



FAKULTÄT II – INFORMATIK, WIRTSCHAFTS- UND RECHTSWISSENSCHAFTEN
DEPARTMENT FÜR INFORMATIK

Dynamische Regel-und Reserveleistungsvorhaltung in zukünftigen Smart Grids

Dissertation zur Erlangung des Grades eines
Doktors der Ingenieurwissenschaften

vorgelegt von

Anja Ohsenbrügge

Gutachter:

Prof. Dr. Sebastian Lehnhoff
Jun.-Prof. Dr. habil. Oliver Kramer

Tag der Disputation: 4. Dezember 2015

Zusammenfassung

Die ständige Balance zwischen Erzeugung und Verbrauch ist eine zentrale Forderung im elektrischen Energiesystem zur Gewährleistung einer konstanten Netzfrequenz und damit einer gleichbleibenden Versorgungsqualität. Zur Gewährleistung dieser Balance wird permanent eine bestimmte Regel- und Reserveleistungsmenge bereitgehalten, um Prognoseabweichungen, Lastschwankungen oder Kraftwerksausfälle kompensieren zu können. Daher ist eine möglichst genaue Vorhersage der erwarteten Einspeisung und Nachfrage eine wichtige Herausforderung. In den letzten Jahren haben dabei insbesondere Methoden des maschinellen Lernens beachtliche Verbesserungen der Prognosegüten erzielt. Dennoch steigt der Bedarf an Regelleistung aufgrund der Zunahme volatiler Erzeugung. Insbesondere der Bedarf an negativer Regelleistung, um Leistungsüberschüsse und damit einen Frequenzanstieg, zu kompensieren, hat in den vergangenen Jahren deutlich zugenommen. Im Gegensatz zu den dynamischen Prognosemethoden auf Basis des maschinellen Lernens, beruht die aktuelle Art der Bereitstellung und Bemessung der Regelleistung weiterhin auf statischen analytischen Methoden. Diese resultieren aus der ehemals hierarchisch und zentral geführten Struktur des Europäischen Energiesystems. Im Gegensatz dazu ist die heutige Struktur durch die Zunahme der Erneuerbaren Energien sowie der Liberalisierung des Energiesektors zunehmend dezentral. Damit haben sich neben den Randbedingungen für die Bereitstellung, die heute zunehmend durch dezentrale Anlagen realisiert werden muss, auch die entscheidenden Einflussparameter für die Dimensionierung der Regelleistungsmengen zum Teil erheblich verändert.

Das Ziel dieses Dissertationsvorhabens ist das Aufzeigen dieser veränderten Einflussgrößen sowie die Anpassung der Regelleistungsbemessung an die heutigen Strukturen. Dabei liegt der Schwerpunkt in der Entwicklung eines flexiblen Prognosemodells zur Vorhersage der regelzoneninternen Systembilanzungleichgewichte und der damit verbundenen Regelleistungsbedarfe. Ziel dieses Modells ist die tägliche adaptive Regelleistungsdimensionierung, angepasst an den jeweiligen Systemzustand des elektrischen Versorgungsnetzes. Für dieses flexible Prognosemodell werden Methoden des maschinellen Lernens insbesondere der k-nächsten-Nachbarn (KNN) und der Gradient Boosting Trees (GBT) verwendet. Abschließend erfolgt eine Evaluation des Prognosemodells. Dabei werden die potentiell einzusparenden Mengen beispielhaft für das Testjahr 2013 ermittelt und mit den Ergebnissen einer statistischen Vergleichsberechnung verglichen. Die Arbeit umfasst dabei fünf wesentliche Aspekte:

1. Analyse des aktuellen Prozesses zur Regelleistungsvorhaltung
2. Analyse der wesentlichen Einflussparameter auf den Bedarf an Regelleistung
3. Abgleich der Analysen und Aufzeigen von Verbesserungspotentialen
4. Entwicklung eines flexiblen Prognosemodells auf Basis der abgeleiteten Anforderungen
5. Evaluation des Prognosemodells

Abstract

To ensure a constant power frequency and thus a stable quality of supply, the permanent balance of power demand and supply is the most crucial constraint in an electrical power system. Therefore there is a need for reserve and balancing power to cover prediction-deviations for example of wind generation and loads or unpredictable events like power plant outtakes. Therefore time series modeling and prediction of the power demand and supply is an important task, In recent years machine learning algorithms have drawn attention and have established themselves in the forecasting community. Especially for wind power and electricity demand the machine learning algorithms improved the prognosis accuracy. But due to the increasing share of generation from renewable resources the need for reserve and balancing power to cover these prognosis faults is still increasing. In contrast of the dynamic machine learning approaches, the current design for the dimensioning of necessary reserves and its reliable provision is still a statical method. It is based on the former hierarchical and centralized structure of the European electricity sector. In contrast, the increase of generation from renewable resources makes the system become more and more decentralized and complex. Thus, the reserve and reliability strategy has to be adapted to today's structure.

The goal of this work is to identify these altered circumstances and to develop a dynamic strategy for reserve dimensioning, which factors these in. In particular a new approach of forecasting the system imbalances, responsible for the activation of frequency control reserve, other than just analyzing past activations has been investigated. The result is a flexible forecasting model based on methods of statistical learning, especially k-nearest neighbors and gradient boosting trees designed to predict future system imbalances. The work includes five main aspects:

1. Analysis of the current process of balance power provision
2. Analysis of the main influencing parameters on the demand of balancing power
3. Comparison of both analysis and identification of room for improvement
4. Development of a flexible forecast model
5. Evaluation of the forecast model

Inhalt

1	Einleitung	1
1.1	Problemstellung	1
1.2	Zielsetzung der Arbeit	3
1.3	Anforderungen	4
1.4	Beitrag der Arbeit	6
1.5	Aufbau der Arbeit	6
2	Vorbereitung - Grundlagen	9
2.1	Prozessanalyse	9
2.1.1	Regelleistung im energiepolitischen Kontext	9
2.1.2	Technische Grundlagen zur Regelleistung	14
2.1.3	Ursachen für Bilanzungleichgewichte	16
2.1.4	Formalisierung Regelzonensaldo	22
2.1.5	Gestaltung und Entwicklung des Regelleistungsmarktes	25
2.2	Datenanalyse	29
2.2.1	Datengrundlage	29
2.2.2	Analyse der Regelleistungsaktivierung	32
2.2.3	Analyse des Regelzonensaldo	37
2.2.4	Effektanalyse der Einflussgrößen	47
2.3	Problemformulierung	52
2.3.1	Gegenüberstellung Prozess- und Datenanalyse	52
2.3.2	Entwicklung der RL-Bemessung -Stand der Technik	54
2.3.3	RL-Bemessung als Prognosemodell	57
2.4	Zusammenfassung und Diskussion	63
3	Modellbildung	65
3.1	Grundlagen dynamische Prognosemodelle	65
3.1.1	Prognose als überwachtes Lernen	65
3.1.2	k-Nächste-Nachbarn (KNN)	69
3.1.3	Gradient Boosting Trees (GBT)	71
3.1.4	Vorgehensmodell Maschinelles Lernen	76
3.2	Merkmalsgenerierung	77
3.2.1	Merkmalstransformation	77
3.2.2	Merkmalsskalierung	79
3.2.3	Distanzfunktion	80
3.2.4	Merkmalsauswahl	84
3.3	Modellbewertung – Zielfunktion	90
3.3.1	Gütemaße für die Prognose	90

3.3.2	Zielfunktion des Prognosemodells	94
3.3.3	Modellparametrierung	96
3.3.4	Modelloptimierung	97
3.4	Implementierung	99
3.5	Zusammenfassung	101
4	Evaluation	103
4.1	Evaluationsszenarien	103
4.2	Ergebnisse für den Netzregelverbund	106
4.2.1	Ergebnisse für KNN	106
4.2.2	Ergebnisse für den Gradient Boosting Trees (GBT)	119
4.3	Anwendung des Prognosemodells auf die Regelleistungsbemessung	126
4.3.1	Sicherheitsniveau des Prognosemodells (VaR)	126
4.3.2	Einsparpotentiale des Prognosemodells	130
4.3.3	Vergleich mit der situativen faltungsbasierten Bemessung	139
4.4	Ergebnisse für die einzelnen Regelzonen	144
4.4.1	Ergebnisse für 50 Hertz	144
4.4.2	Ergebnisse für Amprion	148
4.4.3	Ergebnisse für Tennet	150
4.4.4	Ergebnisse für TransnetBW	152
4.5	Zusammenfassung	154
5	Zusammenfassung und Ausblick	157
5.1	Zusammenfassung	157
5.2	Ausblick	159
6	Anhang	161
6.1	Evaluation	161
6.2	Statistische Grundlagen	181
	Glossar	185
	Abkürzungen	191
	Abbildungen	193
	Literatur	197
	Danksagung	209

1 Einleitung

Der Ausstieg aus der Kernenergie und die Zunahme dezentraler Erzeugung aus erneuerbaren Energien machen einen grundlegenden Systemwandel erforderlich, um die Energieversorgung weiterhin verlässlich, klimaverträglich und bezahlbar zu gestalten. Ein Schwerpunkt bildet die versorgungssichere und zuverlässige Substitution konventioneller Großkraftwerkskapazitäten durch dezentrale Energiesysteme wie Photovoltaik- (PV), Windkraft- und Kraft-Wärme-Kopplungsanlagen¹. Insbesondere die Regel- und Reserveleistungsvorhaltung, um Prognoseabweichungen, Lastschwankungen oder Kraftwerksausfälle kompensieren zu können, muss an die heutige komplexe Struktur angepasst werden. Zum einen steigt mit der Zunahme des Anteils an erneuerbaren Energien der Anteil der Prognoseabweichungen, während der Anteil der Kraftwerksausfälle insbesondere von Großanlagen wie Kernkraftwerken zurück geht, und zum anderen muss auch die Bereitstellung der Regel- und Reserveleistung, bei einem Wegfall der im Netz befindlichen Großanlagen, in Zukunft durch erneuerbare Energiequellen und kurzfristig zuschaltbare Kleinkraftwerke bzw. abschaltbare Lasten realisiert werden.

1.1 Problemstellung

Das aktuelle Design der Regelleistungs- und Reservevorhaltung resultiert aus der ehemals hierarchischen und zentralen Struktur des Europäischen Energiesystems. Im Gegensatz dazu ist die heutige Struktur, durch die Zunahme der Erneuerbaren Energien sowie der Liberalisierung des Energiesektors, zunehmend komplex und dezentral. So haben sich auch die entscheidenden Einflussparameter für die Dimensionierung der Regelleistungsmengen in den vergangenen Jahren zum Teil erheblich verändert. Während früher vor allem Kraftwerksausfälle und das Lastrauschen den Einsatz von Regelleistung (RL) verursachten, so sind es heute vermehrt Prognosefehler. Dies führt zu einer veränderten Mengenverteilung der einzelnen Regelleistungsarten – man unterscheidet nach dem Zeitpunkt der Aktivierung drei Arten² – und zum anderen hat es Auswirkungen auf die Auswahl bzw. den Entwurf der Bemessungsmethode. Während man für die Kraftwerksausfälle und das Lastrauschen noch eine statistische Unabhängigkeit vom aktuellen Systemzustand³ annehmen konnte, ist dies für die Prognoseabweichungen nicht mehr vollständig korrekt. Im Gegenteil, diese hängen stark mit dem aktuellen Netz- und Versorgungszustand zusammen. Des Weiteren sind Kraftwerksausfälle unkorreliert, während diese Annahme für Prognoseabweichungen nicht uneingeschränkt korrekt ist.

Das aktuelle Bemessungskonzept ist damit sowohl konzeptionell als auch methodisch nicht mehr adäquat. Konzeptionell lässt sich sowohl in Bezug auf die Versorgungssicherheit als auch in Bezug auf die Wirtschaftlichkeit verstehen; so befindet sich die Regelleistung im „Spannungsfeld zwischen einer Reduktion der Vorhaltungskosten und Gewährleistung von Systemsicherheit“ [SK12], was im aktuellen Design dadurch berücksichtigt wird, dass nicht die gesamte benötigte Menge an Regelleistung vorgehalten wird, sondern ein akzeptiertes Defizitniveau P_D ⁴ von aktuell 0,05 % einzuhalten ist. Wird dieses niedrige Defizitniveau in Zukunft bei steigenden Anteilen erneuerbarer Energien beibehalten, so werden sich die vorzuhaltenden Mengen und dementsprechend auch die Kosten nach

¹ Die wesentlichen Begriffe der Energiewirtschaft sind im Glossar erläutert.

² Diese sind Primärregelleistung, Sekundärregelleistung und Minutenreserve.

³ Ein Systemzustand beinhaltet zum Beispiel die aktuelle Erzeugungszusammensetzung im Netz, d.h. insbesondere den aktuellen Anteil an Wind- und Solarleistung im Netz.

⁴ Das Defizitniveau entspricht dem Anteil der maximal zulässigen unterdeckten Zeitintervalle.

dem derzeitigen Bemessungskonzept erhöhen⁵. Dabei sieht das aktuelle Konzept der Dimensionierung eine vierteljährliche Anpassung der Mengen auf Basis historischer Daten der vergangenen zwölf Monate mit einem Zeitversatz von einem Quartal vor⁶. „Dieses Vorgehen setzt voraus, dass bezüglich der Regelleistungsdimensionierung kritische Situationen schon mit dem Vorlauf von einem Quartal hinreichend sicher erkannt würden“ [SK12]. Mit zunehmender fluktuierender Erzeugung und damit einer täglich geänderten Zusammensetzung der Erzeugungsleistung im Netz, wird dies jedoch immer weniger der Fall sein. So stellen in Zukunft neben Extremwetterlagen auch Naturphänomene wie die Sonnenfinsternis, durch ihren verstärkten Einfluss auf die Stromerzeugung, ein Gefährdungspotential für die Versorgungssicherheit dar. Und die möglichen Auswirkungen dieser Phänomene können nur kurzfristig, bei genauer Kenntnis der erwarteten Erzeugungsleistungen, bewertet werden. So wird in einem Gutachten der Consentec [Con10] auch bereits im Jahr 2010 „eine Anpassung der Modellierung und Parametrierung der Methodik“ gefordert, wenn sich "die Wissensbasis über die Ursachen und Auswirkungen von Bilanzungleichgewichten grundsätzlich verändern“. Und genau diese Wissensbasis ist in den vergangenen Jahren gewachsen; so wird unter anderem die statistische Unabhängigkeit der Einflussgrößen, wie sie das aktuelle faltungsbasierte Bemessungskonzept unterstellt, zunehmend in Frage gestellt.

Daher ist die aktuelle Dimensionierung, die analytisch a-posteriori die eingesetzten Regelleistungsmengen mit den vorgehaltenen Mengen vergleicht und bei Bedarf anpasst, nicht mehr zeitgemäß, sondern bedarf einer methodischen Anpassung. So wurde beispielsweise die Extremsituation im Dezember 2011 für die Neuberechnung der Bedarfswerte ab dem 2. Quartal 2012 nicht berücksichtigt, obwohl Studien bereits im ersten Quartal 2012 eine häufige Überschreitung der zulässigen Defizitwerte feststellten [HZ15]. Des Weiteren ist dieses zentrale Design auf die reine Dimensionierung der Regelleistungsmengen beschränkt, eine aktuelle Prognose und damit kritische Einstufung kommender Systemzustände lässt sich mit diesem Verfahren nicht vornehmen. Dieses Wissen ist jedoch für die einzelnen Übertragungsnetzbetreiber (ÜNB) von Bedeutung, da sie für das Systemgleichgewicht, d.h. die ständige Deckung von Erzeugung und Verbrauch, innerhalb ihrer Regelzone verantwortlich sind. So stellt nach Ansicht des Bundesverbandes der Energie- und Wasserwirtschaft (BDEW) genau dieses „regelzonenspezifische Balancing“ (Frequenz-, Austauschleistungsregelung für eine Regelzone, „Netzregelung“) für die Übertragungsnetzbetreiber aufgrund der hohen Volatilitäten der erneuerbaren Energiequellen eine neue Herausforderungen dar [bde12]. Die Bundesregierung spricht in ihrem aktuellen Grünbuch „Ein Strommarkt für die Energiewende“ [Bun12] vom Ziel, dass „in Zukunft die ausgeschriebene Menge für Regelleistung an die jeweilige Einspeisung von Wind- und Sonnenenergie angepasst werden könnte“ und nennt dieses Vorhaben „adaptive Bedarfsdimensionierung“.

Daher kann eine exaktere dynamische Prognose der Systembilanzungleichgewichte und der damit verbundenen Regelleistungsbedarfe einen wertvollen Beitrag zur Sicherstellung der Versorgungssicherheit und der Wirtschaftlichkeit auch bei zunehmendem Anteil an fluktuierender Einspeisung leisten. Im Bereich der Prognose dieser fluktuierenden Einspeisungen sowie der zu erwartenden Last haben sich in den vergangenen Jahren vermehrt Methoden des maschinellen Lernens durchgesetzt und dazu beigetragen, dass die Prognosegenauigkeit erheblich gesteigert werden konnte. Aufgrund des weiter zunehmenden Anteils fluktuierender Erzeugung wird der Regelungsbedarf jedoch trotz verbesserter Prognosen in den kommenden Jahren steigen.

⁵ Dies liegt daran, dass die installierte Erzeugungsleistung aus erneuerbaren Energien als Einflussgröße in die Bemessung einfließt.

⁶ Siehe hierzu [www.regelleistung.net], zuletzt geprüft am 10.08.2015.

Es ergibt sich demnach folgende Forschungsfrage, die im Rahmen dieser Arbeit untersucht bzw. beantwortet werden soll:

Ist eine adaptive Regelleistungsbemessung auf Basis einer täglichen Prognose der erwarteten Systemungleichgewichte mit Methoden des maschinellen Lernens möglich?

Dieser Forschungsfrage liegen dabei folgende Arbeitshypothesen zugrunde, die zuvor motiviert wurden und die in dieser Arbeit untersucht werden:

- Die derzeitige Regelleistungsvorhaltung ist ineffizient und berücksichtigt nur unzureichend die geänderten Anforderungen eines zunehmend auf dezentraler und volatiler Erzeugung aufbauenden Energiesystems.
- Die Aktivierung von Regelleistung erfolgt nicht zufällig; insbesondere lassen sich zeitlich und regional differenzierte Ursache-Wirkungs-Zusammenhänge sowie partielle Wechselwirkungen zwischen den Einflussfaktoren feststellen.
- Methoden des maschinellen Lernens können genutzt werden, ein Prognosemodell zu entwickeln, das die Vorhersage zukünftiger Bilanzungleichgewichte und damit eine dynamischere effizientere Regelleistungsvorhaltung ermöglicht.
- Die vorzuhaltenden Regelleistungsmengen lassen sich zeitlich reduzieren und somit Kosten einsparen.
- Das aktuelle Defizitniveau, bzw. das daraus resultierende Sicherheitsniveau von 99,95 % kann gehalten werden.

1.2 Zielsetzung der Arbeit

Aus der oben aufgeführten Forschungsfrage und den abgeleiteten Hypothesen ergibt sich das Ziel dieser Arbeit wie folgt:

Entwicklung eines flexiblen Prognosemodells mit Methoden des maschinellen Lernens zur adaptiven Bemessung der erforderlichen Regelleistungsmengen

Das zu entwickelnde Prognosemodell soll es ermöglichen, das Systemungleichgewicht (Regelzonensaldo) für verschiedene Prognosehorizonte vorherzusagen und damit insbesondere kritische Systemzustände in Bezug auf die Regelleistungsmengen bzw. den daraus resultierenden erhöhten Regelleistungsbedarf abzuleiten.

Aus dieser Zielsetzung ergeben sich die folgenden Einzelziele, die durch diese Arbeit erfüllt werden sollen:

Räumlich und zeitlich differenzierte Prognose

Das Prognosemodell soll sowohl örtlich als auch zeitlich variabel sein. So soll das Prognosemodell in regionalen Abstufungen sowohl für die einzelne Regelzone anwendbar sein, als auch im gesamten Netzregelverbund. Das Weiteren soll der Prognosehorizont frei wählbar sein, um so zum Beispiel zeitabhängigen Prognoseanpassungen aufgrund geänderter Datenlage - beispielsweise einer verbesserten Windprognose - zu ermöglichen.

Analyse und Integration des Ursache-Wirkungs-Zusammenhanges der Bilanzungleichgewichte

Im aktuellen Bemessungskonzept erfolgt die Gleichgewichtung aller Einflussfaktoren durch die Faltung der Wahrscheinlichkeitsdichtefunktionen (WDF). Ziel des Prognosemodells ist es, die Einflussfaktoren in Kenntnis des Systemzustandes entsprechend zu gewichten. Dazu ist eine Ursache- Wirkungs-Analyse durchzuführen, aus der sich diese Gewichte ableiten lassen.

Berücksichtigung von Zukunftswerten

Ziel des neuen Systems ist, dass es kein analytisches a-posteriori Prinzip verfolgen soll, wie es das aktuelle Design der vergangenheitsbezogenen Dimensionierung tut, sondern das zu entwickelnde Prognosemodell soll a-priori auf die zukünftigen Bedingungen eingehen. Dazu sollen auch Prognosen über die Erzeugungsleistung aus Wind und PV sowie Lastprognosen mit in das Modell einbezogen werden.

Risikoeinstufung der Prognose

Zur Gewährleistung der Systemsicherheit ist für das zu entwickelnde Prognosemodell eine Risikoanalyse durchzuführen. So wird das Modell auf vorhandenen Daten evaluiert und es werden Aussagen über das zu erwartende Sicherheitsniveau getroffen.

Vorschläge zur Anwendung/Umsetzung

Im Rahmen der Evaluation sollen Aussagen über ein mögliches Einsparungspotential getroffen werden, die bei einer Umsetzung der Methode zu erwarten wären. Dies gilt insbesondere bei einer Umstrukturierung der Ausschreibungszeiten und Produkte.

1.3 Anforderungen

Aus den im vorangegangenen Kapitel vorgestellten Ziele werden in diesem Kapitel Anforderungen abgeleitet, die einen Vergleich des zu entwickelnden Prognosemodells mit den bisherigen Verfahren der Dimensionierung ermöglichen. Dabei lassen sich aus den Zielsetzungen die folgenden Anforderungen ableiten:

Räumlich und zeitlich differenzierte Prognose } \Rightarrow *Skalierbarkeit*

Integration des Ursache-Wirkungs-Zusammenhanges } \Rightarrow *Dynamik*

Berücksichtigung von Zukunftswerten } \Rightarrow *Adaptivität*

Risikoeinstufung des Systemzustands } \Rightarrow *Sicherheit*

Skalierbarkeit

Um eine räumlich und zeitlich differenzierte Prognose zu ermöglichen, müssen die Eingangsparameter skalierbar sein; so soll beispielsweise der Prognosehorizont variabel sein, woraus sich unterschiedliche Zeitfenster zwischen dem bilanziellen Handel bzw. der Einspeiseprognose und der physikalischen Erfüllung ergeben. Für das Prognosemodell ist es daher erforderlich, dass die Daten in einer Art und Weise aufbereitet und gespeichert werden, die sowohl eine gezielte Datenabfrage der Merkmale in aggregierter, sortierter oder gruppierter Art und Weise ermöglicht als auch die Voraussetzungen für eine integrierte explorative Datenanalyse schafft. Dazu werden die von Pendse und Creeth [PC95] aufgestellten Anforderungen an derartige mehrdimensionale Datenwürfel, für die sie den Begriff des „OLAP“-Würfels (**O**nline **A**nalytical **P**rocessing) geprägt haben, übernommen. Diese Anforderungen können unter dem Agronym **FASMI** (engl. fast Analysis of Shared Multidimensional Information) zusammengefasst werden [ML13] und umfassen neben der *multidimensionalen Strukturierung* der Daten auch *schnelle Antwortzeiten*, *interaktive Werkzeuge der automatischen Analyse* sowie eine *transparente Datenbereitstellung*.

