,77	0,75	0,74	0,66	0,61	0,60	0,61	0,57	0,54	0,53	0,53	0,51	0,49	0,49	0,47

Tabelle B.7: IOA_2 ausgewählter Modellspezifikationen für die Prognose von Regelernergieabrufmengen

Quellenverzeichnis

- [1] Amemiya, Takeshi. *Advanced econometrics*. Harvard university press. 1985.
- [2] Beyer, K., Goldstein, J., Ramakrishnan, R. and Shaft, U. *When is “nearest neighbor” meaningful?*. International conference on database theory (pp. 217-235). Springer Berlin Heidelberg, 1999.
- [3] Brockwell, Peter J., and Richard A. Davis. *Introduction to time series and forecasting*. Springer, 2016.
- [4] Brockwell, Peter J., and Richard A. Davis. *Time series: theory and methods*. Springer Science & Business Media, 2013.
- [5] Brückl, Oliver, *Wahrscheinlichkeitstheoretische Bestimmung des Regel- und Reserveleistungsbedarfs in der Elektrizitätswirtschaft*. Dissertation Universität München, 2006
- [6] CONSENTEC. *Gutachten zur Dimensionierung des Regelleleistungsbedarfs unter dem NRV*. Aachen, 2010.
- [7] De Jong, Robert and Herrera, Ana María. *Dynamic censored regression and the Open Market Desk reaction function*. Journal of Business & Economic Statistics, 29.2 (2011): 228-237, 2011.
- [8] E-Control, *Das österreichische Strommarktmodell*. Österreich, 2013
- [9] Greene, William H.. *Econometric analysis*. Sixth Edition, New Jersey: Prentice Hall, 2008.
- [10] Guégan, Dominique, and Rakotomaroahy, Patrick. *The multivariate k-nearest neighbor model for dependent variables: one-sided estimation and forecasting*. Documents de travail du Centre d’Economie de la Sorbonne 2009.50 - ISSN : 1955-611X. 2009. jhalshs-00423871v2_i, 2009.

- [11] Hamilton, James Douglas. *Time series analysis*. Vol. 2. Princeton: Princeton university press, 1994.
- [12] Haubrich, H. J.. *Gutachten zur Höhe des Regelenergiebedarfs*. Im Auftrag der Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen, Bonn, 2008.
- [13] Hayashi, Fumio. *Econometrics. 2000*. Princeton University Press, 2000.
- [14] Hechenbichler, Klaus, and Schliep Klaus. *Weighted k-nearest-neighbor techniques and ordinal classification*. 2004.
- [15] Hirth, Lion, and Inka Ziegenhagen. *Control power and variable renewables: a glimpse at German data*. 2013.
- [16] Hirth, Lion, Ziegenhagen, Inka and Energiewirtschaftliche Tagesfragen. *Wind, Sonne und Regelleistung*. Energiewirtschaftliche Tagesfragen 63 (2013): 2-4, 2013.
- [17] Hyndman, Rob J., and George Athanasopoulos. *Forecasting: principles and practice*. OTexts, 2014.
- [18] Ilieva, Iliana, and Torjus Folsland Bolkesjø. *An econometric analysis of the regulation power market at the nordic power exchange*. Energy Procedia 58 (2014): 58-64, 2014.
- [19] Jost, D., Braun, A., Fritz, R., Drusenbaum, C., K. Rohrig. *Dynamische Bestimmung des Regelleistungsbedarfs - Abschlussbericht*. Fraunhofer-Institut für Windenergie und Energiesystemtechnik (IWES), Kassel, 2015
- [20] Kabinger, A., Knaus, K, Süßenbacher, W.. *Der kurzfristige physische Stromhandel in Österreich - Vermarktungsmöglichkeiten, Marktkonzentration und Wirkungsmechanismen*. E-Control, Wien, 2014
- [21] Kippelt, S., Schlüter, T. and Rehtanz, C.. *Future demand for prospective providers of control reserves*. IEEE PES Innovative Smart Grid Technologies, Europe. IEEE, 2014.
- [22] Kurscheid, Eva Marie, and Dana Düvelmeyer. *Modellierung der Inanspruchnahme positiver Minutenreserve als zusammengesetzter Poisson-Prozess mit regelzonenabhängiger Parametrierung*. Technische Universität Chemnitz, Fakultät für Mathematik, 2009.
- [23] Kwiatkowski, Denis and Phillips, Peter and Schmidt, Peter and Shin, Yongcheol *Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?* Journal of econometrics 54.1-3 (1992): 159-178. 1992.