Dynamik/Adaptivität

Um die Anforderungen an das Prognosemodell in Bezug auf die Dynamik bzw. Adaptivität zu verfeinern, wird das Konzept der Wandlungsfähigkeit von produzierenden Unternehmen [Spa08] adaptiert. In diesem Kontext wird die Dynamik bzw. die Wandlungsfähigkeit eines Systems nach dem zeitlichen Änderungshorizont in die Turbulenzfähigkeit und Entwicklungsfähigkeit unterteilt. Dabei beschreibt die kurzfristige Turbulenzfähigkeit „die Fähigkeit eines Systems zur aktiven, schnellen Anpassung der Strukturen auf zeitlich nicht vorhersehbar wechselnde Aufgaben aus eigener Substanz“ [Har96]. Kommt die Erkennung des Änderungsbedarfs dabei von außen, so spricht man auch von *Flexibilität*, erkennt ein System diesen Änderungsbedarf von innen heraus, so spricht man von *Adaptivität*. Dem Gegenüber versteht man unter der langfristigen Entwicklungsfähigkeit die „Fähigkeit zur evolutionären Entwicklung der Strukturen bei zeitlich konstanten oder längerfristig vorhersehbar wechselnden Anforderungen aus eigener Substanz“ [Har96].

Das zu entwickelnde Prognosesystem soll eine Integration des Ursache-Wirkungs-Zusammenhangs ermöglichen, indem es sich adaptiv an Strukturänderungen anpassen kann. Dabei soll sowohl eine langfristig vorhersehbare Anpassung, zum Beispiel der Wegfall von Kernkraftwerken in der Kraftwerkszusammensetzung, als auch eine kurzfristige Anpassung, zum Beispiel durch eine geänderte Windprognose, möglich sein. Insbesondere die kurzfristige Anpassung soll dadurch realisiert werden, dass sich die Gewichtung der Einflussparameter flexibel bzw. adaptiv an den jeweiligen Systemzustand anpasst. Dabei gilt es einen geeigneten Mittelweg zu finden, zwischen den Anforderungen der Flexibilität bzw. Adaptivität und den Anforderungen, die an ein stabiles sicheres Prognosemodell gestellt werden, wie sie beispielsweise Mertens aufgestellt hat [Mer11]. So soll sich das Prognosemodell zwar flexibel an Änderungen im System anpassen, jedoch nicht jeden „Ausreißer“ in den Daten als Anlass zur Modellanpassung nehmen. Diese Forderung nach einem stabilen System ist eng verbunden mit den Anforderungen der Sicherheit.

Sicherheit

In komplexen Systemen, wie dem elektrischen Energieversorgungssystem, ist es unmöglich, Risiken völlig auszuschließen. Daher gilt es ein Maß zu finden, mit dem die zu erreichende Sicherheit⁷ bzw. das Maß der verbleibenden Unsicherheit quantifiziert werden kann. Die Norm ISO 31000 definiert Risiko als „Effekt der Unsicherheit auf den Grad der Zielerreichung“. In Bezug auf die Prognose

⁷ Im Englischen wird zwischen dem Begriff der *Security* (Angriffssicherheit), und dem Begriff der *Safety* (Betriebssicherheit) unterschieden, in dieser Arbeit wird unter dem Begriff Sicherheit die Betriebssicherheit verstanden.

spricht man dabei nicht von negativen Effekten sondern von dem Risiko eines Prognosefehlers. Dabei lassen sich diese Prognosefehler entsprechend den unterschiedlichen Ursachen ihrer Unsicherheit in zwei Gruppen aufteilen [Shr09]. Zum einen resultieren die Unsicherheiten aus den Daten, und zum anderen lassen sie sich auf das Modell zurückführen. Zur Quantifizierung des mit dem Prognosemodell verbundenen Risikos wird das Konzept des Value at Risk (VaR) angepasst. Dieses bezeichnet ein Risikomaß, das angibt, welchen Wert der Prognosefehler mit einer gegebenen Wahrscheinlichkeit innerhalb eines gegebenen Zeithorizonts nicht überschreitet. Das aktuelle Bemessungskonzept verwendet genau dieses VaR-Verfahren, indem die Regelleistungsmenge anhand des vorgegebenen Defizitniveaus bestimmt wird.

1.4 Beitrag der Arbeit

Um die oben aufgeführten Ziele zu erreichen, wird mit dieser Arbeit ein flexibles Prognosemodell zur dynamischen Vorhersage des Regelsaldos (PMRS) entwickelt. Im Gegensatz zu dem bisherigen Bemessungskonzept bzw. Forschungsarbeiten auf diesem Gebiet, soll kein mathematisches Modell als Funktion der Einflussparameter entwickelt werden, sondern der funktionale Zusammenhang zwischen den Einflussgrößen und dem Regelleistungseinsatz soll aus den Daten abgeleitet werden. Dazu werden Methoden der modernen computergestützten Datenanalyse – „Data Mining“ – verwendet. Für das Prognosemodell werden insbesondere die Methoden der k-nächsten-Nachbarn (KNN) [Dix02] und der Gradient Boosting Trees (GBT) [Sch11] verwendet.

1.5 Aufbau der Arbeit

Der Aufbau der Arbeit leitet sich aus den beiden führenden Vorgehensmodellen für das Data Mining ab. So wurden sowohl der Knowledge Discovery in Databases (KDD)-Prozess nach Fayad, Pietetsky-Shapiro und Smyth [FPSS96] als auch der Cross-Industry Standard Process for Data (CRISP) [Cha00] nach Chapman betrachtet und in die folgenden Prozessschritte *Vorbereitung*, *Modellbildung* und *Evaluation/Anwendung* aggregiert, die in den nachfolgenden Kapiteln beschrieben werden. Abbildung 1.1 zeigt den Aufbau und Zusammenhang der Kapitel dieser Arbeit.

Um einen bestehenden Prozess verbessern zu können, sind zum einen das Anwendungsgebiet und zum anderen die vorhandenen Daten zu analysieren. Im CRISP-Modell werden diese Prozessschritte auch unter den Begriffen „Business Understanding“ und „Data Understanding“ propagiert. Diese beiden IST-Zustände sind anschließend gegenüberzustellen, um die Güte des aktuellen Prozesses zu bewerten bzw. Verbesserungspotentiale abzuleiten. Daher wird im folgenden Kapitel 2.1 ein kurzer Überblick über die Regel- und Reserveleistungsvorhaltung in Deutschland gegeben. Dabei wird sowohl auf die energiepolitischen, marktwirtschaftlichen als auch technischen Hintergründe eingegangen. Anschließend erfolgt in Kapitel 2.2 eine IST-Analyse der vorhandenen Datengrundlage, insbesondere der Dynamik und Struktur der Regelleistungsaktivierung der letzten Jahre. Dazu wird zunächst die verwendete Datengrundlage sowie die Datenaufbereitung und -modellierung nach den Prinzipien des OLAP-Würfels vorgestellt, bevor anschließend eine univariate Datenanalyse, d.h. die Zeitreihenanalyse der Einzelfaktoren erfolgt. Aus diesen Informationen werden in Kapitel 2.3 Anforderungen bzw. Designspezifikationen an das zu entwickelnde Prozessmodell abgeleitet. In diesem Zusammenhang werden neben dem aktuellen Konzept der Regelleistungsbemessung auch aktuelle Forschungsansätze auf diesem Gebiet diskutiert. Das Ergebnis dieser Diskussion bzw. ein Abgleich

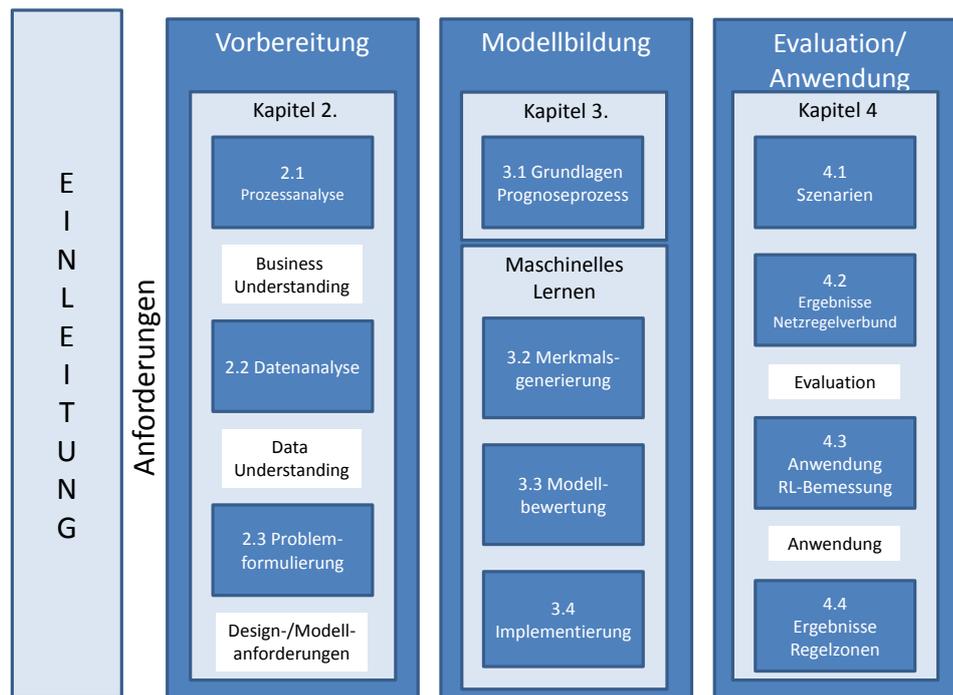


Abbildung 1.1: Übersicht der Kapitel

der bestehenden Arbeiten mit den in der Einleitung aufgestellten Anforderungen fließen am Ende des Kapitels in die Zusammenfassung.

Anschließend erfolgt in Kapitel 3 der Prozessschritt der sogenannten „Modellbildung“, indem die in Kapitel 2 gewonnenen Erkenntnisse in ein Modell überführt werden. Dazu wird in Abschnitt 3.1 zunächst kurz auf die methodischen Grundlagen der Prognose auf Basis des maschinellen Lernens eingegangen, bevor in den Kapiteln 3.2 und 3.3 der genaue Aufbau des entwickelten Prognosemodells vorgestellt wird. Die Kapitel orientieren sich dabei am Vorgehensmodell für maschinelles Lernen, das in Kapitel 3.1 vorgestellt wird. Kapitel 3.4 gewährt einen kurzen Einblick in die Implementierung.

Abschließend erfolgt in Kapitel 4 die Evaluation und Anwendung des entwickelten Prognosemodells. Zunächst werden in Kapitel 4.1 die Evaluationsszenarien eingeführt, bevor in Kapitel 4.2 exemplarische Ergebnisse für den Netzregelverbund vorgestellt werden. Anschließend werden in Kapitel 4.3 zum einen die Punktprognosen gegen eine statistische Vergleichsprognose – „Persistenz“ – evaluiert, und zum anderen werden die Intervalprognosen an dem aktuellen Sicherheitsniveau gemessen. Aus der anschließenden Anwendung des Prognosemodells für die Regelleistungsbemessung werden die potentiellen Einsparpotentiale für das Testjahr 2013 ermittelt. Dazu werden sowohl Aussagen über die einzusparenden Regelleistungsmengen, als auch die einzusparenden Kosten getroffen. Diese Aussagen werden gegen eine aktuelle Vergleichsstudie (DESIRE14 [Buc14]) evaluiert. Abschließend werden die Ergebnisse für einzelne Regelzonen vorgestellt (Kapitel 4.4) sowie die Evaluationsergebnisse in einer Zusammenfassung diskutiert.

In Kapitel 5 erfolgt schließlich die Zusammenfassung der Arbeit sowie ein Ausblick auf mögliche anschließende Forschungstätigkeiten auf dem Gebiet der Reserve- und Regelleistungsvorhaltung.

2 Vorbereitung - Grundlagen

Im folgenden Kapitel werden sowohl der Anwendungskontext als auch die Datengrundlage vorgestellt. So wird zunächst das aktuelle Regelleistungsdesign in Deutschland vorgestellt bevor anschließend in einer Datenanalyse die Regelleistungsaktivierung der vergangenen Jahre analysiert wird. Abschließend werden die Ergebnisse dieser beiden Unterkapitel gegenübergestellt und mögliche Schwachstellen bzw. Verbesserungspotentiale aufgezeigt. Das Ergebnis dieser Diskussion bzw. ein Abgleich mit bereits bestehenden Arbeiten fließen am Ende des Kapitels in die Zusammenfassung.

2.1 Prozessanalyse

2.1.1 Regelleistung im energiepolitischen Kontext

Alle Maßnahmen der deutschen Energiepolitik orientieren sich am energiepolitischen Zieldreieck mit den Dimensionen *Ökonomie*, *Ökologie* und *Versorgungssicherheit*. Wörtlich formuliert die Bundesregierung in ihrem Energiekonzept das Ziel folgendermaßen [FNE10]:

„Deutschland soll in Zukunft bei wettbewerbsfähigen Energiepreisen und hohem Wohlstandsniveau eine der energieeffizientesten und umweltschonendsten Volkswirtschaften der Welt werden“

Das dazu vorliegende „Energiekonzept 2050“ [FNE10] geht davon aus, dass bis zum Jahr 2050 die „Transformation zu einem vollständig auf der Nutzung erneuerbarer Energiequellen basierten Energiesystem“ gelingt. Auf diesem Energiekonzept basieren die beiden wesentlichen Elemente der deutschen Energiepolitik der letzten Jahre. Zum einen der *Ausbau der Erneuerbaren Energien* und zum anderen die *Liberalisierung des Energiesektors*. Die deutsche Energiepolitik ist dabei, wie die der anderen europäischen Staaten auch, nicht mehr vollständig unabhängig, sondern die nationale energiepolitische Gesetzgebung muss sich an der europäischen Gesetzgebung orientieren¹. Umgesetzt wurde das europäische Recht im deutschen Energiewirtschaftsgesetz (EnWG), indem die Ziele direkt im §1 verankert sind; so wird der Zweck des Gesetzes mit der „sicheren, preisgünstigen, verbraucherfreundlichen, effizienten und umweltverträglichen leistungsgebundenen Versorgung der Allgemeinheit mit Elektrizität und Gas“ definiert.

Im Zuge der Liberalisierung wurde auf dieser Grundlage mit der Entflechtung (engl. „unbundling“) der Unternehmensbereiche in der Energiewirtschaft ein grundlegender Strukturwandel vollzogen, indem die Unternehmensbereiche *Erzeugung*, *Verteilung*, *Handel* und *Vertrieb* voneinander getrennt wurden. Für den Bereich der Stromversorgung sollen damit Wettbewerbsstrukturen geschaffen werden, die einen diskriminierungsfreien Zugang zu dem natürlichen Monopol der leistungsgebundenen Übertragung elektrischer Energie gewährleisten. Nun lässt sich der Bereich *Verteilung* in Deutschland, aufgrund der Nichtsubstituierbarkeit der Stromnetze, nicht in einen freien Wettbewerbsmarkt überführen. Daher sind die Stromnetze in Deutschland durch die gegebenen Strukturen weiterhin in der Hand von vier großen Übertragungsnetzbetreibern: Amprion, Tennet, 50Hertz und TransnetBW, deren geographische Lagen in Abbildung 2.1 dargestellt ist. Europaweit sind die Übertragungsnetzbetreiber (engl. transmission system operator (TSO)) im sogenannten „Verband Europäischer Über-

¹ Diese gründet sich auf der „Richtlinie zur Liberalisierung des Strommarktes“ von 1996, bzw. ihrer Anpassung von 2003 (Beschleunigungsrichtlinie).

tragungsnetzbetreiber“ (engl. „European Network of Transmission System Operators for Electricity“ (ENTSO-E)) miteinander organisiert.



Abbildung 2.1: Geographische Lage der Regelzonen und deren Betreiber in Deutschland²

Um trotzdem einen transparenten liberalisierten Markt zu gewährleisten, wurde mit der Neuregelung des EnWG am 7. Juli 2005 eine Regulierungsbehörde – die sogenannte „Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen“ (BNetzA) – eingerichtet. Sie hat die Aufgabe, durch die Entflechtung und die Regulierung der Elektrizitätsnetze, die Voraussetzungen für einen funktionierenden Wettbewerb auf dem Strommarkt, sowie den ihm vor- und nachgelagerten Märkten zu schaffen und gleichzeitig die Versorgungssicherheit zu gewährleisten. Gemeinsam mit dem Bundeskartellamt bildet sie eine wettbewerbsrechtliche Missbrauchsaufsicht [Kon09]. Für den Bereich der Verteilung wurden in diesem Zuge zwei Verordnungen, die Netzzugangsverordnung Strom (StromNZV) und die Stromnetzentgeltverordnung (StromNEV)³ erlassen, die die konkrete Umsetzung der Gesetze regeln.

Während mit der *Liberalisierung des Energiesektors* damit vor allen Dingen die ökonomischen Ziele umgesetzt wurden, trägt der *Ausbau der Erneuerbaren Energien* durch die Unabhängigkeit von der Importenergie sowohl zur Erreichung der ökonomischen Ziele bei, als auch, durch die Reduzierung des CO_2 Ausstoßes, zu den ökologischen Zielen. Beide Ziele stehen jedoch in direktem Zielkonflikt in Bezug auf die Wahrung der *Versorgungssicherheit*. So erhöht die Zunahme fluktuierender Energiequellen die Unsicherheit im Netz, während gleichzeitig durch die fortschreitende Liberalisierung und Dezentralisierung zentrale Steuer- und Regelungsmöglichkeiten wegfallen.

Den Begriff der *Versorgungssicherheit* definiert ecoplan in einer Studie [eco03] wie folgt:

"Versorgungssicherheit ist die Garantie, dass Elektrizitätsverbraucher elektrische Energie mit definierter Qualität beziehen können, zu dem Zeitpunkt, wenn sie diese benötigen, und zu kostenorientierten und transparenten Preisen."

²Abbildung aus [Ros12]

³ Seit dem 7. Nov. 2007 ist diese durch die Anreizregulierungsverordnung (ARegV) ergänzt.

⁴Eigene Abbildung in Anlehnung an [www.e-control.at], zuletzt geprüft am 10.08.2015.



Abbildung 2.2: Überblick Begriffsfeld Versorgungssicherheit⁴

Gemäß Abbildung 2.2 lässt sich der Begriff *Versorgungssicherheit* zunächst in die beiden Unterpunkte *Versorgungsqualität* und *Versorgungssicherung* unterteilen. Dabei spiegelt der Begriff *Versorgungsqualität* sozusagen die operative *Versorgungssicherheit* wider, während sich die *Versorgungssicherung* um den strategischen langfristigen Erhalt der *Versorgungssicherheit* bemüht. Kern dieser Arbeit ist die operative *Versorgungssicherheit*, die sich wiederum in verschiedene Unterpunkte aufteilen lässt; neben der *Dienstleistungsqualität* sind dies vor allen Dingen die *Versorgungszuverlässigkeit*, die *Verfügbarkeit* und die *technisch-physikalische Produktqualität*, in Form gleichbleibender Frequenz und Spannung. Dieser Bereich der technischen *Versorgungsqualität* wird auch als *System-sicherheit* bezeichnet.

Nach EnWG §§ 1 und 2 liegt die Verantwortung für diese *Systemsicherheit* in Deutschland bei den vier Übertragungsnetzbetreibern, die diese durch die Bereitstellung von sogenannten *Systemdienstleistungen* gewährleisten⁵. Um Frequenz, Spannung und Belastung der Netzbetriebsmittel innerhalb zulässiger Grenzwerte zu halten bzw. nach einer Störung in den Normalbetrieb zurückzuführen, sind die Übertragungsnetzbetreiber befugt in den Netzbetrieb einzugreifen.

Gemäß dem §13 EnWG stehen den Übertragungsnetzbetreibern im Rahmen dieser *Systemdienstleistungen* verschiedene Handlungsoptionen zur Verfügung ([Rol11], Seite 174, [Sch09]):

- **Netzbezogene Maßnahmen** (Netzschaltungen):
Diese Maßnahmen sind Bestandteil der Netzführung und dienen beispielsweise der Wahrung der n-1 Sicherheit oder durch Topologieänderungen dem Engpassmanagement.
- **Marktbezogene Maßnahmen** (Einsatz von Regelernergie):
Marktbezogene Maßnahmen dienen dem Erhalt der Systembilanz, z.B. durch den Einsatz von Regelernergie oder dem Handel am Intraday Markt.
- **Anpassungen** (unplanmäßige Ab-/und Zuschaltungen):
Dies sind Maßnahmen zur Netzführung wie zum Beispiel die Spannungs- und Blindleistungsoptimierung oder das Engpassmanagement durch Re-Dispatch.

⁵ Vor der Liberalisierung lag diese Verantwortung bei den Energieversorgungsunternehmen (EVU).

Die Verfahren zum Design dieser Systemdienstleistungen und damit zur Evaluierung der Versorgungssicherheit lassen sich grundsätzlich in *deterministische* und *probabilistische* Verfahren einteilen [Brü08]. Ein Beispiel für ein *deterministisches* Design ist das (n-1) Kriterium [Kra10]. Dies sieht eine redundante Netztopologie vor, so dass der Ausfall eines Betriebsmittels sich immer durch ein Anderes kompensieren lassen muss. Die Bewertung der damit gewährleisteten Versorgungszuverlässigkeit erfolgt mit Hilfe von Kennzahlen⁶, die Auskunft über die Nutzungsunterbrechungen geben. Für die marktbezogenen Maßnahmen, insbesondere die Reserve- und Regelleistungsbemessung, kann man ebenfalls zwischen deterministischen und probabilistischen Verfahren unterscheiden. Dabei haben die *probabilistischen* Verfahren den Vorteil, die Versorgungszuverlässigkeit quantifizieren zu können ([Kra10], Seite 5). Sie lassen sich weiter unterteilen in analytische und simulative Methoden, wobei Letztere sich wiederum in sequentielle und nicht sequentielle Methoden unterteilen lassen, je nachdem ob die zeitliche Reihenfolge berücksichtigt wird ([Kra10], Seite 41). Abbildung 2.3 zeigt einen Überblick über die möglichen Verfahren zur Regelleistungsbemessung.

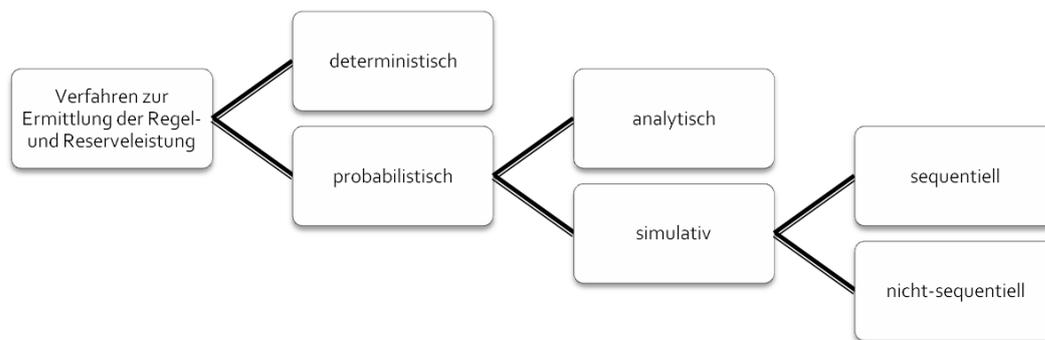


Abbildung 2.3: Verfahren zur Berechnung des Regelbedarfs⁷

Bis zum jetzigen Zeitpunkt (2015) werden in Deutschland für die Regelleistungsbemessung ausschließlich analytische Methoden eingesetzt. So erfolgt die aktuelle Dimensionierung der Regelleistungsmengen mit Hilfe probabilistischer analytischer Methoden⁸. Entscheidende Kennzahl für die Regelleistungsbemessung ist dabei die sogenannte *Defizitwahrscheinlichkeit* (engl. loss of load probability LOLP). Diese gibt die Wahrscheinlichkeit an, ein Leistungsdefizit nicht decken zu können [DVG97]. Die Reserve- und Regelleistung ist entsprechend so zu bemessen, dass zu jedem Zeitpunkt des Jahres die Wahrscheinlichkeit, die Last nicht decken zu können, einen vereinbarten Maximalwert (derzeit 0,025%⁹) nicht überschreitet [DVG97]. Bei einem Leistungsüberschuss, d.h. im Falle negativer Regelleistung, spricht man von *Überschusswahrscheinlichkeiten*. "Das Komplement der Defizitwahrscheinlichkeit bezeichnet man als *Zuverlässigkeitsniveau*" [Brü08, Seite 59].

⁶ Beispiele für diese Kennzahlen sind der SAIDI (System Average Interruption Duration Index) oder der CAIDI (Customer Average Interruption Duration Index).

⁷ Eigene Abbildung nach [Brü08, Seite 61].

⁸ Ein Sonderfall stellt die deterministische Bemessung der Primärregelung dar, die sich aus der Kompensation zweier Kraftwerksausfälle ergibt.

⁹ Dieses Wert gilt jeweils positiv und negativ, d.h. insgesamt ergeben sich 0,05%.

Die Kosten, die diese Systemdienstleistungen (Regelleistung, Verlustenergie und Re-Dispatch) verursachen, machen bereits jetzt in etwa 70 % der gesamten Netzkosten eines Übertragungsnetzbetreibers aus [Bun10]. Werden die Ziele der Bundesregierung hin zu einer Bereitstellung der Energie aus 100 % erneuerbaren Energiequellen umgesetzt, wird sich dieser Anteil weiter erhöhen. So bringt der *Ausbau der Erneuerbaren Energien* einen Anstieg der Volatilität der Erzeugung mit sich, was sowohl zu einem Anstieg der unplanmäßigen Ab- und Zuschaltungen als auch zu einer Zunahme der marktbezogenen Maßnahmen wie dem Einsatz von Regelleistung führen wird.

In Bezug auf die Zunahme der Regelleistungsmengen gibt es verschiedene Studien über die Entwicklung der Bedarfsmengen in Zukunftsszenarien. So errechneten Kays und Schwippe im Jahr 2010 [KSWR10] eine Zunahme an positiver Minutenreserve um das bis zu 1,8-fache für das Jahr 2040 im Vergleich zum Jahr 2008. Und eine Studie der Consentec [Cr10] im Auftrag des Bundeswirtschaftsministeriums ermittelte im Jahr 2010 einen starken Anstieg der Regelleistung ab einem EE-Anteil von 40%. Ab einem Anteil von 50% prognostizierten sie sogar eine Verdopplung der Reservemengen sowie einen Anstieg der positiven Regelenergie auf das 2,3-fache [Cr10]. Im Zuge dieser Berechnungen wurde im Jahr 2010 der sogenannte *Netzregelverbund* (NRV), das heißt ein Zweckverbund der vier deutschen Übertragungsnetzbetreiber, eingeführt. Die Funktionalität dieses Netzregelverbundes wird über vier Module sichergestellt¹⁰; diese umfassen neben der Vermeidung der gegenläufigen Regelleistungsaktivierung, auch eine gemeinsame Regelleistungsdimensionierung, eine gemeinsame Beschaffung von Sekundärregelleistung sowie eine kostenoptimale Regelleistungsaktivierung.

Bei den unplanmäßigen Ab- und Zuschaltungen gab es laut dem jährlichen Monitoringbericht der Bundesnetzagentur [Bun14] im Jahr 2012 im Vergleich zum Jahr 2011 einen Anstieg der Re-Dispatch Maßnahmen um 42,3 % auf 7.160 Stunden¹¹. Die Zahl der Abregelungen von EE-Anlagen aufgrund von Netzengpässen ist zwar im Vergleich zum Jahr 2011 leicht gesunken, trotzdem wurde eine Gesamtstrommenge von 385 Mio. kWh abgeregelt. Dies entspricht Ausgleichszahlungen in Höhe von 33 Mio. Euro. Nach den Daten des aktuellen (2014) Energiewende-Index (EWI) [McK14] mit dem McKinsey seit zwei Jahren den Status der Energiewende analysiert, sind die Gesamtkosten für Netzeingriffe aufgrund von fluktuierenden erneuerbaren Energien im Jahr 2012 im Vergleich zum Jahr 2008 um 100 % gestiegen und betragen insgesamt 165 Mio. Euro.

Im Vergleich zu den Kosten die durch den Einsatz von Regelleistung entstehen, ist dies jedoch eine verhältnismäßig geringe Summe. So beliefen sich die Kosten für die Regelleistung im Jahr 2012 nach Zahlen des Monitoringberichts auf insgesamt 417 Mio. Euro, wobei die Sekundärregelleistung den größten Anteil von 267,07 Mio. Euro hatte. Damit beträgt der Anteil der Regelleistung an den Gesamtkosten der Systemdienstleistungen, die bei 1.077 Mio. Euro liegen, 38,7 %. Die Versorgungssicherheit ist somit nicht nur ein rein technisches Problem, sondern bietet durchaus das Potential der volkswirtschaftlichen Optimierung und damit der Erreichung der ökonomischen Ziele. Insbesondere die Optimierung der Regelleistungsvorhaltung ist daher ein zentrales Ziel auf dem Weg in eine kosteneffiziente Zukunft. Daher wird die Regelleistungsvorhaltung im Folgenden sowohl von der technischen Seite als auch von der marktwirtschaftlichen bzw. rechtlichen Seite betrachtet.

¹⁰ Siehe hierzu [www.netzregelverbund.de], zuletzt geprüft am 10.08.2015.

¹¹ Dies entspricht einem prozentualen Anteil von 82 %.

2.1.2 Technische Grundlagen zur Regelleistung

Zur Gewährleistung einer gleichbleibenden Versorgungsqualität muss die Netzfrequenz, die im europäischen Verbundnetz¹² einheitlich 50 Hertz beträgt, konstant gehalten werden. Da man elektrische Energie im Netz nur in geringen Mengen speichern kann, ist dazu die ständige Systembilanz zwischen Erzeugung und Verbrauch zu halten. Diese Regelungsaufgabe wird daher auch als *Leistungs-Frequenz-Regelung* bezeichnet. Kommt es durch Erzeugungsüberschuss zu einer Erhöhung der Frequenz oder durch einen Verbrauchsüberschuss zu einer Absenkung, so ist es die Aufgabe der Leistungs-Frequenz-Regelung, die Frequenz durch Leistungsanpassungen auf ihren Sollwert zurückzuführen. Dabei wird – abhängig von der Höhe der Abweichung vom Sollwert – zwischen drei Betriebszuständen unterschieden [Sch09].

Bei Schwankungen unter zehn mHz – im Toleranzbereich oder auch Todband genannt – wird der Betriebszustand als normal eingestuft und es erfolgt keine Regelung [Con14a]. Liegt die Differenz zwischen zehn mHz und 200 mHz, liegt ein gestörter Betriebszustand ohne größere Risiken vor, der durch den Einsatz von automatischen Reglern und dem Einsatz von Regelenergie ausgeglichen wird. Überschreitet die Abweichung schließlich die Grenze von 200 mHz, besteht eine erhebliche Gefährdung des Netzbetriebes, die im Extremfall zum Zusammenbruch führen kann. Daher greift ab einer Differenz von 200 mHz der sogenannte fünf-stufige Lastabwurfplan, in dessen Folge sukzessive Last abgeworfen wird, d.h. Verbraucher vom Netz getrennt werden [Sch09]. Abbildung 2.4 zeigt beispielhaft die Frequenzregelung bei einem Ausfall von zwei Kraftwerken mit einer Leistung von insgesamt drei GW¹³ im Schwachlastfall.

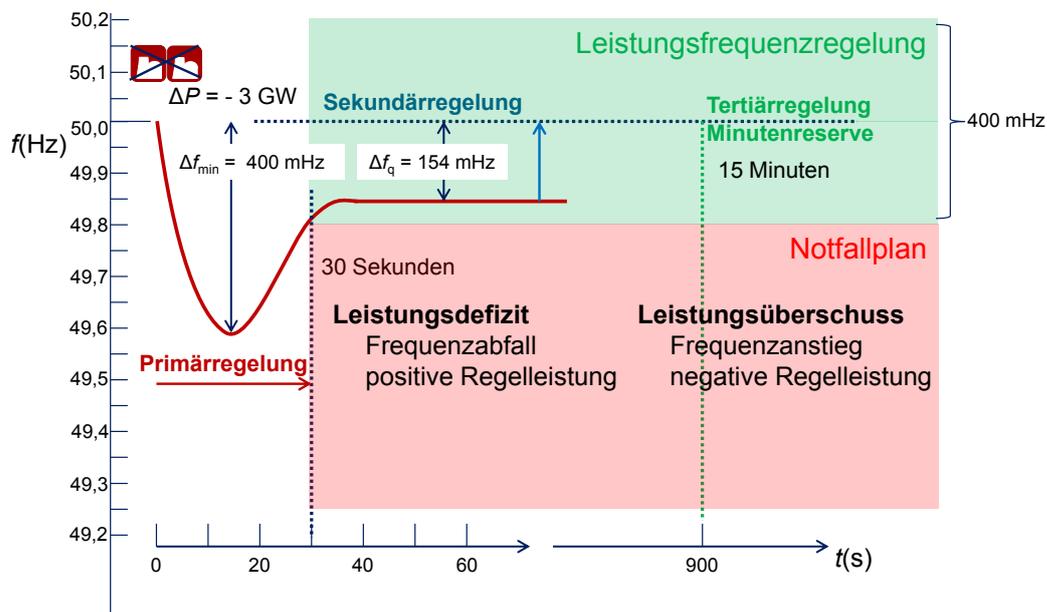


Abbildung 2.4: Rückführung der Netzfrequenz bei Kraftwerksausfall¹⁴

¹² Das technische Verbundnetz ist der Bereich des kontinentaleuropäischen Netzes (ehemals UCTE) im Unterschied zum organisatorischen Gebiet der ENTSO-E.

¹³ Dies entspricht dem Auslegungsfall der Primärregelung im europäischen Verbundnetz.

¹⁴Eigene Abbildung in Anlehnung an [Wei09b, Seite 12].

Wie stark sich eine Leistungsabweichung dabei auf die Netzfrequenz auswirkt, ist abhängig von der Größe und Zusammensetzung des Netzes. So sorgen im Netz befindliche rotierende Massen sowie der sogenannte Netzselbstregeleffekt dafür, dass die Frequenzabweichungen zum Teil abgefangen werden können. Dieses Abfangen eines Frequenzabfalls lässt sich in drei Phasen unterteilen. In der ersten Phase werden die im Netz befindlichen rotierenden Massen zum Ein- bzw. Ausspeichern der Rotationsenergie genutzt, was auch als Momentanreserve bezeichnet wird. In einer zweiten Phase wird der Frequenzabfall durch den Netzselbstregelungseffekt abgebremst bevor in der dritten Phase die *Primärregelleistung* (PRL) eingesetzt wird. Die resultierende Frequenzabweichung Δf_q wird schließlich durch *Sekundärregelleistung* (SRL) ausgeglichen.

Wie hoch diese verbleibende auszugleichende Frequenzabweichung ist, ergibt sich aus der sogenannten Netzleistungszahl K_L , die eine Berechnung der Frequenzabsenkung im Verhältnis der ausgefallenen Leistung ermöglicht [Sch09]. Im europäischen Verbundnetz beträgt diese Netzleistungszahl in Schwachlastzeiten ca. 16.000 MW/Hz und in Starklastzeiten ca. 18.000 MW/ Hz, d.h. für eine Frequenzänderung von 1 Hz ist in Starklastzeiten eine Leistungsdifferenz von 18.000 MW erforderlich [Sch09, Seite 698]. Darin enthalten ist die im europäischen Verbundnetz vorgehaltene *Primärregelleistung* von 3.000 MW. Setzt man die maximal zulässige Frequenzabweichung von $\Delta f = 200$ mHz zugrunde, entspricht dies einer Leistungszahl von 15.000 MW/Hz.

Die tatsächliche Netzleistungszahl ist somit – je nach Last im Netz – höher als die durch die Vorgaben der ENTSO-E einzuhaltenen Untergrenze. Die Differenz ergibt sich in etwa zu gleichen Teilen aus dem Verbraucherselbstregeleffekt und aus dem sogenannten „surplus-control of generation“, d.h. aus drehzahlgeregelten Erzeugern, die nicht an der Primärregelung teilnehmen [Wei09b]. Man kann die Netzkennzahl daher nach *Primärregelleistung* und *Netzselbstregeleffekt* aufteilen und man erhält nach [Wei09a]:

Netzleistungszahl getrennt nach PRL und Netzselbstregeleffekt:

$$K_L = \underbrace{\frac{\Delta P}{\Delta f}}_{PRL} + \overbrace{\frac{k_{pf} P_0}{f_0}}^{\text{Selbstregeleffekt}} \quad (2.1)$$

Der Netzselbstregeleffekt hängt somit sowohl von der entsprechenden Kennzahl k_{pf} , d.h. von der entsprechenden Leistungs-(p), Frequenz-(f)statik als auch von der aktuellen Netzlast P_0 ab. Die nach Einsatz von Primärregelung verbleibende quasistationäre Frequenzabweichung wird nach 30 Sekunden durch den Einsatz von *Sekundärregelleistung* ausgeglichen.

Während die Primärregelung direkt in den Kraftwerken erfolgt, wird die Sekundärregelleistung im Netz über einen übergeordneten Frequenzregler, den sogenannten Sekundärregler geregelt. So besteht die Möglichkeit, sie – im Unterschied zur Primärregelleistung – zentral zu steuern und somit Ungleichgewichte über Regelzonen hinweg auszugleichen. Dieser Regler berechnet die notwendige Aktivierung von Sekundärregelreserve, indem er kontinuierlich die Übergabeleistungen der Regelzone an Nachbarregelzonen bzw. die Netzfrequenz mit den entsprechenden Sollwerten vergleicht [Con14a]. Er gibt daraufhin ein entsprechendes Sollsignal an die informationstechnisch direkt an den Regler angeschlossenen Regelkraftwerke bzw. Kraftwerkspools weiter [Con14a]. Tritt zum Beispiel

in einer Regelzone ein Kraftwerksausfall auf (wie in Abbildung 2.4 dargestellt), so wird diese Regelzone solange "überspeist", bis die Frequenz in der Regelzone auf ihren Normalwert zurückgekehrt ist und die Primärregelleistung vollständig deaktiviert ist [Con14a].

Nach 15 Minuten erfolgt die Ablösung der Sekundärregelleistung durch die sogenannte *Minutenreserveleistung* (MRL). Der Einsatz der Minutenreserve erfolgt nicht weiter über ein kontinuierliches Regelsignal sondern als Fahrplanlieferung in 15-Minuten-Intervallen. Die Aktivierung erfolgt seit dem 03.07.2012 automatisiert¹⁵ über alle Regelzonen hinweg nach aufsteigender Reihenfolge der angebotenen Arbeitspreise (engl. Merit Order). Im Gegensatz zur rein technischen Frequenzregelung ist die Minutenreserve daher eine nach wirtschaftlichen Aspekten optimierte Stromerzeugung und Verteilung (eng. economic dispatch) [Sch09]. Die Bereitstellung von Minutenreserve erfolgt maximal in vier Viertelstunden, inklusive der Viertelstunde, in der die Leistungsregelung begann. Sollte nach einer Stunde eine weitere Frequenzabweichung vorliegen, so erfolgt der Ausgleich durch die sogenannte *Stundenreserve*, die nicht mehr Teil der eigentlichen Leistungs-Frequenz-Regelung ist [Cra12].

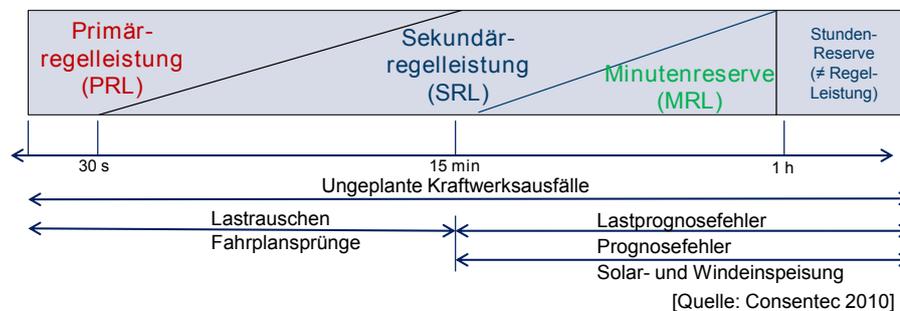


Abbildung 2.5: Regelleistungsarten und ihre Einflussfaktoren¹⁶

In Abbildung 2.5 sind die verschiedenen Regelleistungsarten und die Stundenreserve in ihrer zeitlichen Abfolge sowie die jeweils entscheidenden Einflussgrößen dargestellt. So liegen neben den in Abbildung 2.4 gezeigten Kraftwerksausfällen, die Ursachen für den Abruf von Regelleistung unter anderem in Prognoseabweichungen, Lastschwankungen oder sogenannten Fahrplansprüngen. Diese unterschiedlichen Einflussgrößen werden im folgenden Kapitel näher erläutert.

2.1.3 Ursachen für Bilanzungleichgewichte

Während früher vor allen Dingen *Kraftwerksausfälle* und *Lastprognosefehler* sowie *stochastische Lastschwankungen* für Bilanzungleichgewichte und damit den Einsatz von Regelleistung verantwortlich waren, sind es durch die Liberalisierung und den damit verbundenen europäischen Stromaus-tausch (Stromtransiten) sowie die Zunahme erneuerbarer Energiequellen an der Erzeugung zusätzlich *Fahrplansprünge* und *Prognosefehler durch dargebotsabhängige Einspeisung*. Des Weiteren ist eine Zunahme von „nicht natürlichen“ Einflüssen auf die Frequenzregelung zu erkennen, wie zum Bei-spiel der Einfluss des Strommarktes für Wirkleistung. Diesen Einflussgrößen liegen im Unterschied

¹⁵ Dazu betreibt Amprion einen Merit-Order-List-Server (MOLS), der mit den MRL-Anbietern, beispielsweise mit dem Mols-Anbieter-Client (Merlin) über das Internet auf Basis des Datenaustauschstandards XML kommuniziert [Spe12].

¹⁶Eigene Abbildung in Anlehnung an [Con08].

zu den natürlichen Einflussgrößen – beispielsweise Prognosefehler aus der Winderzeugung – keine stochastischen Naturprozesse zugrunde, sondern es handelt sich um von Menschen induzierte Prozesse. Diese Prozesse lassen sich nur bedingt durch Zufallsprozesse abbilden, sondern tendieren dazu, bestimmten strategischen Mustern zu folgen. Nachfolgend werden die einzelnen Einflussfaktoren auf den Regelleistungsbedarf kurz vorgestellt:

Bei den **Lastschwankungen** ist zwischen den *Lastprognosefehlern* und dem stochastischen Lastverhalten – sogenanntes *Lastrauschen* – zu unterscheiden. Während für das Lastrauschen eine normalverteilte Zufallsgröße mit einer Standardabweichung von 0,5 % vorgeschlagen wird [Con08], gibt es für die Modellierung des Lastprognosefehlers zwei verschiedene Möglichkeiten. Zum einen eine mittelwertfreie Normalverteilung mit einer Standardabweichung von 2 % – 3 % der Regelzonenhöchstlast und alternativ die Analyse von Zeitreihen bereinigt von Kraftwerksausfällen, was allerdings die dargebotsabhängigen Prognosefehler weiterhin überlagern würde [Con08]. In dieser Arbeit kann die nachgefragte Last bzw. der Lastprognosefehler nicht analysiert werden, da er als Zeitreihe nicht für alle Regelzonen zur Verfügung steht. Zur weiteren Analyse wird stattdessen die *vertikale Netzlast* verwendet. Diese ist definiert als „die vorzeichenrichtige Summe aller Übergaben aus dem Übertragungsnetz über direkt angeschlossene Transformatoren und Leitungen zu Verteilungsnetzen und Endverbrauchern“ (siehe www.amprion.net). Dabei kann die vertikale Netzlast auch negative Werte annehmen, wenn in den unteren Netzebenen mehr Energie erzeugt, als von den direkt angeschlossenen Verbrauchern benötigt wird. In diesem Fall wird die Energie ins Übertragungsnetz zurückgespeist und in einer anderen Regelzone „verbraucht“ oder ins Ausland exportiert¹⁷. Die Summe der vertikalen Netzlast über die vier Regelzonen ist somit zwar ein Anhaltspunkt für das Lastverhalten der Verbraucher, liegt jedoch unter der tatsächlich „verbrauchten“ Energie¹⁸, da ein Teil der Verbraucher bereits durch die in den unteren Netzebenen angeschlossenen Erzeuger versorgt werden.

Bei diesen, in den unteren Netzebenen angeschlossenen Erzeugern, handelt es sich in erster Linie um dezentrale Einheiten auf Basis erneuerbarer Energiequellen (Wind, Sonneneinstrahlung). Da die Erzeugung von elektrischer Energie aus diesen dargebotsabhängigen Energiequellen nicht exakt prognostizierbar und ohne Zwischenspeicherung¹⁹ auch zum jetzigen Zeitpunkt nicht steuerbar ist, kommt es zu **dargebotsabhängigen Prognosefehlern**. Dabei steigt die Prognosegenauigkeit mit kürzer werdendem Prognosehorizont deutlich an. So reduziert sich der Prognosefehler bei einem Prognosehorizont von vier Stunden (Intraday) im Vergleich zur Ein-Tages-Prognose (One-Day-Ahead) um mehr als ein Drittel. Tabellen 2.1 und 2.2 zeigen beispielhaft die mittleren Prognosefehler für Wind- und PV-Einspeisung für die Regelzone von Tennet.

	2009	2010	2011	2012
One-Day-Ahead	4,86	3,93	3,69	3,53
Intraday	3,67	2,48	2,08	1,81

Tabelle 2.1: mittlere Prognosefehler (RMSE) für Windenergie²⁰

¹⁷ Sie hierzu [www.ffe.de], zuletzt geprüft am 10.08.2015.

¹⁸ Energie kann nicht verbraucht, sondern nur umgewandelt werden.

¹⁹ Eine Zwischenspeicherung ist aktuell (2015) aufgrund ausreichender Speicherkapazitäten nicht möglich.

²⁰ Die Zahlenwerte entstammen [www.tennet.de], zuletzt geprüft am 10.08.2015.

	2009	2010	2011	2012
One-Day-Ahead	6,69	4,82	4,90	4,21
Intraday	6,60	4,29	3,50	3,11

Tabelle 2.2: mittlere Prognosefehler (RMSE) für PV-Einspeisung²⁰

Zur Vorhersage der Windeinspeisung greifen die ÜNB auf die Prognosewerte von speziellen Dienstleistern zurück²¹. Der im Internet frei veröffentlichte Stand entspricht jeweils 8:00 Uhr des Vortages. Dabei wird für jede Viertelstunde ein Leistungswert in Megawatt (MW) angegeben. Dabei gibt es eine „Informationslücke“ in den Datenbanken der ÜNB hinsichtlich der Erzeugung und Last in den untergeordneten Spannungsebenen [DEN10]. So fehlen den ÜNB für die Erstellung von Prognosemodellen "realitätsnahe Einspeise- und Lastprognosen bzw. aktuelle Ist-Werte"[Bun11]. Insbesondere schwer vorherzusagen sind dabei sogenannte Windrampen, d.h. sehr kurzfristige Leistungsänderungen, die mit dem Anteil installierter Windleistung ansteigen. Dies ist besonders in prozentual stark betroffenen Regelzonen problematisch. So betrug die installierte Leistung von Windenergieanlagen (WEA) in Deutschland zum Jahresende 2013 ca. 33.500 Megawatt²², wobei der Hauptteil (ca. 40 %) dieser Anlagen in der Regelzone von 50 Hertz einspeist²³. Dementsprechend lag der maximale Leistungssprung innerhalb einer Viertelstunde in der 50 Hertz Regelzone im Jahr 2013 bei +1.431 MW bzw. -901 MW²⁴. Die maximalen Stundensprünge lagen sogar doppelt so hoch und betrug im Jahr 2013 +2.265 MW bzw. -2.245 MW. Diese sind vor allen Dingen auf die Zunahme von Offshore- und großen Onshore-Windparks und den damit verbundenen hohen Leistungskonzentrationen zurückzuführen. So führen fehlerhafte Vorhersagen aufgrund der zeitlichen Veränderung des Windfeldes oder im zeitlichen Durchzug von Wetterfronten zu teilweise erheblichen Leistungsdifferenzen, die die Inanspruchnahme von Sekundärregelleistung zur Folge haben [Brü08].