-
- [24] Möller, C., Rachev, S. T., Kim, Y. S., and Fabozzi, F. J.. *Innovation processes in logically constrained time series*. Advances in Directional and Linear Statistics. Physica-Verlag HD, 2011. 173-188, 2011.
- [25] Nicholson, E., Rogers, J. and Porter, K.. *The relationship between wind generation and balancing-energy market prices in ERCOT: 2007–2009*. No. NREL/SR-5500-49415. National Renewable Energy Laboratory (NREL), Golden, CO., 2010.
- [26] Ohsenbrügge, Anja. *Dynamische Regel-und Reserveleistungsvorhaltung in zukünftigen Smart Grids*. Dissertation Universität Oldenburg, 2015.
- [27] Samworth, Richard J.. *Optimal weighted nearest neighbour classifiers*. The Annals of Statistics 40.5 (2012): 2733-2763, 2012.
- [28] Scherrer, Wolfgang. *Grundlagen der Ökonometrie*. Technische Universität Wien, Institut für Stochastik und Wirtschaftsmathematik, 2015
- [29] Scherrer, Wolfgang. *Stationäre Prozesse und Zeitreihenanalyse*. Technische Universität Wien, Institut für Stochastik und Wirtschaftsmathematik, 2015
- [30] Schneider, Ulrike. *Mikroökometrie*. Technische Universität Wien, Institut für Stochastik und Wirtschaftsmathematik, 2015
- [31] Schwarz, Carl James. *Sampling, regression, experimental design and analysis for environmental scientists, biologists, and resource managers*. Department of Statistics and Actuarial Science, Simon Fraser University 57, 2011.
- [32] Swider, Derk Jan. *Handel an Regelernergie-und Spotmärkten: Methoden zur Entscheidungsunterstützung für Netz-und Kraftwerksbetreiber*. Springer-Verlag, 2008.
- [33] Wenzel, Anne. *Komponentenzerlegung des Regelleistungsbedarfs mit Methoden der Zeitreihenanalyse*. Master-Arbeit Technische Universität Chemnitz, 2010.
- [34] Willmott, Cort J., Scott M. Robeson, and Kenji Matsuura. *A refined index of model performance*. International Journal of Climatology 32.13 (2012): 2088-2094. 2012
- [35] Wolfram, Martin, Bokhari, Hamza and Westermann, Dirk. *Factor influence and correlation of short term demand for control reserve*. PowerTech, 2015 IEEE Eindhoven. IEEE, 2015.
- [36] Yeo, In-Kwon, and Richard A. Johnson. *A new family of power transformations to improve normality or symmetry*. Biometrika (2000): 954-959, 2000

ANHANG D

Websites

- [1] <https://www.apg.at/>
Website des österreichischen Übertragungsnetzbetreibers APG, letzter Aufruf: Jänner 2017
- [2] <https://www.apg.at/de/markt/netzregelung>
Erläuterungen zu Netzregelung in der Regelzone APG, letzter Aufruf: Jänner 2017
- [3] <https://www.apg.at/de/markt/netzregelung/statistik>
Statistiken der Netzregelung in der Regelzone APG, letzter Aufruf: Jänner 2017
- [4] <https://www.apg.at/de/markt/netzregelung/sekundaerregelung/ausschreibungen>
Ausschreibungen der Sekundärregelleistung in der Regelzone APG, letzter Aufruf: Jänner 2017
- [5] <https://www.apg.at/de/markt/netzregelung/ungewollter-austausch>
Ungewollter Stromaustausch der Regelzone APG mit benachbarten Netzen, letzter Aufruf: Jänner 2017
- [6] <https://www.apg.at/de/markt/Markttransparenz/last/Ist-Last>
Ist-Last in der Regelzone APG, letzter Aufruf: Jänner 2017
- [7] <https://www.entsoe.eu/about-entso-e/Pages/default.aspx>
Erklärungen zu ENTSO-E, letzter Aufruf: Jänner 2017
- [8] <https://transparency.entsoe.eu/>
Transparenz-Plattform der ENTSO-E, letzter Aufruf: Jänner 2017
- [9] <https://www.regelleistung.net/ext/tender/remark>
Internetplattform der deutschen Übertragungsnetzbetreiber, letzter Aufruf: Jänner 2017

- [10] https://www.eeh.ee.ethz.ch/fileadmin/user_upload/eeh/studies/courses/power_system_dynamics_and_control/Documents/ENTSO_E_Policy1_final.pdf
Erläuterungen zu Richtlinien der ENTSO-E bei Regelleistung, letzter Aufruf: Jänner 2017
- [11] <https://www.epexspot.com/en/>
Website der Handelsplattform European Power Exchange, letzter Aufruf: Jänner 2017
- [12] http://www.inekon.de/tl_files/inekon/content/Themen/Regelenergie/Uebersicht_Regelenergie.png
Schematische Darstellung von Regelenergieabrufen, letzter Aufruf: Jänner 2017
- [13] <https://stat.ethz.ch/R-manual/R-devel/library/stats/html/00Index.html>
R-Paket: *stats*, letzter Aufruf: Jänner 2017
- [14] <https://cran.r-project.org/web/packages/AER/AER.pdf>
R-Paket: *AER*, letzter Aufruf: Jänner 2017
- [15] <https://cran.r-project.org/web/packages/car/car.pdf>
R-Paket: *car*, letzter Aufruf: Jänner 2017
- [16] <https://cran.r-project.org/web/packages/forecast/forecast.pdf>
R-Paket: *forecast*, letzter Aufruf: Jänner 2017
- [17] <https://cran.r-project.org/web/packages/kknn/kknn.pdf>
R-Paket: *kknn*, letzter Aufruf: Jänner 2017
- [18] <https://cran.r-project.org/web/packages/lmtest/lmtest.pdf>
R-Paket: *lmtest*, letzter Aufruf: Jänner 2017
- [19] <https://cran.r-project.org/web/packages/nortest/nortest.pdf>
R-Paket: *nortest*, letzter Aufruf: Jänner 2017
- [20] <https://cran.r-project.org/web/packages/sandwich/sandwich.pdf>
R-Paket: *sandwich*, letzter Aufruf: Jänner 2017
- [21] <https://cran.r-project.org/web/packages/survival/survival.pdf>
R-Paket: *survival*, letzter Aufruf: Jänner 2017
- [22] <https://cran.r-project.org/web/packages/tseries/tseries.pdf>
R-Paket: *tseries*, letzter Aufruf: Jänner 2017
- [23] <https://cran.r-project.org/web/packages/urca/urca.pdf>
R-Paket: *urca*, letzter Aufruf: Jänner 2017