Diese Inanspruchnahme der Regelleistung in Folge von Windprognosefehlern ist auch der Tatsache geschuldet, dass die dezentralen Erzeugungseinheiten bis heute nahezu ausschließlich ohne Beeinflussungsmöglichkeit durch den Systembetreiber betrieben werden. Insbesondere kleine dezentrale Einheiten unterliegen nicht den Anforderungen, die an Erzeuger im liberalisierten Markt gestellt werden, sondern werden überwiegend als Teil der Verbraucher behandelt. Dies führt dazu, dass sie aus Sicht des Übertragungsnetzbetreibers lediglich als Veränderung der Nettolast wirken, deren Bandbreite und Volatilität damit zunimmt [CW12]. So müssen, im Unterschied zu zentralen Kraftwerken, Betreiber von dezentralen Erzeugungsanlagen (DEA) keine Leistungsfahrpläne einhalten, sondern können elektrische Energie einspeisen, solange die Anschlussbedingungen erfüllt sind [Ri10], [VDE06]. Nach § 8 EEG besteht für die Verteilnetzbetreiber (VNB) eine Aufnahmepflicht (sog. Einspeisevorrang). Der so eingespeiste EEG-Strom kann vom Hersteller seit dem Januar 2012 entweder im Rahmen der Direktvermarktung selbst am Markt angeboten werden oder die EEG-Mengen werden über die Übertragungsnetzbetreiber an der Börse²⁵ (Spotmarkt und Intraday) veräußert²⁶ und der

²¹ Für die Regelzone von 50 Hertz sind dies beispielsweise energy und meteo systems , EuroWind , Fraunhofer IWES, meteomedia und WEPROG.

²² Davon entfielen ca. 400 MW auf Offshore-Anlagen.

²³ Siehe hierzu [www.50hertz.com], zuletzt geprüft am 10.08.2015.

²⁴ Diese Größenordnungen sind vergleichbar mit einem Kraftwerksausfall.

²⁵ Die für Deutschland zuständige Börse ist die European Energy Ex-Change in Leipzig (EEX).

²⁶ Eine Neuauflage des EEG 2014 sieht künftig eine alleinige Direktvermarktung der EEG Strommengen vor.

Anlagenbetreiber erhält die gesetzliche Mindestvergütung²⁷. Die eingespeisten EEG-Mengen werden entsprechend der aktuell nachgefragten Netzlast zwischen den Regelzonen aufgeteilt – sogenannter „horizontaler Belatungsausgleich“ (HoBa) [Cr10]. Die ÜNB betreiben hierzu jeweils einen sogenannten EEG-Bilanzkreis. Ein auftretender Prognosefehler der Erzeugungsleistung kann damit zu Bilanzungleichgewichten führen, wenn die marktwirtschaftlichen Maßnahmen zum Fehlerausgleich im Zuge der Bewirtschaftung des EEG-Bilanzkreises nicht ausreichend waren [Con08]. So wird die ursprünglich prognostizierte Menge an EEG Strom an der Börse gehandelt, die entstehenden Leistungsdifferenzen durch Prognoseverbesserungen werden am sogenannten Intraday Markt nachverhandelt und nur der verbleibende Rest wird über die Ausgleichsenergie geregelt. Der davon nicht regelzonenintern auszugleichende Anteil wird über Regelenergie gedeckt.

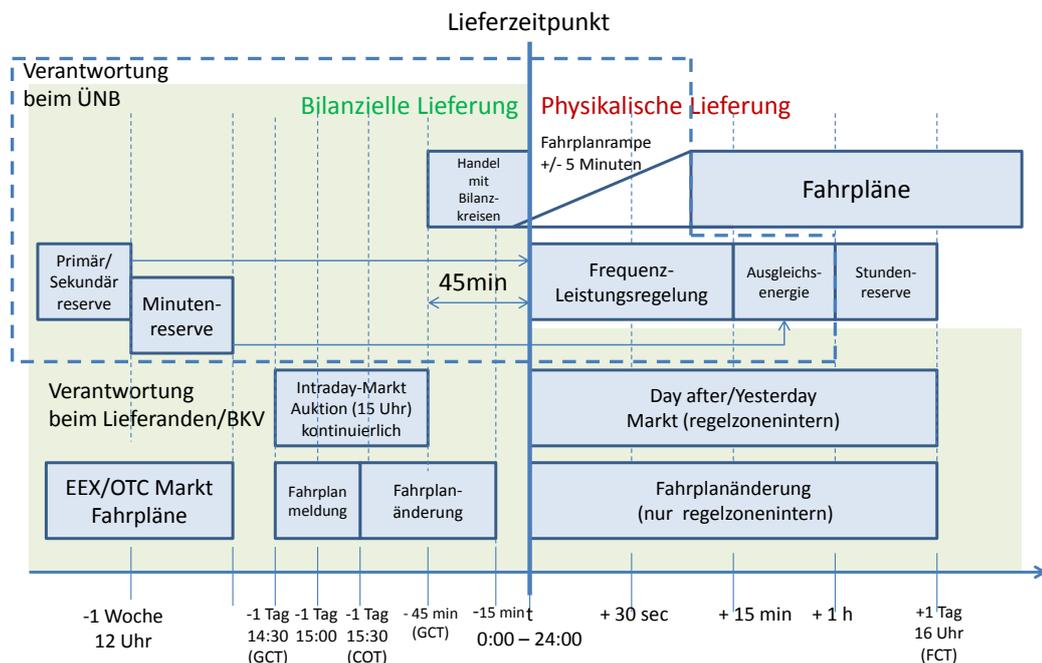


Abbildung 2.6: Zeitliche Einordnung der Strommarktprodukte

Die Menge bzw. die Aktivierung der Regelleistung hängt somit entscheidend mit den Produkten am Wirkleistungsmarkt zusammen, sowohl was den Preis als auch die zeitliche Struktur anbetrifft. Abbildung 2.6 zeigt einen Überblick über die verschiedenen Strommarktprodukte und ihre zeitliche Einordnung. Unter anderem erfordert die Steuerbarkeit des Netzes bzw. die Systemsicherheit, dass der physische Stromhandel mit einer gewissen Vorlaufzeit vor dem Lieferzeitpunkt beendet werden muss. Der früheste Liefertermin im Spotmarkt an der Börse ist daher der folgende Tag (sogenannter „Day-Ahead-Markt“) aufgeteilt in 24 Stundeneinheiten²⁸. Ferner besteht die Möglichkeit im sogenannten Terminmarkt auch einen beliebigen späteren Lieferzeitpunkt zu vereinbaren. Diese so gehandelte Energie wird dann „fahrplanmäßig“ produziert, d.h. der Einsatz der Kraftwerke und der Betrieb der Netze erfolgt auf Basis von sogenannten „Fahrplänen“, daher der deutsche Begriff „Fahrplanener-

²⁷ Die gesetzliche Mindestvergütung wird sowohl aus den Markterlösen an der Börse sowie den EEG-Umlagen der Endkunden generiert.

²⁸ Da es sich bei Strom um einen Warenstrom handelt ist die gehandelte Einheit MWh.

giemarkt“. Dazu werden die Fahrpläne nach der sogenannten Gate-Closure-Time (GCT) an der EEX zwischen den Regelzonen abgeglichen und bis 15:30 Uhr der sogenannten Cut-Off-Time (COT) gegebenenfalls korrigiert. Dieser Prozess des Fahrplanmanagements wird auch „Dispatch“ genannt²⁹. Der Strommarkt für Fahrplanenergie in Deutschland lässt sich nach zwei Kriterien aufteilen. Zum einen unterscheidet man hinsichtlich der Frist der Strombereitstellung zwischen Spot- und Terminmarkt, und zum anderen gibt es eine Einteilung nach der Marktform zwischen Börse und bilateralen „Over-The-Counter-Handel“ (OTC). Darüber hinaus gibt es an der deutschen Börse seit dem September 2006 einen untertägigen Handel den sogenannten Intraday-Handel, auf dem nach der zentralen Auktion bilateral über die Plattform der EEX, Strom für den aktuellen Tag gehandelt wird. Dabei kann auf dem Intraday sowohl in Stundenkontrakten, als auch in 15 Minutenkontrakten gehandelt werden³⁰. Die Gate-Closure-Time am Intraday endet jeweils 45 Minuten vor Lieferung³¹; dies ist auch der Zeitpunkt an dem die Verantwortung für die Netzstabilität auf den ÜNB übergeht [HJ08, Seite 86]. In den verbleibenden 45 Minuten findet der Handel zwischen dem Übertragungsnetzbetreiber und den Bilanzkreisen mit Ausgleichsenergie statt. Im Anschluss ist es bis 16:00 Uhr des folgenden Handelstages grundsätzlich möglich, Bilanzkreisabweichungen nachträglich durch Meldung beim Netzbetreiber zu „heilen“, wenn ein Marktteilnehmer seine verursachten Abweichungen vom Fahrplan mit entsprechenden Positionen anderer Marktteilnehmer innerhalb derselben Regelzone verrechnen kann³². Dies geschieht auf dem sogenannten „rückwirkenden Handel“³³. Um 16:00 Uhr³⁴ erfolgt mit der abschließenden Versendung des „Final Confirmation Reports“ durch den Übertragungsnetzbetreiber an die Bilanzkreise die endgültige Mengenfeststellung der zu valutierenden Ausgleichsenergie [Spe12].

Durch diese Strommarktprodukte bzw. die Abbildung von kontinuierlichen Last-/Erzeugungskurven auf diskrete Fahrpläne entstehen sogenannte **Fahrplansprünge**. So müssen sowohl die Lastkurve als auch die Einspeisekurven der EE-Einspeisung in Fahrpläne bzw. Stromprodukte überführt werden.

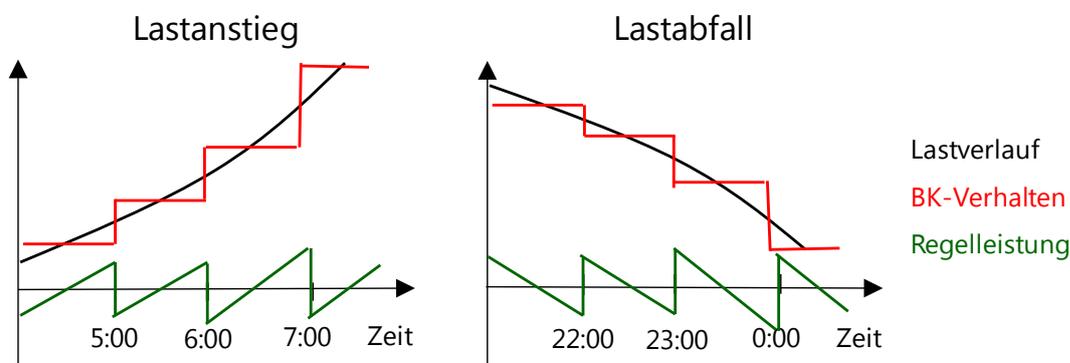


Abbildung 2.7: Fahrplansprünge - Vermutetes Verhalten der Regelzonenbetreiber³⁵

²⁹ Siehe hierzu Fahrplanmeldung in Deutschland mit Hilfe des ENTSO-E Scheduling System (ESS) [www.amprion.net], zuletzt geprüft am 10.08.2015.

³⁰ Seit dem Herbst 2014 ist ein Handel mit 15 Minutenkontrakten auch am Spotmarkt der EEX möglich.

³¹ Da der Einsatz der Regelleistung in Echtzeit erfolgen muss, kann er nur sinnvoll koordiniert werden, wenn nicht gleichzeitig noch physische Handelsgeschäfte auf dem Produktmarkt getätigt werden können [Lie12].

³² Hierbei handelt es sich quasi um eine buchungstechnische Erfassung einer bereits vorher physisch geflossenen Stromlieferung [spot-ex.de], zuletzt geprüft am 10.08.2015.

³³ Dieser Markt wird auch Yesterday bzw. Day-After-Market genannt [www.spot-ex.de], zuletzt geprüft am 10.08.2015.

³⁴ Final-Confirmation-Time (FCT)

³⁵ Abbildung aus [Cr10, Seite 14].

Da diese Fahrpläne entsprechend den am Markt gehandelten Produkten größtenteils stündlich angepasst werden, ergeben sich zu Beginn einer jeweiligen Stunde treppenförmige Abweichungen zwischen den tatsächlichen Kurven und den generierten Fahrplänen. Diese Abweichungen müssen durch Regelleistung ausgeglichen werden und es ergibt sich für die Regelleistungsaktivierung eine „Sägezahn“-Struktur, die um den Nullpunkt schwankt.

Für die Lastkurve ist dies in Abbildung 2.7 dargestellt. Die Steigung ist entsprechend dem Lastverlauf vormittags ansteigend und nachmittags bei Lastabfall absteigend. Neben diesen Sprüngen innerhalb einer Regelzone entstehen weitere Sprünge durch den Austausch von Leistungen zwischen den einzelnen Regelzonen. So kann es durch den volatilen Austausch von Leistungen bzw. Fahrplänen zwischen den Regelzonen zu Sprüngen zwischen den Fahrplänen zweier aufeinander folgenden Viertelstunden kommen. Diese Abweichungen können sowohl positiv (Leistungsüberschuss/Stromexport) als auch negativ (Leistungsdefizit/Stromimport) sein [Brü08]. Die Ausregelung dieser Sprünge erfolgt nun nicht durch eine sprunghafte Veränderung des im Sekundärregler hinterlegten Sollwerts für den Austausch der Regelzone, vielmehr wird der Fahrplansprung durch eine „rampenförmige Anpassung des Sollwerts“ umgesetzt. Der Zeitraum für die Dauer der Leistungsanpassung vom alten zum neuen Sollwert ist auf 10 Minuten festgesetzt (+/-5 Minuten) [Con08]. Die dabei entstehenden „Ausgleichsflächen“ werden mit positiver bzw. negativer Ausgleichsenergie gefüllt. Die Höhe dieser Sprünge hängt zum einen mit den über die Regelzonen hinweg gehandelten Strommengen (Stromtransit) als auch mit dem horizontalen Bilanzausgleich (HoBa) zusammen, daher die Bezeichnung „HoBa-Sprünge“. So muss auch die regelzonenübergreifende EEG-Menge anschließend innerhalb der aufnehmenden Regelzone durch die Anpassung der konventionellen Kraftwerksleistung angepasst werden, was zu weiteren Sprüngen führt. Tabelle 2.3 zeigt die Parameter der Fahrplansprünge für das Jahr 2008, wie sie in der aktuellen Regelleistungsbemessung berücksichtigt werden.

Netzbetreiber	Regelzonenhöchstlast[MW]	σ /Regelzonenhöchstlast [%]
Amprion	30.346	0,97
Tennet	23.286	1,05
50 Hertz	14.663	1,13
TransnetBW	10.800	1,23

Tabelle 2.3: Regelzonenungleichgewichte aufgrund von Fahrplansprüngen im Jahr 2008)³⁶

Weitere Fahrplansprünge ergeben sich aus der Anpassung der kontinuierlichen Kurve der PV-Einspeisung in Fahrplanprodukte an der Börse. Ähnlich den Fahrplansprüngen bei konventionellen Kraftwerken entsteht auch hier ein „sägezahnförmiger“ Regelleistungsbedarf, allerdings mit umgekehrten Vorzeichen. So wird vormittags zu Beginn einer Stunde mehr Energie gehandelt als produziert wird (Unterdeckung - positiver RL-Bedarf) und nachmittags entsprechend weniger gehandelt als produziert wird (Überdeckung - negativer RL-Bedarf). Ein Großteil dieses Mismatching zu Beginn bzw. am Ende jeder vollen Stunde wird seit dem Jahr 2011 durch Viertelstunden-Produkte am Intraday-Markt abgedeckt. So spiegeln die Preise für die Viertelstundenprodukte am Intraday genau den Bedarf an Ausgleichsenergie aufgrund von Fahrplansprüngen wider (siehe Abbildung 2.8) [Buc14].

³⁶Werte aus [Con08], die Netzbetreiber hatten 2008 noch andere Namen zur Vergleichbarkeit wurden die heutigen Namen angegeben.

³⁷Abbildung aus [Buc14, Seite 102].

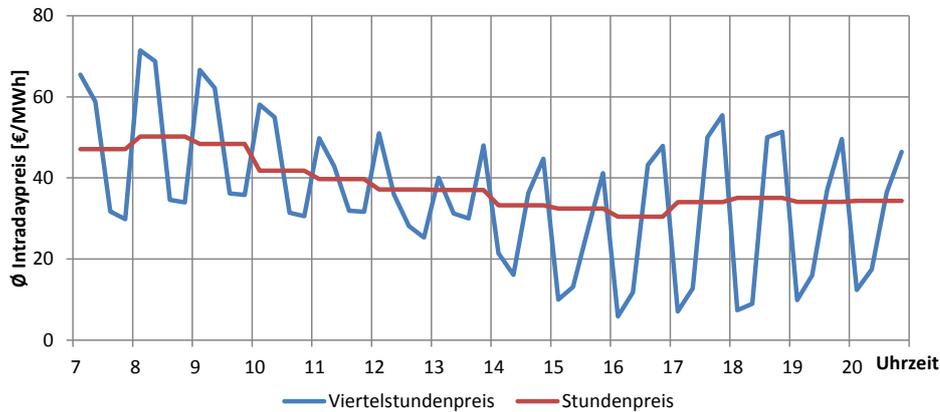


Abbildung 2.8: Verlauf der Preise für Viertelstundenprodukte am Intraday-Markt³⁷

2.1.4 Formalisierung Regelzonensaldo

Die entscheidende Größe der Systembilanz und damit für den Bedarf an Regelleistung ist der über die vier Regelzonen aufsummierte gemeinsame *Regelzonensaldo*. Laut Definition der Netzbetreiber³⁸ entspricht der *Regelzonensaldo* jeder einzelnen Regelzone den Abweichungen aller Bilanzkreise innerhalb der Regelzone und ist äquivalent zum Bezug von Regelleistung innerhalb der Regelzone. Die Werte sind dabei vorzeichenreu, d.h. ein positiver Regelzonensaldo entspricht dem Bezug von positiver Regelleistung, um eine unterdeckte Regelzone auszugleichen und umgekehrt. Abbildung 2.9 zeigt schematisch die Berechnung des Regelzonensaldos.

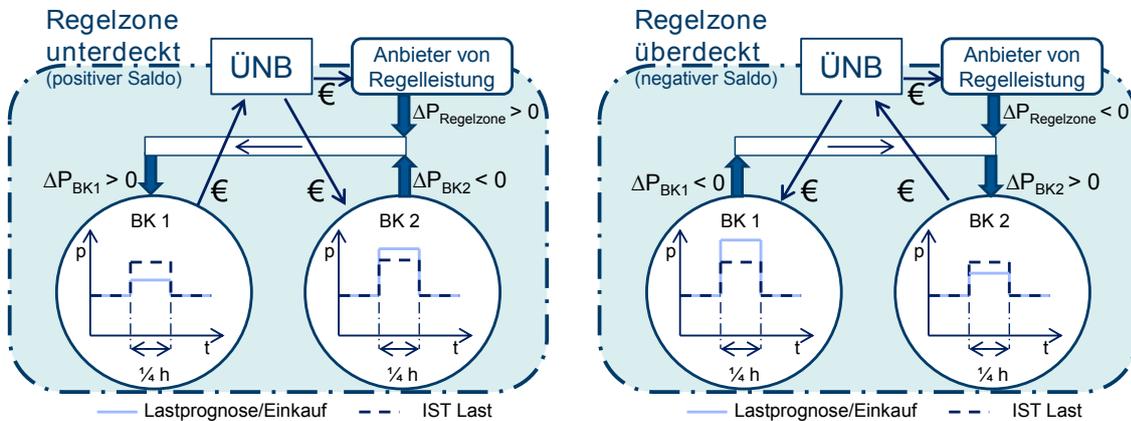


Abbildung 2.9: Berechnung des Regelzonensaldos³⁹

Jede Regelzone besteht aus sogenannten Bilanzkreisen, wobei jeder Bilanzkreis entsprechend seiner Lastprognose die erforderliche Energiemenge über einen Einkauf der entsprechenden Mengen am Wirkleistungsmarkt beschafft. Kommt es nun zu einer Abweichung zwischen der tatsächlich eingetretenden IST-Last und den eingespeisten Leistungen, entsteht innerhalb eines Bilanzkreises eine

³⁸ Siehe hierzu [www.regelleistung.net], zuletzt geprüft am 10.08.2015.

³⁹ Abbildung aus [Brü08, Seite 5](Vorzeichen geändert und Leistung statt Arbeit)

Leistungsdifferenz $\Delta P_{BK} = \text{IST-Last} - \text{Lastprognose}$. Diese Ungleichgewichte werden durch den Übertragungsnetzbetreiber in Form von Ausgleichsenergie kompensiert⁴⁰. Ein Großteil der Ungleichgewichte gleicht sich dabei bereits innerhalb einer Regelzone aus, da in den Bilanzkreisen in der Regel Abweichungen in beide Richtungen auftreten⁴¹. Dazu kauft der ÜNB den Bilanzkreisen, die mehr als im Fahrplan angegeben ins Netz einspeisen, die überschüssige Energie ab, d.h. der ÜNB setzt negative Ausgleichsenergie ein. Den Bilanzkreisen, die unterspeisen, verkauft er positive Ausgleichsenergie. Der Ausgleichsenergiemarkt ist damit ein Monopol, indem in einer Regelzone jeweils ein Anbieter von Ausgleichsenergie (ÜNB) vielen Nachfragern (Bilanzkreisen) gegenüber steht. Dieses Marktmodell bedarf der Regulierung durch die Bundesnetzagentur. So wird die Abrechnung der Regelleistung über die Ausgleichsenergie im §8 der StromNZV geregelt. Im Gegensatz zum Regelleistungsmarkt wird hier jedoch nicht die angebotene Menge sondern der Preis reguliert. So wird der Preis für gelieferte Ausgleichsenergie über den regelzonenübergreifenden einheitlichen Bilanzausgleichsenergiepreis (reBAP) geregelt. Der jeweilige Bilanzkreisverantwortliche (BKV) bildet dabei die Schnittstelle zwischen den ÜNB und den Netznutzern bzw. Erzeugern und übernimmt die wirtschaftliche Verantwortung für Ungleichgewichte zwischen Einspeisung und Entnahme aufgrund von Prognoseungenauigkeiten oder Produktionsausfällen innerhalb seines Bilanzkreises.

Die resultierende Differenz zwischen Einspeisungen und Entnahmen in der gesamten Regelzone $\Delta P_{\text{Regelzone}} = \sum \Delta P_{BK}$ stellt den Regelzonensaldo dar. Diese Regelzonensalden werden aufsummiert und sowohl untereinander als auch mit den assoziierten Nachbarstaaten ausgeglichen. Es verbleibt der Regelzonensaldo für den Netzregelverbund ΔP_{NRV} , der im weiteren als „Regelsaldo“ bezeichnet wird. Dieser Regelsaldo wird durch alle Übertragungsnetzbetreiber gemeinsam in Form von Regelenergie ausgeglichen. Die Mengen an Ausgleichsenergie liegen somit deutlich höher als die eingesetzte Regelenergie.

Aufgrund der Tatsache, dass der Regelleistungseinsatz in Echtzeit erfolgt, ist es möglich, dass innerhalb einer Viertelstunde sowohl positive als auch negative Regelleistung abgerufen wird [Lie12, Seite 52]. Diese Tatsache betrifft jedoch hauptsächlich die Primärregelleistung, daher wird dieser Aspekt in dieser Arbeit vernachlässigt. Abbildung 2.10 zeigt beispielhaft den aufsummierten Regelsaldo sowie den Abruf von Regelleistung für den 1. Dezember 2012 im Netzregelverbund⁴². Die Kurve des Regelsaldos wird quasi ausgefüllt durch den Abruf von Regelleistung. Gut zu erkennen sind die sägezahnförmigen Verläufe der Fahrplansprünge. Weiterhin auffällig ist der starke Abfall des Saldos ab 17:00 Uhr, so dass die „Sägezähne“ bzw. der Saldo nicht länger um den Nullpunkt schwanken, und sich somit positive und negative Regelleistung halbstündlich abwechseln, sondern der Verlauf fast komplett unterhalb der Nullgrenze und damit im negativen Regelleistungsbereich verbleibt.

Um die Ursachen dieser Verschiebung zu finden wurde daher der entsprechende Abschnitt zwischen 18:00 Uhr und 24:00 Uhr in den einzelnen Regelzonen analysiert. Abbildung 2.11 zeigt entsprechend den Verlauf der Regelzonensalden sowie ausgewählte Prognosefehler in den einzelnen Regelzonen. Bis auf die Regelzone von TransnetBW ist in allen drei Regelzonen ein relativ hoher negativer Windfehler aufgetreten. In den Regelzonen von 50 Hertz und Tennet folgte der Regelzonensaldo auch diesem Windfehler, wobei dieser in der Zone von Tennet überlagert wird durch die gut erkennba-

⁴⁰ Von der Ausgleichsenergie im Sinne der StromNZV zu unterscheiden ist der umfassendere Begriff der „Ausgleichsleistungen“ (siehe Kapitel 2.1.1, Seite 13).

⁴¹ Siehe hierzu [www.dena.de], zuletzt geprüft am 10.08.2015.

⁴² Die Auswertung erfolgte auf Basis der im Internet verfügbaren Daten [(www.regelleistung.net)], zuletzt geprüft am 10.08.2015.

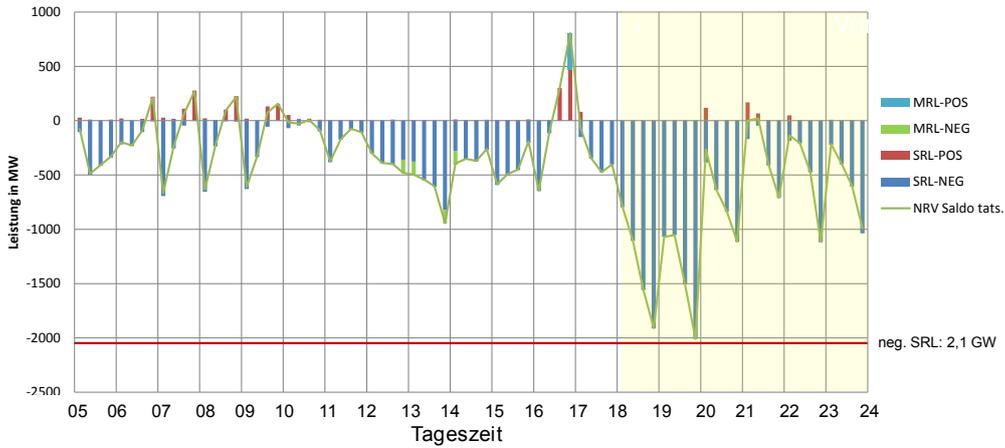


Abbildung 2.10: Abruf von Regelleistung am Samstag, den 1.12.2012 im Netzregelverbund

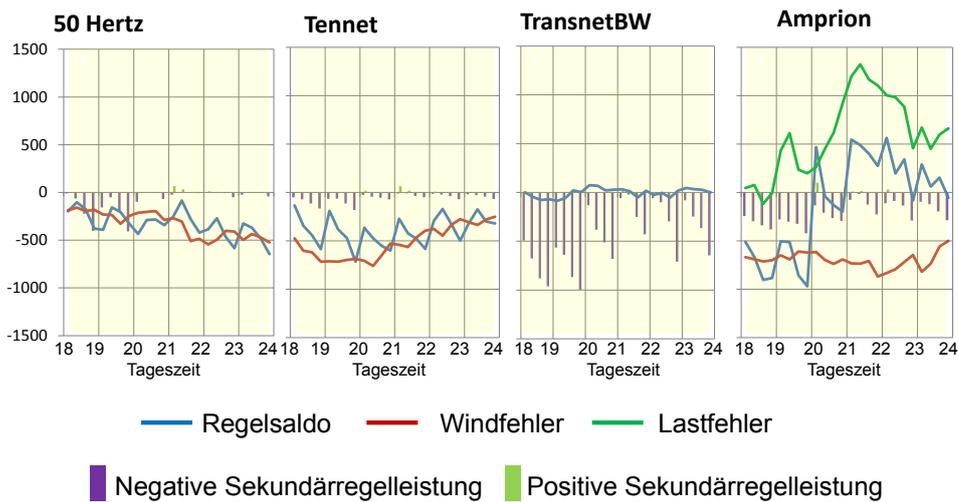


Abbildung 2.11: Abruf von Regelleistung am Samstag, den 1.12.2012 in den Regelzonen

ren Fahrplansprünge. Ebenso zu erkennen ist die Tatsache, dass bezogen auf eine einzelne Regelzone der Regelzonensaldo nicht dem Bezug von Regelenergie entspricht. So wurde in beiden Regelzonen weniger Sekundärregelleistung abgerufen als für den tatsächlichen Ausgleich des Saldos erforderlich gewesen wäre. Stattdessen wurde diese Regelenergie in der TransnetBW Zone abgerufen, in der ein quasi ausgeglichener Saldo vorlag. Dies ist eine Folge des horizontalen Belastungsausgleichs und der dementsprechenden Verteilung der überschüssigen Windenergie in nachfrageintensive Regionen im Süden Deutschlands. Die Regelzone von Amprion nimmt eine gewisse Sonderstellung ein, auch hier ist ein relativ hoher negativer Windfehler zu beobachten, jedoch folgt der Regelzonensaldo nicht in dem Maße dem Windfehler, wie zum Beispiel in den Regelzonen von 50 Hertz oder Tennet. Stattdessen ist ein relativ hoher Sprung des Regelsaldo um 20:00 Uhr beobachtbar, der in keinem direkt

erkennbaren Zusammenhang zu den dargestellten Prognosefehlern steht. Es kann daher nur vermutet werden, dass mögliche strategische Entscheidungen Grund für den Saldoanstieg sind. So kann ein Zusammenhang zwischen den Strompreisen bestehen, da sowohl am Wirkleistungs- als auch am Regelleistungsmarkt um 20:00 Uhr die NT-Zeitscheiben⁴³ beginnen. Im folgenden wird daher die Gestaltung des Regelleistungsmarktes vorgestellt.

2.1.5 Gestaltung und Entwicklung des Regelleistungsmarktes

Während es vor der Entflechtung eine vertikal integrierte, d.h. unternehmensinterne Bereitstellung von Regelleistung durch die Übertragungsnetzbetreiber gab, sind die dafür benötigten Kapazitäten seit der Liberalisierung frei am Markt auszuschreiben. Gemäß §22 des EnWG und §6 der StromNZV hat die Beschaffung transparent und diskriminierungsfrei zu erfolgen, daher erfolgt diese Ausschreibung für alle deutschen Übertragungsnetzbetreiber gemeinsam über eine Internetplattform⁴⁴.

Auf dieser Internetplattform werden die unterschiedlichen Regelleistungsarten getrennt voneinander ausgeschrieben; in wöchentlichen Abständen für die Primär- und Sekundärregelleistung und werktäglich für die Minutenreserve. Diese Ausschreibung erfolgt in Form sogenannter „Multi-Unit Auktionen“ [HJ08, Seite 89]. Das heißt zum einen, dass sowohl die Angebotsmengen vom Nachfrager (ÜNB) aufgeteilt werden dürfen, als auch, dass ein Anbieter (Stromerzeuger) seine Leistungsmenge auf mehrere Gebote verteilen darf. Durch diese Form der Risikosteuerung wird die Versorgungssicherheit erhöht [Swi06]. Des Weiteren unterteilt sich die Ausschreibung in ein- und mehrdimensionale Auktionen, je nachdem ob nur die Kapazität (Leistung in MW) oder auch die potentielle Arbeit (zu liefernde Energie in MWh) ausgeschrieben werden. So wird die Primärregelleistung in einer eindimensionalen Auktion versteigert, da aus technischen Gründen die tatsächliche Arbeit nicht gemessen werden kann. Für die Primärregelung wird daher nur ein sogenannter *Leistungspreis* für die Vorhaltung der Leistung bezahlt. Bei der Sekundärregelleistung und Minutenreserve handelt es sich dagegen um eine mehrdimensionale Auktion. Hier umfassen die Gebote jeweils einen Leistungs- und einen sogenannten *Arbeitspreis*. Der Leistungspreis gilt, wie bei der Primärregelleistung, für die Kapazitätsvorhaltung und wird in (Euro/MW) gezahlt, während die tatsächlich abgerufene Energiemenge mit einem Arbeitspreis in (Euro/MWh) abgerechnet wird. Im Gegensatz zur Wirkleistungsbörse (EEX), bei der alle Anbieter einen einheitlichen Preis – den sogenannten Market-Clearing-Preis (MCP)⁴⁵ – erhalten, wird bei der Regelleistung jeder Anbieter nach seinem angebotenen Arbeitspreis bezahlt. Daher ist es erforderlich mit verdeckten Geboten zu arbeiten, da ansonsten Informationen über das Bietverhalten der anderen Auktionsteilnehmer zu strategischem Verhalten führen könnte ([HJ08], Seite 89).

Für die Teilnahme am entsprechenden Markt müssen die Anbieter technische Voraussetzungen, sogenannte *Präqualifikationen*, erfüllen. Neben „technischer Kompetenz“ müssen eine „ordnungsgemäße Erbringung der Regelleistung unter betrieblichen Bedingungen und die wirtschaftliche Leistungsfähigkeit“ des potentiellen Anbieters gewährleistet sein⁴⁶. Die entsprechenden Präqualifikationsanforderungen sind ursprünglich im Transmission Code der deutschen ÜNB (letzte Fassung aus dem Jahr 2007) beschrieben. Weiterentwicklungen der Präqualifikationsanforderungen werden mit den Anbietern auf vertraglicher Basis vereinbart, wobei der jeweils aktuelle Stand veröffentlicht

⁴³ Das NT steht für Niedrigtarif.

⁴⁴ Siehe [www.regelleistung.net], zuletzt geprüft am 10.08.2015.

⁴⁵ Das letzte Gebot, das einen Zuschlag erhält bestimmt den Preis.

⁴⁶ Für die aktuellen Präqualifikationsrichtlinien siehe [www.regelleistung.net], zuletzt geprüft am 10.08.2015.

Musterverträgen entnommen werden kann [Con14a]⁴⁷. So wurden diese Präqualifikationen in den vergangenen Jahren schrittweise gelockert bzw. individualisiert, so dass die Anzahl an präqualifizierten Anbietern kontinuierlich gewachsen ist und sich vermehrt auch Koalitionen dezentraler Einheiten unter den Anbietern finden.

Der Regelleistungsmarkt weist somit eine monopsonistische Struktur auf [Rol11]. Nach der Definition von Beyer [Bre11] stehen dabei viele Anbieter nur einem einzigen Nachfrager, dem Monopsonisten, gegenüber⁴⁸. Im Falle der Regelleistung ist der einzige Nachfrager der Netzregelverbund, während prinzipiell jedem Stromlieferanten eine Präqualifikation offen steht. Dieses Konzept der zentralen Regelungsverantwortung durch die Übertragungsnetzbetreiber bzw. den Netzregelverbund hat sich im gesamten Bereich des ENTSO-E als „einzig praxisgerecht und effizient“ erwiesen, da es, im Vergleich mit der ehemaligen Regelungsverantwortung bei den einzelnen Energieversorgungsunternehmen, einen deutlich geringeren Aufwand an Regelungstechnik und Regelreserven erfordert [Con14a]. Diese Erkenntnis ist allerdings erst mit der Liberalisierung gereift; davor wurde die Ansicht vertreten, „dass nur die vertikale Integration Prozessstandards und -flexibilität etablierte, die den Charakter eines öffentlichen Gutes hinsichtlich der Versorgungssicherheit internalisiere“ [Rol11, Seite 71]. Die Systemregelung ist somit im deutschen Energierechtsrahmen als eine „Gemeinschaftsaufgabe angelegt, die jeder ÜNB im Rahmen seiner Systemverantwortung gemäß EnWG für alle Netznutzer innerhalb seiner Regelzone übernimmt“ [Con14a, Seite 5] und deren Kosten er den Nutzern über die Netznutzungsentgelte weiter verrechnet. Diese machen in etwa 40 Prozent der Netznutzungsentgelte (NNE) aus [Kon09].

Produkt	Ausschreibung	Ausschreibungsmengen	Mind. Angebot	Aktivierung	Zeitscheiben	Vergütung
Primärregelleistung (PRL)	Wöchentlich	600 MW	1 MW	< 30 Sekunden Vollautomatisch Portionalregler	1 Woche	Leistungspreis
Sekundärregelleistung (SRL)	Wöchentlich	+/-2.100 MW	5 MW	< 5 Minuten Vollautomatisch MOLS	2 Tarife HT(8:00-20:00) NT (20:00-0:00)	Leistungspreis Arbeitspreis
Minutenreserveleistung (PRL)	(Werk)Täglich	+/-2.400 MW	5 MW	< 15 Minuten Teilautomatisiert MOLS	6x4h/Tag (0:00-4:00,...) ,20:00-24:00)	Leistungspreis Arbeitspreis

Tabelle 2.4: Regelleistungsprodukte

Eine rein marktwirtschaftliche kostenbasierte Bemessung der Regelleistung ist, wie bei anderen öffentlichen Gütern (z.B. der öffentlichen Sicherheit), daher nicht möglich bzw. würde die Versorgungssicherheit gefährden. Stattdessen ist das Design des Regelleistungsmarktes reglementiert und die vorgegebenen („konstanten“) Handelsmengen werden von den Regulierungsbehörden vorgegeben⁴⁹. So werden die auf dem Regelleistungsmarkt gehandelten Produkte, anders als an „klassischen“ Märkten, nicht von den Marktakteuren gebildet, sondern werden von den regulierenden Behörden vorgegeben. In Deutschland ist dies die Bundesnetzagentur⁵⁰, die die Produkte nach Ort, Zeit und technischen Beschränkungen spezifiziert [Rol11]. Tabelle 2.4 zeigt einen Überblick der aktuellen Spezifikationen.

⁴⁷ Siehe [www.regelleistung.net/ip/action/static/prequal], zuletzt gerüpf am 10.08.2015.

⁴⁸ Das Monopson ist somit das Gegenteil zum Monopol (z.B. Ausgleichsenergiemarkt), bei dem ein Anbieter vielen Nachfragern gegenübersteht.

⁴⁹ Eine gewisse preisinduzierte Mengensteuerung versucht die Bundesnetzagentur dennoch über eine sogenannte Anreizregulierung, so ist zum Beispiel die Höhe der umzusetzenden Kosten durch Netznutzungsentgelte limitiert.

⁵⁰ Die Bundesnetzagentur ist dabei über die „Agentur für die Zusammenarbeit der Regulierungsbehörden (ACER)“ an den europäischen Rechtsrahmen gekoppelt, so dass künftige Vorgaben vor allem aus den Netzkodizes zu den Themen „Load Frequency Control and Reserves“ sowie „Electricity Balancing“ resultieren [Con14a].

Daher spricht man bei dieser besonderen Form der einseitigen Auktion (engl. one-sided procurement auction) auch von einer Ausschreibung [Swi08].

Diese Ausschreibungs- und Präqualifikationsbedingungen stehen meist im Fokus, wenn es um die Optimierung des Regelleistungsmarktes in der Zukunft geht. So schlagen Experten und Marktakteure häufig vor, „die Produktlänge und Vorlaufzeiten zu verkürzen“. Insbesondere sollen „Sekundärregelleistung und Minutenreserve kalendertäglich ausgeschrieben werden“ [Bun12]⁵¹. Alternativ beziehungsweise zusätzlich wird darüber diskutiert, einen kurzfristigen Regelarbeitsmarkt oder einen Sekundärmarkt für die Bereitstellung von Regelleistung einzuführen. Der Regelleistungsmarkt steht dabei in ständiger Wechselwirkung mit dem Strommarkt für Wirkleistung, da es den Stromlieferanten frei steht, auf welchem der Märkte sie ihre Leistung anbieten. So gibt es starke tägliche Preisschwankungen auf dem Regelenergiemarkt, die in direktem Bezug zu den Preisschwankungen auf dem Spotmarkt der EEX stehen. Abbildung 2.12 zeigt die tägliche Volatilität der Leistungspreise auf dem Minutenreservemarkt für die Jahre 2012 und 2013. In den Tabellen 2.5 und 2.6 sind zudem jeweils die Mittel- und Maximalwerte der Zeitscheiben getrennt nach Sommer und Winter angegeben.

2012 Zeitscheibe	Negative MRL				Positive MRL			
	Winter		Sommer		Winter		Sommer	
	max	mean	max	mean	max	mean	max	mean
00:00-04:00	149,57	18,34	115,47	24,49	0,80	0,03	7,79	0,50
05:00-08:00	154,44	18,96	121,35	24,78	5,10	0,78	27,38	1,74
09:00-12:00	47,93	3,99	42,61	7,45	18,30	2,16	27,47	3,39
13:00-16:00	46,97	4,11	48,23	8,16	7,87	1,08	40,422	3,45
17:00-20:00	48,37	3,75	44,64	7,62	46,58	6,91	40,12	3,56
21:00-24:00	47,81	4,63	42,00	6,74	4,64	0,62	27,94	2,71

Tabelle 2.5: Leistungspreise für MRL im Jahr 2012

2013 Zeitscheibe	Negative MRL				Positive MRL			
	Winter		Sommer		Winter		Sommer	
	max	mean	max	mean	max	mean	max	mean
00:00-04:00	278,11	34,84	124,32	32,02	1,09	0,02	8,93	1,23
05:00-08:00	279,12	33,12	106,80	29,75	3,62	0,39	21,00	3,05
09:00-12:00	163,16	14,47	114,68	16,30	18,09	1,71	40,14	7,87
13:00-16:00	186,08	16,78	188,61	28,10	20,11	1,24	39,72	6,21
17:00-20:00	135,79	13,51	108,19	20,04	27,50	4,18	30,12	7,76
21:00-24:00	133,96	14,34	52,81	10,89	18,12	1,02	47,34	7,11

Tabelle 2.6: Leistungspreise für MRL im Jahr 2013

In der Abbildung 2.12 ist deutlich zu erkennen, dass nachts – in Zeiten niedriger Netzlast und niedriger Preise an der EEX – die Leistungspreise für negative Regelleistung höher sind, während der

⁵¹ Siehe auch Kommentare zum Grünbuch.

⁵²Eigene Berechnungen auf Basis [www.regelleistung.net], eine entsprechende Auswertung der Jahre 2008 bis 2010 findet sich in [Her11].

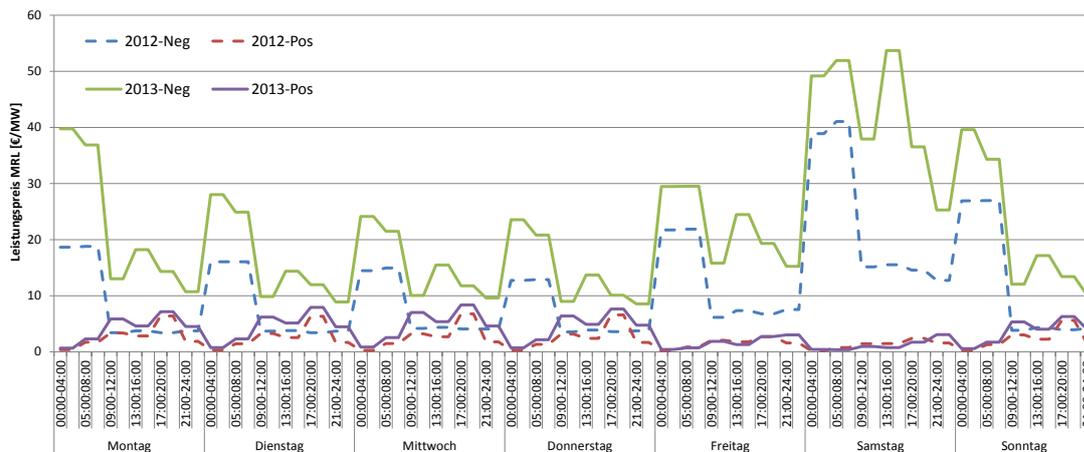


Abbildung 2.12: Preise für Regelleistung in den Jahren 2012 und 2013⁵²

Verlauf für positive Regelleistung genau umgekehrt verläuft. Insbesondere in der Nacht von Sonntag auf Montag, wenn die Netzlast und damit der Preis an der Börse ihren Tiefpunkt haben, betrug der Leistungspreis im Verhältnis zu Nächten in der Woche ca. das 1,6-fache. Dies liegt darin begründet, dass in Zeiten, in denen konventionelle Kraftwerke „nicht im Geld“ sind, d.h. die Preise auf dem Wirkleistungsmarkt unter ihren Betriebskosten liegen, diese nicht ins Netz einspeisen und damit für negative Regelleistung nicht zur Verfügung stehen. So ist dementsprechend der Preis für negative RL-Vorhaltung am höchsten. Demgegenüber ist der Preis für die positive RL-Vorhaltung in diesen Stunden am niedrigsten, da es für die Kraftwerke lukrativ wäre, an Wochenenden „durchzulaufen“, d.h. ein Abfahren der Anlagen verhindert werden könnte. In diesem Fall würden die Einnahmen aus der Leistungsvorhaltung positiver Minutenreserve die Differenz zum niedrigen Börsenpreis decken. Im Vergleich zwischen den beiden Jahren ist zu erkennen, dass der negative Leistungspreis insgesamt deutlich gestiegen ist, während der positive Leistungspreis annähernd konstant geblieben ist. So lagen die Preise für negative MRL im Jahr 2013 teilweise doppelt so hoch wie noch im Jahr 2012 und es wurden Spitzenwerte für die negative Vorhaltung von 279 Euro/4h erzielt, was einem Preis von 70 EUR/MWh entspricht und damit deutlich über dem Börsenmittelwert (Phelix Base – PHB) an der EEX von 40 EUR/MWh (2013) liegt. Im Rahmen der Datenanalyse erfolgt daher im nächsten Kapitel eine detaillierte Analyse der Regelleistungsabrufe insbesondere eine Untersuchung der Wochentags- sowie Tageszeitabhängigkeit.

2.2 Datenanalyse

2.2.1 Datengrundlage

Als Datengrundlage dienen ausschließlich die im Internet frei verfügbaren Daten⁵³. Nach den Transparenzaufgaben der Bundesnetzagentur sind die Übertragungsnetzbetreiber zur Veröffentlichung ihrer relevanten Daten verpflichtet. So stellt jeder ÜNB folgende Daten zur Verfügung:

- Abgerufene (regelzoneninterne) Regelleistung
- Regelzonensaldo
- Windeinspeiseprognose
- Hochrechnung der Windeinspeisung
- Solarprognose
- Hochrechnung der Einspeisung aus Solarenergie
- Vertikale Netzlast

Diese werden im Internet sowohl auf den Internetseiten der Netzbetreiber⁵⁴ als auch auf der gemeinsamen Seite⁵⁵ veröffentlicht. Für diese Daten besteht allerdings keine gemeinsame Konvention über deren Formatierung, so dass die Daten eine zum Teil sehr unterschiedliche Struktur aufweisen. Darüber hinaus verfährt jeder ÜNB unterschiedlich mit dem „Verrechnen“ der Zeitumstellung zwischen Sommer- und Winterzeit. Diese Tatsachen führen dazu, dass zunächst eine umfangreiche Formatierung der Daten erfolgen muss, bevor diese einheitlich verarbeitet werden können. Insbesondere müssen die Daten in Bezug auf den *Umgang mit fehlenden Daten* sowie der *Datenskalierung* vorverarbeitet werden.

Umgang mit fehlenden Daten

Vereinzelt kann es vorkommen, dass fehlende Werte oder falsche Werte in einer Zeitreihe stehen. Falsche Werte kommen zum Beispiel durch eine fehlerhafte Transformation zwischen der englischen Dezimalzahlnotation (Punkt) und der deutschen Notation (Komma) zu Stande. Derartige Fehlwerte werden im Vorfeld angepasst. Dazu stehen verschiedene Möglichkeiten zur Verfügung. Entweder können fehlende/mangelhafte Werte durch Interpolation oder durch Vor/Zurück-Propagierung ersetzt werden. In unserem Fall wird im Fall fehlerhafter Werte die Interpolation gewählt. Ein weiterer Faktor fehlender bzw. doppelter Werte ist der Übergang zwischen Sommer- und Winterzeit. Zur einheitlichen Auswertung der Zeitreihen wurden daher die „doppelten“ Stunden mit der Interpolation gemittelt und die fehlende Stunde wurde durch Vor- (die ersten beiden Werte) bzw. Zurückpropagierung (die letzten beiden Werte) aufgefüllt. Der Fehler, der dadurch gemacht wird ist anhand der großen Datenmenge vernachlässigbar gering.

⁵³ Es war leider nicht möglich direkt Daten der ÜNB zu erhalten.

⁵⁴ ([www.amprion.net]; [www.50hertz.com]; [www.tennet.de]; [www.trannetbw.de])

⁵⁵ Siehe [www.regelleistung.net], zuletzt geprüft am 10.08.2015.

Datenskalierung

Werden die einzelnen Merkmale in unterschiedlichen Zeitabschnitten gemessen, liegen die Daten dementsprechend in unterschiedlicher Auflösung vor. Im Anwendungskontext der Regelleistung besteht das Problem, dass z.B. die Preisdaten der EEX in stündlicher Auflösung vorliegen, während die Regelleistungssalden in viertelstündlicher Auflösung vorliegen. Wir verwenden für unsere Simulation die kleinste Auflösung, da diese viertelstündliche Auflösung die für den Einsatz von Minutenreserve entscheidende Auflösung ist, bzw. der Regelsaldo bereits den viertelstündlichen Mittelwert darstellt.

Diese Datenaufbereitung wird vorgenommen, indem die Daten zunächst einzeln homogenisiert und in „*.csv“ Dateien gespeichert werden, damit diese im Anschluss einheitlich eingelesen werden können. Die so eingelesenen Daten werden in „*.hdf5“ Format gespeichert. HDF5 steht für „**H**ierarchical **D**ata **F**ormat“ und erlaubt den schnellen Zugriff auf ein- und mehrdimensionale homogene Tabellen. Dies ermöglicht bei Programmaufrufen ein schnelles Laden der Daten in „Panel“-Form. Die Panel-Daten sind dabei wie in Abbildung 2.13 strukturiert.

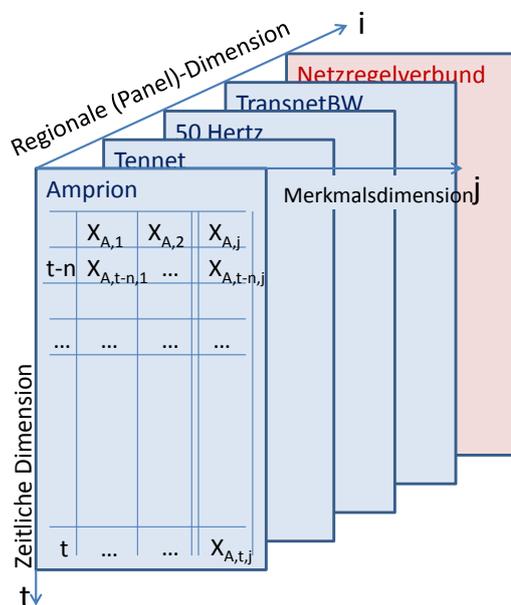


Abbildung 2.13: Datenaufbereitung als Panel-Daten

Das dreidimensionale Panel – nach den Grundsätzen des OLAP-Würfels⁵⁶ – ermöglicht neben dem schnellen Zugriff auf einzelne Daten auch die dreidimensionale Datenanalyse und ist ein gängiges Format in der Ökonomie. Die Panel Objekte der verwendeten *Python*⁵⁷ Bibliothek *Pandas* sind zweidimensionale Tabellen – sogenannte „Dataframes“ –, die eine automatisierte Auswertung in alle drei Dimensionen erlauben. So ist die Ebene des Netzregelverbundes eine automatisiert erzeugte Summe der vier Regelzonen, wobei die Summe jedes einzelnen Tabelleneintrags gebildet wird. Auf diese Weise lassen sich auch regionale Zusammenhänge, wie zum Beispiel die Korrelationen zwischen den Regelzonen, berechnen.

⁵⁶ OnLine Analytical Processing (siehe Einleitung, Seite 5).

⁵⁷ Python ist eine ausgewählte höhere objektorientierte Programmiersprache, siehe hierzu [www.python.org], zuletzt geprüft am 10.08.2015.

Dementsprechend gibt es drei Dimensionen:

- **Hauptachse i** (items):
Jedes Element dieser Achse entspricht einem *Dataframe*, d.h. einer zweidimensionalen Tabelle. In unserem Fall entspricht jede Tabelle i einer Regelzone bzw. dem NRV als Summe der Einzel-tabellen.
- **Hauptachse t** (major axis):
Entspricht den Zeilen der Tabelle bzw. des *Dataframes*. In unserem Fall entspricht der Index (Zeilennummer) des *Dataframes* den Zeiteingaben der einzelnen Intervalle, die Hauptachse t ist somit die Zeitachse.
- **Hauptachse j** (minor axis):
Entspricht den Spalten der Tabelle. In unserem Fall entspricht jede Spalte einer Einflussgröße (Merkmal) bzw. dem viertelstündlichen Wert dieser Einflussgröße.

Diese derart aufbereiteten Daten können genutzt werden, um mit Hilfe der sogenannten explorativen Datenanalyse (EDA) anhand von graphischen Darstellungen bzw. Berechnungen, Muster oder Zusammenhänge zu erkennen, um damit auf die strukturellen Systemeigenschaften (Stabilität, Struktur, Dynamik) schließen zu können. Die explorative Datenanalyse steht damit im Kontrast zu traditionellen strukturprüfenden (induktiven) Methoden, bei denen im vor herein (a-priori) Erwartungen formuliert werden, die anschließend getestet werden [ML13]. Strukturentdeckende Verfahren sind insbesondere geeignet, wenn – wie in diesem Fall – ein komplexer Zusammenhang gegeben ist. So lassen sich Methoden des Data Mining nutzen, um in großen Datenmengen vorher nicht genau spezifizierte Zusammenhänge aufzuspüren. Einen ersten Aufschluss über die Struktur der Daten ermöglicht die sogenannte deskriptive Statistik, d.h. eine Berechnung der wesentlichen statistischen Kenngrößen der Einzelzeitreihen. Für die Jahre 2012 und 2013 sind die Kennzahlen in den folgenden Tabellen 2.7 und 2.8 zusammengefasst⁵⁸.

2012	RS	VNLast	WindE	Wind_Err	Wind_Err	PVE	PV_Err	PV_Err
	[MW]	[MW]	[MW]	[MW]	[%]	[MW]	[MW]	[%]
count	35.136	35.136	35.136	35.136	35.136	19.049	19.049	19.049
mean	-64	32.890	5.219	264	23,17	5.856	12	49,61
std	944	8.374	4.444	861	32,73	5.321	1,127	130,37
min	-4.658	11.681	115	-4.871	0,00	1	-6.006	0,00
25%	-570	26.936	1.978	-171	5,75	1.092	-411	5,60
50%	-82	32.718	3.911	278	13,37	4.382	27	12,98
75%	450	39.290	7.099	700	27,24	9.767	402	30,53
max	4.135	54.507	24.086	5.448	646,66	22.402	6.615	423,51

Tabelle 2.7: Auswertung der Einflussfaktoren im Jahr 2012 für den NRV

Die Tabellen zeigen die Auswertung für den Netzregelverbund. Für jedes Merkmal werden die Mittelwerte (mean), die Standardabweichung (std), die Extremwerte (min, max) sowie die Quantile (25%, 50%, 75%) ausgegeben. Die Kennzahl „count“ steht für die Anzahl berücksichtigter Samples⁵⁹. So

⁵⁸ RS: Regelsaldo, VNetlast: Vertikale Netzlast, WindE: Windeinspeisung, Wind_Err: Windfehler, PVE: PV-Einspeisung, PV_Err: PV-Fehler

⁵⁹ Der Begriff Sample wird im Folgenden für Beispieldatenpunkte verwendet.

2013	RS	VNLast	WindE	Wind_Err	Wind_Err	PVE	PV_Err	PV_Err
	[MW]	[MW]	[MW]	[MW]	[%]	[MW]	[MW]	[%]
count	35.040	35.040	35.040	35.040	35.040	19.373	19.373	19.373
mean	-83	32.471	5.389	155	24,6	6.129	130	40,72
std	738	8.527	4.866	1.043	31,94	5.949	1.243	121,94
min	-4.611	5.038	121	-6.115	0,00	1	-6.197	0,00
25%	-472	2.6542	1.831	-313	6,46	955	-276	6,18
50%	-69	32.151	3.812	213	14,73	4.152	40	14,77
75%	331	38.781	7.411	668	29,47	10.060	577	31,80
max	4.516	53.124	26.268	5.945	451,63	23.998	9.564	451,63

Tabelle 2.8: Auswertung der Einflussfaktoren im Jahr 2013 für den NRV

ist zu erkennen, dass das Jahr 2012 ein Schaltjahr war und dementsprechend 96 Intervalle (entspricht einem Tag) mehr besitzt als das Vergleichsjahr. An der Anzahl Samples ist auch zu erkennen, dass für die Auswertung der PV-Einspeisung und der PV-Fehler nur die Stunden zwischen Sonnenauf- und Sonnenuntergang betrachtet werden⁶⁰. Die EE-Fehler (Prognose-IST) sind vorzeichenreu dem daraus resultierenden Saldo. So bezeichnet ein positiver EE-Fehler eine Mindereinspeisung und dementsprechend einen positiven Saldo und den potentiellen Bedarf an positiver Regelleistung. Dabei stellen die prozentualen EE-Fehler jeweils das Verhältnis des absoluten viertelstündlichen Fehlers zur absoluten viertelstündlichen Einspeisung dar. Bei den Windfehlern überwiegen die positiven Prognoseabweichungen sowohl im Jahr 2012 als auch im Jahr 2013, während bei den PV-Fehlern im Jahr 2012 noch ein ausgeglichenes Verhältnis vorlag. Im Jahr 2013 überwiegen auch hier die positiven Fehler, so liegt der Höchstwert um ca. ein Drittel höher als der Minimalwert.

Um weitere Aussagen über die Struktur und Dynamik der Regelleistungsaktivierung treffen zu können, erfolgt im Weiteren eine gezielte Datenanalyse sowohl der Regelleistungsabrufe als auch der Regelzonensalden bzw. der Einflussfaktoren. Um hierbei den genauen Einfluss von EE-Prognosefehlern ermitteln zu können, ist es dazu erforderlich, dass die Daten um die Kraftwerksausfälle und Im- und Exporte in Nachbarstaaten bereinigt werden. Dazu wird die Hilfsgröße „Saldo_corr“ eingeführt⁶¹.

2.2.2 Analyse der Regelleistungsaktivierung

Die praktische Analyse der Regelleistungsaktivierung lässt sich in drei Teile untergliedern; als erstes wird eine generelle *Verteilung der verschiedenen Arten der Regelleistung* zwischen den Jahren 2004 und 2013, sowie insbesondere die Unterschiede zwischen den Beispieljahren 2008 und 2012 untersucht. Zweitens wird die Nutzung der Sekundär- und Minutenreserve auf ihre *Tageszeitabhängigkeit* hin untersucht und drittens wird das Auftreten von *Clustern* in der Minutenreserveaktivierung näher beleuchtet.

In Bezug auf die **Verteilung der einzelnen Regelleistungsarten** lässt sich feststellen, dass aufgrund der Zunahme fluktuierender Energieeinspeisungen aus Wind und Solar eine Verschiebung zur Minutenreserve stattgefunden hat. In Abbildung 2.14 ist die Entwicklung der Minutenreserve vom Jahr 2004 bis zum Jahr 2013 dargestellt. Zwischen 2005 und 2008 lag die Anzahl an Aktivierungen von MRL relativ konstant bei 5.325 Aktivierungen und einer mittleren abgerufenen Leistung von

⁶⁰ Es werden nur Intervalle mit einer PV-Einspeisung größer Null betrachtet.

⁶¹ $Saldo_{corr} = \text{Regelsaldo} + \text{Ausfälle} + \text{Export} - \text{Import}$

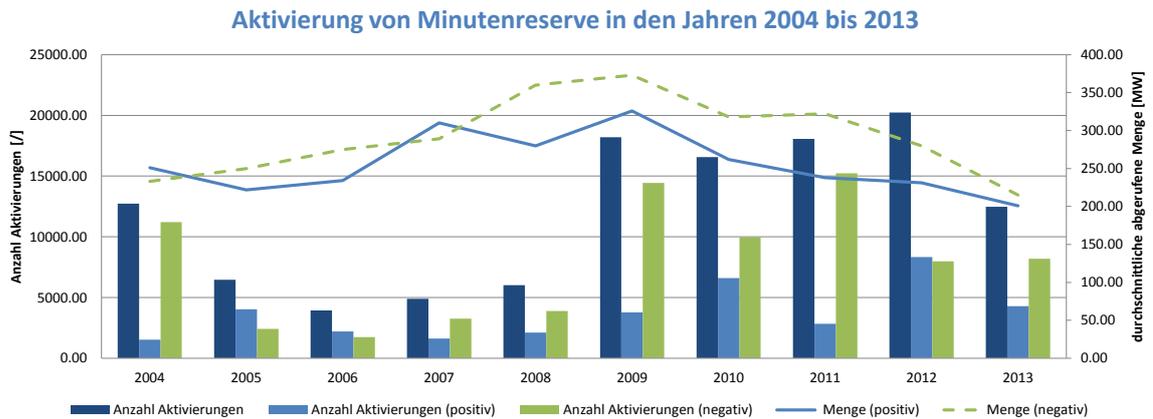


Abbildung 2.14: Menge und Anzahl Aktivierungen von Minutenreserve

300 MW. Im Jahr 2009 gab es einen abrupten Anstieg auf 18.206 Aktivierungen, bei nahezu konstanter Abrufmenge. Seit dem Jahr 2012 liegt die Anzahl Aktivierungen relativ konstant bei 17.282 Aktivierungen, und ist demnach dreimal so hoch wie noch im Jahr 2008 (BNetzA 06/12). In Bezug auf die Sekundärreserve ist es genau umgekehrt, während die Anzahl der Aktivierungsperioden konstant blieb, hat sich die abgerufene Menge halbiert (siehe Abbildung 2.18).

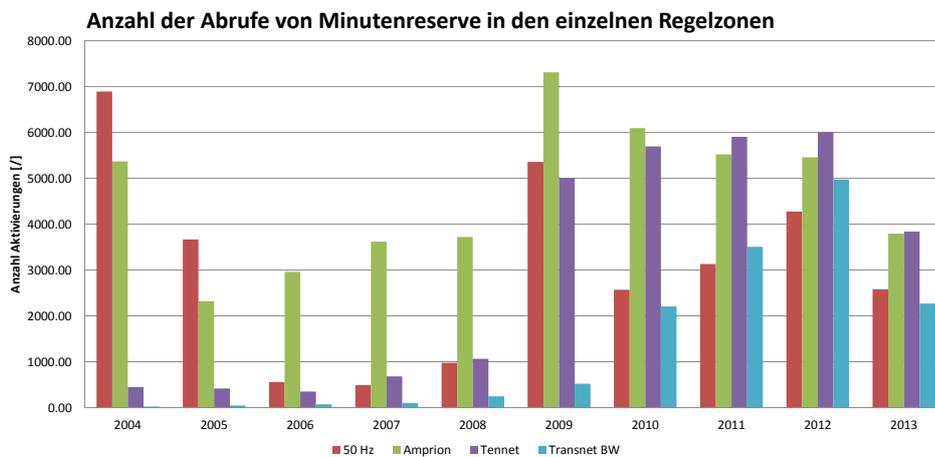


Abbildung 2.15: Minutenreserve in den Regelzonen in den Jahren 2004 bis 2013

Während die Verschiebung der Abrufe zur Minutenreserve auf die Zunahme des Anteils erneuerbarer Energien zurückzuführen ist, lässt sich die Reduzierung der abgerufenen Gesamtmengen (SRL + MRL) neben den Verbesserungen bei der Wind- und PV-Prognose insbesondere mit der Einführung des Netzregelverbundes begründen. So wurde im Dezember 2008 das Modul eins des Netzregelverbundes eingeführt; es dient der Verhinderung einer gegenseitigen Aktivierung von SRL und MRL. Im Mai 2009 ist das zweite Modul in Kraft getreten, das den Regelzonen eine gemeinsame Regelleistungsbemessung erlaubt. Im Juli 2009 erfolgte die Bildung eines gemeinsamen regelzonenübergreifenden, kostenoptimalen Sekundärregelleistungsabruf (Modul vier). Das heißt die Regelleistung wird nicht mehr dort zwingend abgerufen, wo sie entsteht, sondern in der Regelzone, in der sie am

günstigsten angeboten wurde. Seit Mai 2010 ist auch Amprion Teil des Netzregelverbundes, zu dem bisher nur die drei anderen deutschen Übertragungsnetzbetreiber gehörten. Seit Juli 2010 ist schließlich auch das letzte Modul aktiv, das eine gemeinsame kostenoptimale Aktivierung der MRL vorsieht. In Abbildung 2.15 ist die Aktivierung der MRL nach Regelzonen dargestellt.

Es lässt sich gut die Veränderung nach Einführung des NRV erkennen, so hat es zum Beispiel bei der Aktivierung von MRL in der TransnetBW Regelzone quasi erst ab dem Jahr 2010 eine mit den anderen Regelzonen vergleichbare Anzahl an Aktivierungen gegeben. Die Entwicklung der MRL hat sich dabei nicht nur über die Jahre verändert, auch die Verteilung der MRL-Abrufe innerhalb eines Jahres ist durch die Verschiebung der Einflussfaktoren wesentlich differenzierter geworden. Abbildung 2.16 zeigt beispielhaft die Struktur der MRL-Aktivierung für das Jahr 2012.

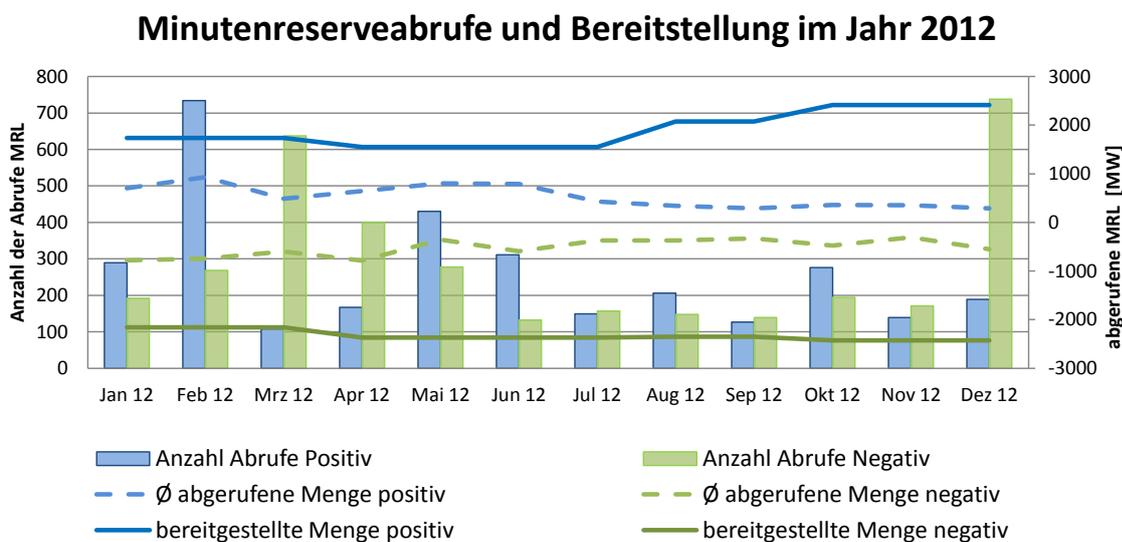
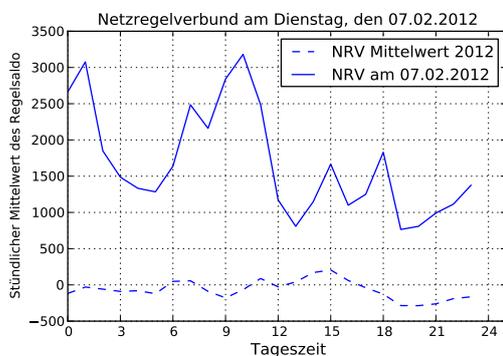


Abbildung 2.16: Abrufstruktur von Minutenreserve im Jahr 2012

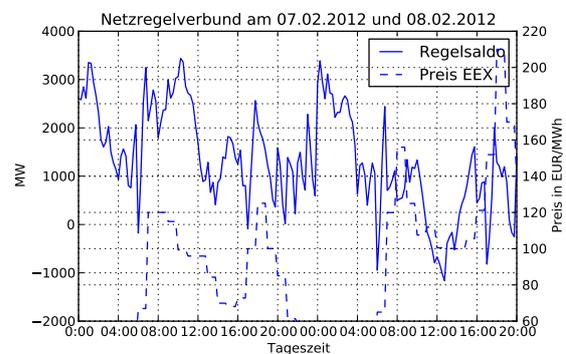
Auf der rechten y-Achse ist die mittlere abgerufene Menge sowie die bereitgestellte Menge jeweils in MW abgetragen. Der Quotient dieser beiden Werte liefert den sogenannten *Abrufgrad*. Für das Jahr 2012 lag der mittlere Abrufgrad bei 0,304 für positive MRL und bei 0,227 für negative MRL, d.h. ca. 70 % der bereitgestellten Leistung wurden nicht abgerufen. Dies spricht für eine Ineffizienz des aktuellen Bemessungskonzepts. Der annähernd waagerechte Verlauf der Kurven zeigt eine über das Jahr statische Abrufmenge. Demgegenüber erfolgt die Aktivierung der MRL dynamisch wie das Histogramm erkennen lässt. So ist auf der linken y-Achse die absolute Anzahl Aktivierungen aufgetragen⁶². Aufgrund der verschiedenen Einflussfaktoren ist die Anzahl an Aktivierungen zwischen den Monaten sehr unterschiedlich. So ist in den Wintermonaten – mit einer verstärkten Windeinspeisung – die Anzahl negativer Abrufe deutlich höher, während in den Frühlingsmonaten – mit einer höheren Anzahl positiver PV-Fehler – die Anzahl positiver MRL-Abrufe steigt. Der Quotient aus der Anzahl Abrufe und der Gesamtzahl an Intervallen ergibt die sogenannte *Abrufhäufigkeit*. Diese lag für positive MRL im Schnitt bei 0,07 (entspricht 50 Stunden im Monat) und für negative MRL bei 0,10 (entspricht 72 Stunden).

⁶² Das monatliche Maximum wären je nach Monat bis zu 2.976 Abrufe.

Der Februar 2012 nimmt eine gewisse „Sonderstellung“ ein, da die positiven Regelleistungsabrufe in diesem Monat deutlich über dem Jahresdurchschnitt bzw. den für einen Wintermonat typischen Werten liegen. Dies liegt daran, dass die verstärkten Abrufe in diesem Monat nicht auf die „üblichen Einflussfaktoren“ zurückzuführen sind, sondern eine starke Abhängigkeit zu den relativ hohen Preisen an der EEX aufzeigen⁶³. Abbildung 2.17 zeigt den Zusammenhang zwischen dem relativ hohen EEX-Preis im Februar 2012 und dem relativ hohen positiven Regelleistungsbedarf bzw. Regelleistungssaldo in diesem Monat. Links dargestellt ist – mit durchgezogener Linie – der stündliche Mittelwert des Saldo am 07. Februar 2012 und darunter – gestrichelt – der stündliche jährliche Mittelwert. So wurden insbesondere nachts ungewöhnlich hohe positive Regelsalden erreicht. Rechts sind sowohl der 07.02. als auch der 08.02. dargestellt. Die durchgezogene Linie zeigt den Regelsaldo und die gestrichelte Linie zeigt den Phelix Base Preis an der EEX. Zu erkennen ist der deutliche Zusammenhang zwischen beiden Kurven, insbesondere folgt der Regelsaldo dem Anstieg der Börsenpreise jeweils um 06:00 Uhr und 16:00 Uhr.



(a) Mittelwerte des Regelsaldo



(b) Mittelwerte des Saldo und des EEX-Base

Abbildung 2.17: Analyse des Februar 2012 - RL-Bedarf und EEX-Preis

Neben dem monatlichen Verlauf wurde die Aktivierung ferner auf ihre **Tageszeitabhängigkeit** hin untersucht, so ist in Abbildung 2.18 die Abrufcharakteristik für positive SRL und MRL für die Jahre 2008 und 2012 im Vergleich dargestellt. Auf der linken Seite ist jeweils die aktivierte Menge an positiver SLR über die Tageszeiten für die Jahre 2008 und 2012 aufgetragen und auf der rechten Seite ist die Anzahl der Aktivierung positiver MRL ebenfalls nach Tageszeiten differenziert für die Jahre 2008 und 2012.

Eine erste Erkenntnis dieser Abbildung ist, dass sich neben den Mengen auch die Charakteristik des Abrufs positiver MRL im Laufe der letzten vier Jahre zum Teil deutlich verändert hat. So wird die bereits zuvor erwähnte Verdreifachung der Anzahl an Aktivierungen von MRL hier ebenso deutlich wie die Reduktion der abgerufenen Menge an SRL. Weiterhin lässt sich eine eindeutige Korrelation der jeweiligen Kurven eines Jahres erkennen, insbesondere die Peaks zu Beginn einer jeden Stunde lassen sich sowohl bei der SRL (linke Seite) als auch bei der MRL (rechte Seite) finden. Diese Tatsache ist auf die Fahrplansprünge zurückzuführen. Im Jahr 2008 waren diese Sprünge jedoch nur in der Sekundärregelleistung sichtbar ohne einen derartigen Einfluss auf die Minutenreserve gehabt zu haben.

⁶³ Dies führte in der Folge zu einer Kopplung der Ausgleichsenergiepreise an den Phelix Base Preis.

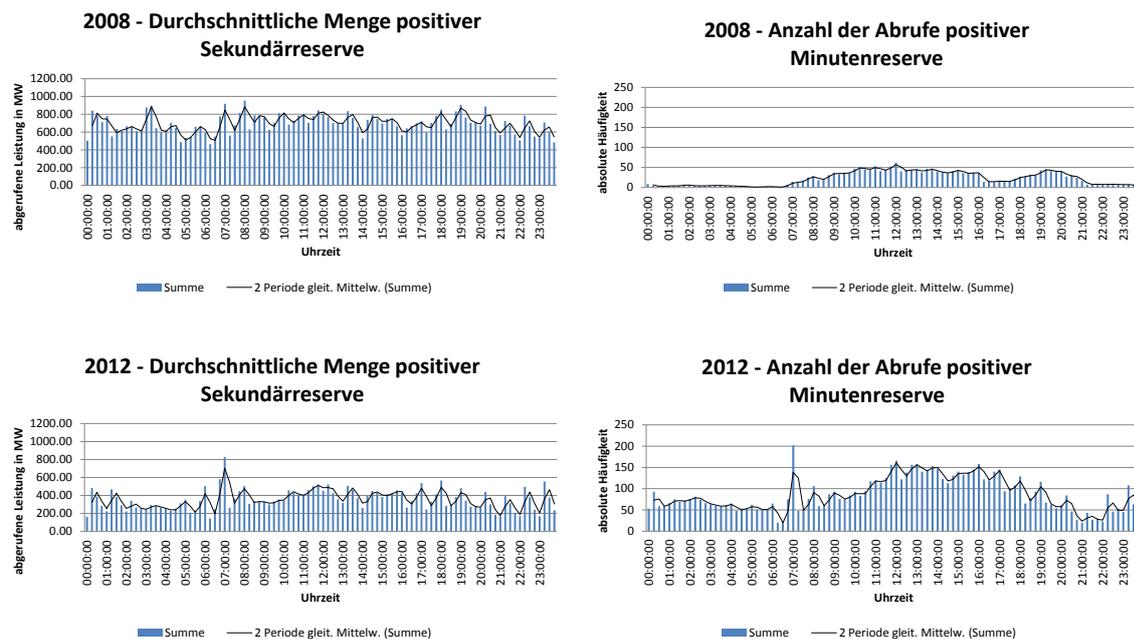


Abbildung 2.18: Menge und Anzahl Aktivierungen von Sekundär- und Tertiärregelleistung

In Bezug auf die Aktivierung der Minutenreserve ist auffällig, dass beide Kurven einen deutlich anderen Verlauf aufweisen. Während im Jahr 2008 nachts zwischen 0:00 Uhr und 07:00 Uhr quasi keine Aktivierung stattfand, lag die Anzahl Aktivierungen im Jahr 2012 nachts sogar über dem Wert, der im Jahr 2008 tagsüber erreicht wurde. Schaut man sich die Wendepunkte der Kurven genauer an stellt man fest, dass die Maxima relativ konstant zwischen 12:00 Uhr und 16:00 Uhr geblieben sind, das Minimum jedoch von 17:00 Uhr im Jahr 2008 nach 21:00 Uhr im Jahr 2012 gewandert ist, bzw. das Zwischentief aus dem Jahr 2008 nicht mehr vorhanden ist. Eine andere Auffälligkeit ist die extreme Spitze morgens um 07:00 Uhr; diese wird in der Analyse des Regelsaldos näher erläutert.

Darüber hinaus wird das Phänomen der **Clusterabrufe** der Minutenreserve untersucht. Bereits [Kur09] stellte im Jahr 2009 fest, dass Minutenreserve selten in einem einzelnen Intervall aktiviert wird, sondern meistens über mehrere Intervalle hinweg in sogenannten Büscheln oder Clustern. Tabelle 2.9 zeigt den prozentualen Anteil an Clusterabrufen für positive MRL für die Summe der Jahre 2006 und 2007 [Kur09] und die eigene Auswertung für das Jahr 2012⁶⁴.

Kurscheid [Kur09] hat in ihrer Arbeit das Vorkommen von Clustern auf die absolute Anzahl von Intervallen bezogen. Um die Zahlen für das Jahr 2012 vergleichbar zu machen, werden diese Werte ebenfalls angegeben (jeweils die erste Anzahl und Prozentzahl). Auf diese Weise werden jedoch Perioden mit einer großen Anzahl von Intervallen stärker gewichtet. Daher ist es vorteilhafter, die absolute Anzahl Aktivierungen als Bezugswert zu nehmen; so entsprechen beispielsweise die 1.934 aktivierten Intervalle in der 50 Hertz Regelzone nur 431 Aktivierungsperioden, von denen 59 % länger als eine Viertelstunde und immerhin 25 % länger als 1 Stunde andauerten. Der Wert von 91 % im Verhältnis zu den aktivierten Intervallen ist daher wenig aussagekräftig, dient jedoch als Vergleich der Jahre

⁶⁴ Für die negative Minutenreserve im Jahr 2012 ist das Ergebnis vergleichbar, für die Jahre 2006/2007 wurde in der vorliegenden Vergleichsstudie nur die positive Minutenreserve betrachtet.

Jahr	Regelzone	Anzahl akt. Intervalle []	Anzahl Aktiv. []	Anteil Cluster [%]		Abrufe bis 45 Min. [%]	Abrufe länger 1h [%]	
2006/2007	VET	187		20		13	7	
	RWE	2631		12		6	6	
	EON	860		18		13	5	
	EnBW	169		24		17	7	
2012	50Hz	1934	431	91	59	19	72	25
	Amprion	2496	545	90	54	16	74	25
	Tennet	2292	323	96	72	11	85	40
	TransnetBW	1614	222	97	75	11	86	45

Tabelle 2.9: Clusterabrufe von MRL in den Jahren 2006/2007 und 2012 im Vergleich

2006/2007. So ist zu erkennen, dass der Anteil an Clusterperioden in den vergangenen Jahren deutlich zugenommen hat; lag ihr Anteil 2006/2007 z.B. in der RWE Regelzone (heute Amprion) noch bei 12 % so liegt er heute bereits bei 54 %. Insbesondere die langen Aktivierungsperioden mit einer Länge von mehr als vier Intervallen (eine Stunde) haben deutlich zugenommen; von einem durchschnittlichen Anteil von 6 % in den Jahren 2006/2007 auf einen Wert von durchschnittlich 34 % im Jahr 2012.

Mit diesen Werten ist es außerdem möglich, die durchschnittliche Länge einer Aktivierungsperiode zu berechnen. Diese liegt bei ca. 4,5 Intervallen für die Regelzonen 50 Hertz und Amprion und bei ca. 7 Intervallen für die Regelzonen von Tennet und TransnetBW. Auch diese Tatsache lässt darauf schließen, dass der Abruf nicht mehr primär dem akuten Ausgleich von Systemungleichgewichten dient, sondern zum Teil auch für die Kompensation langfristiger Prognosefehler genutzt wird. Da die Aktivierung der Regelleistung exakt dem Regelsaldo entspricht, erfolgt im folgenden Kapitel die Analyse der einzelnen Regelzonensalden, bzw. des deutschlandweiten Regelsaldos.

2.2.3 Analyse des Regelzonensaldo

Die Analyse des Regelsaldos bzw. der Zeitreihe erfolgt in Bezug auf die folgenden Eigenschaften⁶⁵:

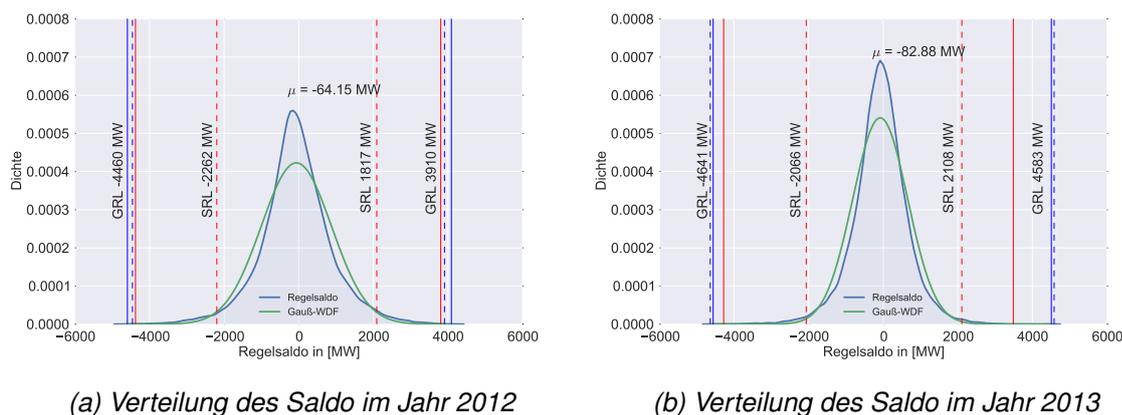
- Verteilung, bzw. Extremwerte
- Stationarität, Trendverhalten
- Korrelation auf verschiedenen Zeitskalen
- Periodizitäten

Verteilung des Regelsaldos

Im Folgenden wird der Regelsaldo auf seine Verteilungsklasse hin überprüft. Nach dem zentralen Grenzwertsatz der Mathematik [Pol20] müsste der Regelsaldo bei genügend großer Samplemenge zur Normalverteilung tendieren, unabhängig der Verteilungen seiner einzelnen Einflussparameter. Abbildung 2.19 zeigt die Verteilung des Regelsaldo für die Jahre 2012 und 2013. Dazu wird eine Kern-

⁶⁵ Dabei liegt die Vermutung zugrunde, dass es sich beim Regelsaldo um eine stationäre, korrelierte Zeitreihe handelt.

dichtefunktion mit einem Gaußkernel als Schätzer verwendet⁶⁶. Als Vergleich wird eine Normalverteilung (Gauß-WDF) zwischen den Extremwerten des Regelsaldo gefittet. Man erkennt, dass beide Verteilungen sich einer Normalverteilung annähern. Insbesondere die wichtigen Eigenschaften der Normalverteilung [MLR11] wie „Eingipfligkeit“ und Symmetrie sind deutlich zu erkennen. Ferner sind die vorgehaltenen Regelleistungsmengen für die SRL und die MRL als vertikale Linien eingetragen. Um diese Werte einordnen zu können, sind die 0,025 % (99,975 %) und 0,0025 % (99,9975 %) Quantil-Werte als durchgezogene Linien eingetragen. Man erkennt, dass die vorgehaltene Menge an GRL ziemlich genau dem 0,025 % Quantil und damit dem geforderten Sicherheitsniveau entspricht.



(a) Verteilung des Saldo im Jahr 2012

(b) Verteilung des Saldo im Jahr 2013

Abbildung 2.19: Häufigkeitsverteilung des Regelsaldos im Netzregelverbund

Zur weiteren Analyse wurden zudem die Verteilungsfunktionen der Regelzonensalden in den einzelnen Regelzonen untersucht. Die Ergebnisse für die Jahre 2007 und 2012 sind in Tabelle 2.10 dargestellt.

Regelzone	Höchstlast [MW]		Mittelwert [MW]		σ /Höchstlast [%]	
	2007	2012	2007	2012	2007	2012
Amprion	30.346	30.724	-101	-167	1,47	1,66
Tennet	23.286	22.239	-26	17	1,28	1,93
50 Hertz	14.663	13.963	-118	66	1,80	3,27
TransnetBW	10.800	12.559	20	19	1,35	1,99
NRV				-65		1,18

Tabelle 2.10: Regelzonensalden der Jahre 2007 und 2012 im Vergleich

Man erkennt, dass die Mittelwerte der Salden sich in diesen fünf Jahren zum Teil deutlich verschoben haben. Insbesondere in der Regelzone von 50 Hertz – mit einem großen Anteil Windenergie – ist der Saldomittelwert von -118 MW auf +66 MW gestiegen, so dass die Regelzone damit im Mittel stetig unterdeckt war. Demgegenüber war die Regelzone von Amprion im Jahr 2012 stetig überdeckt mit im Mittel -167 MW. Abbildung 2.20 zeigt die Verteilung in den Regelzonen von 50 Hertz und Amprion für das Jahr 2012. Ebenso wie für den Netzregelverbund lässt sich auch hier eine sehr gute Übereinstimmung mit der Gauß-WDF feststellen.

⁶⁶ Erläuterungen zu Kerndichtefunktionen siehe Anhang

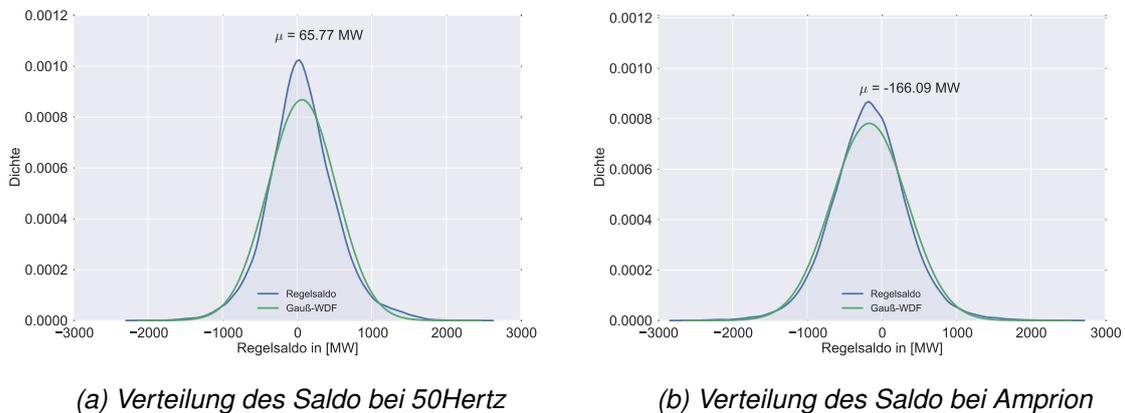


Abbildung 2.20: Häufigkeitsverteilung des Regelsaldos in den Regelzonen im Jahr 2012

Entscheidend für den Abruf von Regelleistung ist jedoch nicht der Mittelwert der Verteilung, sondern die Varianz bzw. die Standardabweichung. So wird als weitere Kennzahl jeweils die Standardabweichung im Verhältnis zur Regelzonenhöchstlast angegeben. Man erkennt, dass die Regelzone von 50 Hertz die größte relative Standardabweichung besitzt, während die Regelzone von Amprion den niedrigsten Wert aufweist. Insgesamt ist jedoch für alle Regelzonen ein Anstieg der Varianz erkennbar. Diese gestiegene Varianz in den einzelnen Regelzonen lässt sich jedoch durch den Netzregelverbund für Gesamtdeutschland deutlich reduzieren. So liegt die relative Standardabweichung für den NRV sogar unter den Werten für die einzelnen Regelzonen im Jahr 2008. Diese Werte bzw. Verteilungen stellen die Mittelwerte über jeweils ein Jahr dar. Interessant ist die Frage, ob sich im Verlauf eines Jahres gewisse saisonale Muster finden lassen, daher wird der Regelsaldo im Folgenden auf Stationarität und Trendverhalten untersucht.

Stationarität Trendverhalten

Laut Definition [Ma10] ist eine Zeitreihe stark stationär, wenn alle Momente nicht von der Zeit abhängen; sind nur die ersten beiden Momente (Mittelwert und Varianz) Zeit-invariant, sind die Zeitreihen schwach stationär, d.h. in der Zeitreihe sind weder monotone Trends noch wechselnde Varianzen (Heteroskedastizitäten) erkennbar [Ma10]. Im Bezug auf die Regelenergie gibt es mehrere zeitliche Einflussfaktoren, z.B. Jahreszeiten oder Wochentage, die den Regelsaldo und damit den Bedarf beeinflussen. So ist die Jahreszeit sowohl entscheidend für die Last als auch für die Produktion aus Wind und Solar. Last und PV-Einspeisung haben darüber hinaus eine starke Tageszeitabhängigkeit. Der Einfluss des Wochentags spiegelt sich ebenfalls in der Last wider. So ist die Last an Wochenenden und Feiertagen deutlich geringer als an Werktagen. Zum Nachweis dieser temporären Abhängigkeiten wird der Regelsaldo anhand verschiedener Zeitmerkmale gefiltert bzw. aggregiert und die ersten beiden Momente werden analysiert. Abbildung 2.21 zeigt die monatlich aggregierten Mittel- sowie Min- und Maxwerte für die Verteilung des Regelsaldos im NRV in den Jahren 2012 und 2013.

Die obere grüne Linie zeigt jeweils den Maximal-, die mittlere blaue Linie den Mittel- und die untere rote Linie zeigt den Minimalwert. Als gestrichelte Linie sind die jeweils vorgehaltenen Regelleistungsmengen eingetragen. Man erkennt, dass es im Jahr 2012 bei der positiven Regelleistung im Mai und Juni eine Unterdeckung gab, die im Oktober entsprechend zu einer Erhöhung der positiven GRL geführt hat. Im Jahr 2013 sind keine Defizite erkennbar. Deutlich zu erkennen ist jedoch eine klare saisonale Struktur, insbesondere in Bezug auf die Maximalwerte. So ist in den Sommermonaten

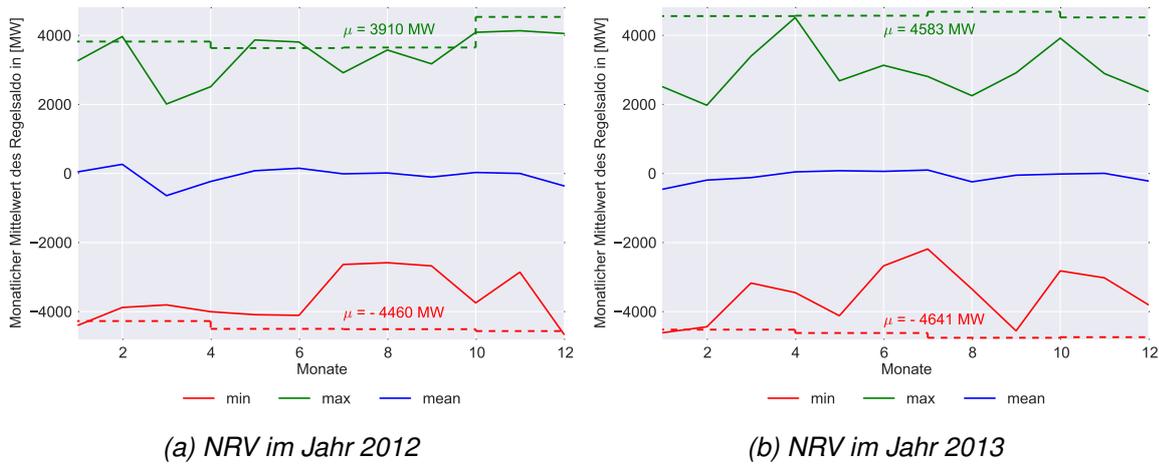


Abbildung 2.21: Monatliche Verteilung des Regelzonensaldos im Netzregelverbund

eine deutlich geringere Spannbreite des Saldos feststellbar. Die Varianz lässt sich weiter reduzieren, wenn man die Werte einzelner Monate weiter nach Tageszeiten aggregiert. So zeigt Abbildung 2.22 die stündlich aggregierten Kennzahlen für ausgewählte Monate im Jahr 2012 und Abbildung 2.23 für das Jahr 2013.

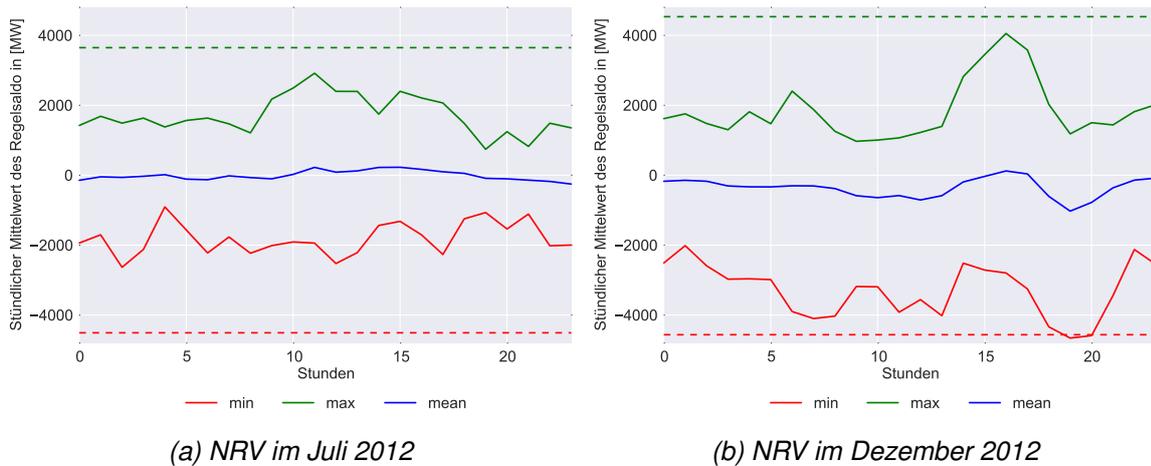


Abbildung 2.22: Stündliche Verteilung des Regelsaldos im NRV im Jahr 2012

Im Jahr 2012 sind insbesondere die Monate Juli und Dezember als Beispielmonate mit der geringsten bzw. größten Varianz von Interesse, während im Jahr 2013 die Monate Januar und September durch ihre starken tageszeitabhängigen Varianzen auffallen. Betrachtet man beispielsweise die Verteilungen im Dezember 2012 zu ausgewählten Uhrzeiten, so lässt sich in Abbildung 2.24 erkennen, dass der Regelzonensaldo für den NRV für diese separierte Samplemenge keine Normalverteilung mehr aufweist, bzw. sich die Verteilungen zwischen 16:00 und 19:00 Uhr (2.24a) und zwischen 19:00 und 21:00 Uhr (2.24b) deutlich unterscheiden. So weisen beide Verteilungen ein zweites lokales Maximum („Mehrgipfligkeit“) auf und sind nicht länger symmetrisch. Dabei sind die Verteilungen spiegelverkehrt, d.h. in dem einen Fall ist die Verschiebung positiv und im anderen Fall negativ. So liegt der Mittelwert zwischen 19:00 und 21:00 Uhr mit - 900 MW deutlich im negativen Bereich, und es ist

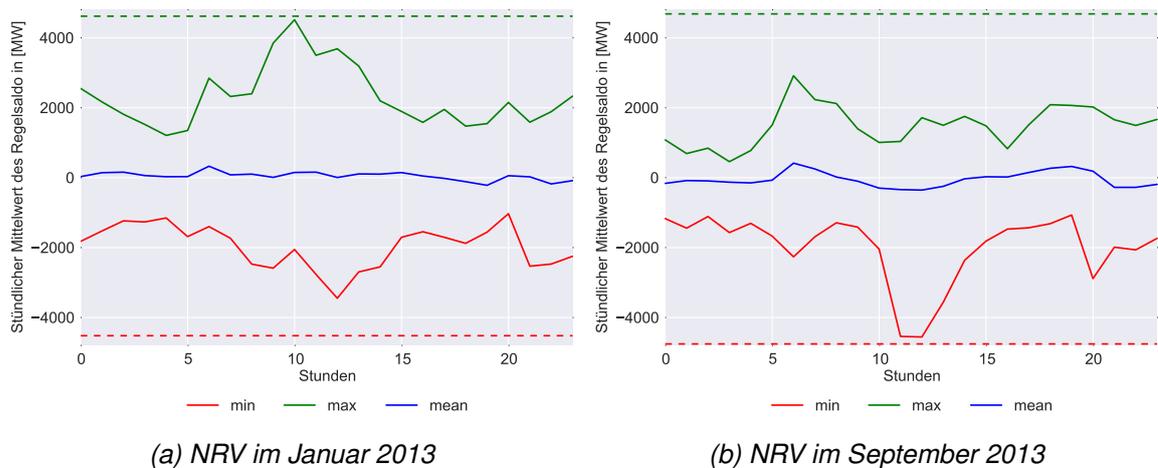


Abbildung 2.23: Stündliche Verteilung des Regelsaldos im NRV im Jahr 2013

eine Häufung großer negativer Salden zu erkennen. Die Annahme einer Normalverteilung ist somit abhängig von der Größe und Zusammensetzung der Samplemenge. Wird wie hier eine geringe Untermenge (372 Intervalle bzw. 1 %) betrachtet⁶⁷, werden die Eigenschaften der Normalverteilung verletzt. Um eine weitere Analyse der Tageszeitabhängigkeit des Regelzonensaldos vorzunehmen, sind in Abbildung 2.25 die stündlich aggregierten Mittelwerte der Regelzonensalden für die Jahre 2011 bis 2013 (2.25a) sowie für die einzelnen Regelzonen im Jahr 2012 (2.25b) dargestellt.

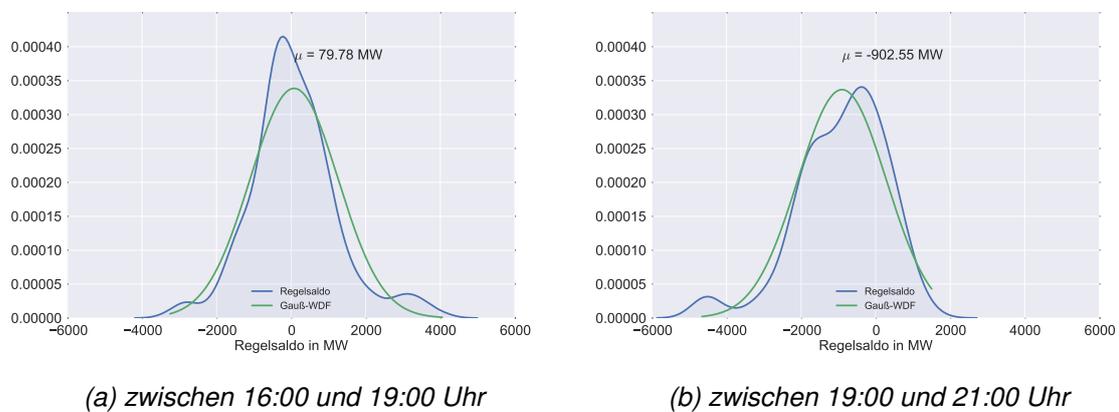
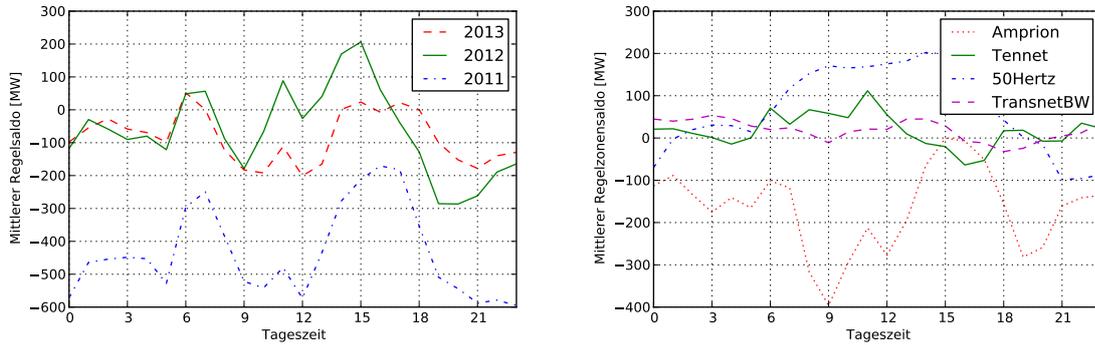


Abbildung 2.24: Verteilung des Regelsaldos im NRV im Dezember 2012

Man erkennt, dass es einen deutlichen Zusammenhang zwischen dem Mittelwert des Regelzonensaldos und der Tageszeit gibt. Dabei war dieser Einfluss im Jahr 2011 (untere gepunktete Linie) noch stärker ausgeprägt als in den Jahren 2012 und 2013. Insbesondere in den Zeiten starker Lastveränderungen in den Morgenstunden (zwischen 05:00 und 09:00 Uhr) und in den Nachmittagsstunden (zwischen 14:00 und 18:00 Uhr) gibt es einen deutlichen Anstieg des Saldos. Insgesamt lässt sich anhand der Kurven auch die bereits zuvor erwähnte Verschiebung des Mittelwertes von einem negativen (überdeckten) Wert (2011) zu einem positiven (unterdeckten) Wert (2012/2013) feststellen.

⁶⁷ Dies Abgrenzung ergibt sich nur aus zeitlichen Merkmalen.



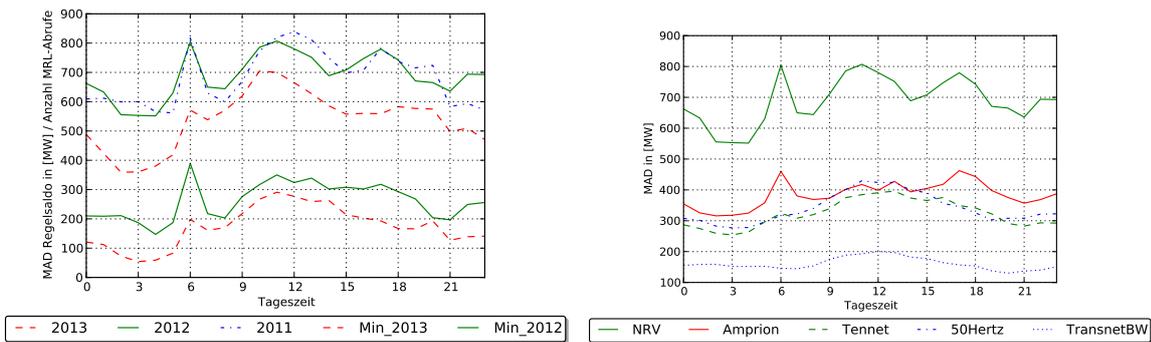
(a) Mittelwerte im NRV (2011-2013)

(b) Mittelwerte der Regelzonen im Jahr 2012

Abbildung 2.25: Stündliche Mittelwerte des Regelzonensaldos

Betrachtet man nur das Jahr 2012 so kann man anhand der rechten Abbildung feststellen, dass diese Tageszeitabhängigkeit regional zwischen den einzelnen Regelzonen stark differenziert. So ist das zeitliche Muster des NRV zum größten Teil auf die Regelzone von Amprion zurückzuführen⁶⁸.

Zur Analyse der Tageszeitabhängigkeit der Varianz werden für den Regelzonensaldo jeweils die mittlere absolute Abweichung vom Mittelwert (engl. mean absolute deviation (MAD)) stündlich aggregiert. Das Ergebnis ist in Abbildung 2.26a dargestellt. Zur Verdeutlichung des Zusammenhangs zwischen der Varianz des Saldos und der Aktivierung von Regelleistung werden in der unteren Bildebene zusätzlich die Aktivierungen von MRL (positiv und negativ) eingezeichnet. Die durchgezogenen Linien zeigen jeweils das Jahr 2012 und die gestrichelten Linien das Jahr 2013. Beiden Linien zeigen jeweils eine deutliche Korrelation. Ferner ist zu erkennen, dass es einen deutlichen Anstieg sowohl des MAD als auch der MRL-Aktivierung um 06:00 Uhr gibt. Diese Häufung der Aktivierung ist in erster Linie auf die Amprion Regelzone zurückzuführen, wie in Abbildung 2.26b erkennbar ist.



(a) MAD und MRL-Abrufe im NRV

(b) MAD in den Regelzonen in 2012

Abbildung 2.26: Stündlicher MAD des Regelsaldos und stündlicher Abruf von MRL

In Tabelle 2.11 sind die Mittelwerte der stündlichen Korrelationen der Regelzonensalden untereinander und mit dem Regelsaldo des NRV dargestellt. Dabei ist der entscheidende Wert der Median, da sich ansonsten negative und positive Korrelationen im Mittel ausgleichen.

⁶⁸ Diese Regelzone weist die höchste Netzlast in Deutschland auf.

2012	Summe	50Hertz	Amprion	Tennet	TransnetBW
Summe (mean)	1,00000	0,52209	0,68486	0,50955	0,12936
Summe (median)	1,00000	0,73916	0,87807	0,74932	0,02262
50Hertz (median)	0,73916	1,00000	0,36086	0,28209	-0,01960
Amprion (median)	0,87807	0,36086	1,00000	0,26046	-0,01664
Tennet (median)	0,74932	0,28209	0,26046	1,00000	-0,06196
TransnetBW (median)	0,02262	-0,01960	-0,01644	-0,06196	1,00000

Tabelle 2.11: Mittelwert bzw. Median der stündlichen Korrelation der Regelsalden

Der Regelzonensaldo der Amprion Regelzone hat mit 0,88 eine hohe Korrelation und damit Ähnlichkeit mit dem Gesamtsaldo des NRV. Ähnlich hoch korreliert sind die Regelsalden der Tennet und 50 Hertz Regelzone. Lediglich der Regelzonalensaldo der TransnetBW Regelzone ist quasi unabhängig vom NRV, bzw. der Einfluss der Regelzone auf den Gesamtsaldo ist nicht messbar. Untereinander sind die Regelzonensalden nur schwach korreliert, was die Annahme der statistischen Unabhängigkeit der Systemungleichgewichte in den einzelnen Regelzonen bestätigt. Eine negative Korrelation und damit das Potential zur gegenseitigen Kompensation weist jedoch nur der Saldo der TransnetBW Regelzone auf. Da es sich bei den Werten jedoch um die Median Werte handelt, ist davon auszugehen, dass es zwischen den anderen Regelzonen ebenfalls zeitweilig gegenläufige Tendenzen geben wird.

Wie in Kapitel 2.1.4 dargestellt, entspricht die aktivierte Regelleistung exakt dem aggregierten Regelsaldo. Die benötigte GRL entspricht demnach dem Erwartungswert des Saldos, bzw. die GRL-Mengen ließen sich entsprechend der Verteilung des Saldos anpassen. Daher werden in den Abbildungen 2.27 und 2.28 die Regelsaldenverteilungen für verschiedene Zeitscheiben der Regelleistungsauktion untersucht. Dazu wird zum einen die Verteilung für die jeweiligen vier Stunden (über das Jahr aggregiert) ermittelt und zum anderen werden die Perzentile der aktuellen Sicherheitsniveaus berechnet (jeweils durchgezogene Linien bzw. untere Werte). Im Vergleich sind die vorgehaltenen Mengen als gestrichelte Linien (obere Werte) eingezeichnet. Schraffiert ergeben sich somit die möglichen Einsparungspotentiale.

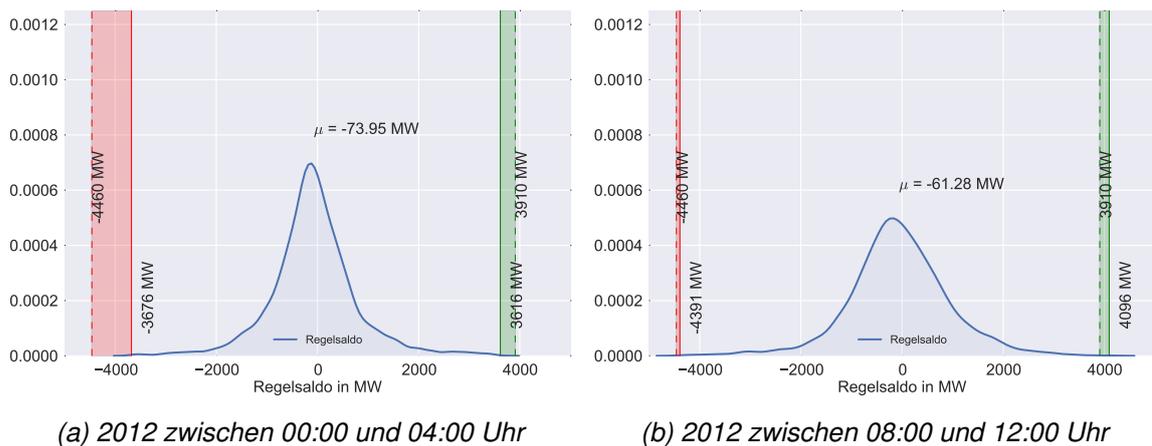


Abbildung 2.27: Regelsaldo im NRV in den Auktionszeitscheiben im Jahr 2012

Es hätte sich so insbesondere nachts zwischen 00:00 und 04:00 Uhr GRL einsparen lassen; wobei ein deutlicher Unterschied zwischen den Jahren 2012 und 2013 erkennbar ist. Lag das negative

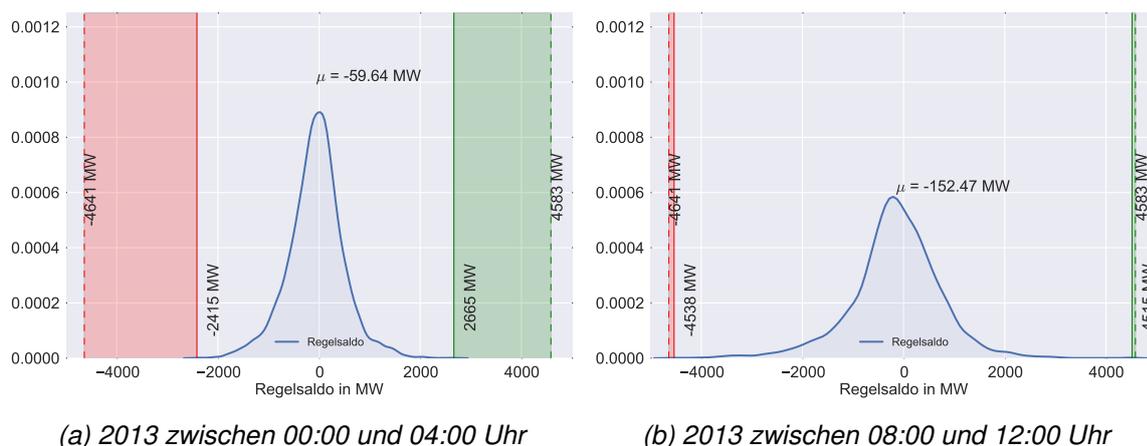


Abbildung 2.28: Regelsaldo im NRV in den Auktionszeitscheiben im Jahr 2013

Einsparungspotential im Jahr 2012 bei 784 MW so wären es im Jahr 2013 mit 2.226 MW fast das Dreifache gewesen. Demgegenüber ließe sich für die Zeitscheibe zwischen 08:00 und 12:00 Uhr keine Regelleistung einsparen; im Gegenteil, im Jahr 2012 war die positive Regelleistung in diesem Zeitfenster nicht ausreichend.

Korrelation auf verschiedenen Zeitskalen

Hurst hat im Jahr 1951 die Beobachtung gemacht, dass die Höhe von Extremereignissen, bzw. der Wertebereich q einer Zeitreihe potentiell von ihrer Auflösung oder Aggregation k abhängt. Insbesondere lässt sich an der Art wie die *Autokorrelationen* einer Zeitreihe mit der Zeit abnehmen, eine Aussage über ihr „Langzeitgedächtnis“ (Langzeit-Persistenz) bzw. über ihre Vorhersagbarkeit treffen. Dieses kann mit dem sogenannten Hurst Exponenten⁶⁹ bewertet werden. Der Hurst Exponent kann als relative Tendenz einer Zeitreihe interpretiert werden. Er kann Werte zwischen null und eins annehmen. Dabei stellt er eine Verallgemeinerung der Fraktalen „Brownschen“ Bewegung als eine Modellklasse für Zeitreihen mit Langzeitabhängigkeiten dar⁷⁰. Er misst quasi das Verhältnis der Strecke, die eine Zeitreihe zurücklegt zur dafür benötigten Zeit T . D.h. je größer die Varianz bzw. je häufiger die Frequenz der Schwankungen, desto geringer die Strecke, die entlang der Zeitachse zurückgelegt wird in Relation zur Gesamtstrecke. Je größer der Hurst-Exponent, desto geringer die mittlere Häufigkeit der Wechsel zwischen Aufwärts- und Abwärtsverhalten. Der Hurst Exponent bewertet somit die relative Varianz oder Volatilität einer Zeitreihe, im Verhältnis zu ihrer Länge. Er ist entsprechend Formel 2.2 [KB11] definiert.

Aus der Formel des Random Walk ergibt sich ein Hurst Exponent von 0,5, der am schwersten zu prognostizieren ist, da es keine Beziehungen zu früheren Realisationen gibt [KB11]. Je größer der Hurst-Exponent, desto größer das Langzeitgedächtnis, bzw. je wahrscheinlicher, dass ein Trend in der Zeitreihe vorhanden ist. So entspricht ein H-Wert von eins einer Geraden. Wenn der Hurst Exponent abnimmt, gibt es Beziehungen zu früheren Realisationen bzw. Muster, die sich für eine Vorhersage nutzen lassen. Ein Exponent von null steht für eine stationäre Zeitreihe.

⁶⁹ Harold Edwin Hurst (1880-1978) hat die Methode des reskalierten Bereichs („rescaled range analysis“) – R S-Analyse – entwickelt (siehe Kantelhardt: „Langzeitkorrelationen in der Natur“, 2012).

⁷⁰ Einstein fand 1908 heraus, dass sich die Strecke R , die ein Partikel zurücklegt in Relation setzen lässt zur Zeit T und es gilt: $R = T^{0.5}$.

Hurst Exponent H

$$H = \frac{\log(R/S)}{\log(T)} \quad (2.2)$$

mit R als die maximale Werte-Spanne innerhalb des Zeitfensters T
 S als die Standardabweichung im Zeitfenster T

$$R/S = k * T^H \quad (2.3)$$

- $0 \leq H < 0.5$ Antipersistenz/Autokorrelation
- $H = 0.5$ Random Walk
- $H > 0.5 \leq 1.0$ Persistenz/Trend

Neben der Brownschen Bewegung lässt sich der Wert auch von der Fraktalanalyse herleiten, die die Selbstähnlichkeit von „Fraktalen“ bemisst. Im Falle von Zeitreihen drückt der Hurst Exponent somit aus, wie selbstähnlich eine Zeitreihe mit sich selbst ist oder anders ausgedrückt, wie kontrolliert ihre Zufälligkeit ist. So misst der Hurst Exponent die „Rauhigkeit“ der Zeitreihe, die mit wachsendem Exponenten abnimmt. So kann man die Dimension einer Zeitreihe in Beziehung zum Hurst Exponenten wie folgt ausdrücken [KB11]:

$$D = 2 - H \quad (2.4)$$

Daraus folgt, dass eine maximal glatte Zeitreihe mit einem H-Wert von eins auch eine Dimension von eins hat, was genau einer Geraden entspricht. Diese lineare Form einer Zeitreihe hat ein maximales Langzeitgedächtnis und alle späteren Realisationen lassen sich anhand früherer Realisationen vorher-sagen bzw. berechnen. So lässt sich der Hurst Exponent auch mit Hilfe der Autokorrelation schätzen, indem man die Varianz der logarithmierten Lag-Werte bestimmt. Da für einen Random Walk die log (Varianz) im Verhältnis der log (Verzögerungswerte) mit dem Wert der Verzögerung stetig anwächst, lässt sich der H Wert in Anlehnung daran wie folgt schätzen⁷¹:

$$E(|\log(t + \tau) - \log(t)|^2) \approx \tau^{2H} \quad (2.5)$$

Abbildung 2.29 zeigt die Ergebnisse der Berechnung des Hurst Exponenten für den Netzregelver-bund im Jahr 2012 für zwölf Stunden und für einen Monat. Die Abbildung 2.29a stellt dabei die Vergrößerung des ersten Abschnitts der Abbildung 2.29b dar. Man kann erkennen, dass der Hurst Exponent bei Zunahme der Verzögerungswerte abnimmt, so beträgt er über vier Stunden noch 0,32 während er bei einem Monat nur noch einen Wert von 0,018 hat. Der Wert entspricht der Hälfte der Steigung der eingezeichneten Geraden⁷². Die Hurst Exponenten für die einzelnen Regelzonen sowie für die Jahre 2011 und 2013 verhalten sich entsprechend. Es kann demnach gezeigt werden, dass eine korrelierte Zeitreihe vorliegt, wobei die Varianz der Werte zunächst deutlich in Abhängigkeit der Verzögerung ansteigt, mit wachsendem Lag jedoch gegen null tendiert. So nähert sich die Gerade

⁷¹ Zur Berechnung des Hurst Exponenten mit *python* siehe: [<https://www.quantstart.com/articles/Basics-of-Statistical-Mean-Reversion-Testing>], zuletzt geprüft am 10.08.2015.

⁷² Die iterative Berechnung des Hurst Exponenten erfolgt, indem eine Regressionsgerade auf den log-Werten gefittet wird.

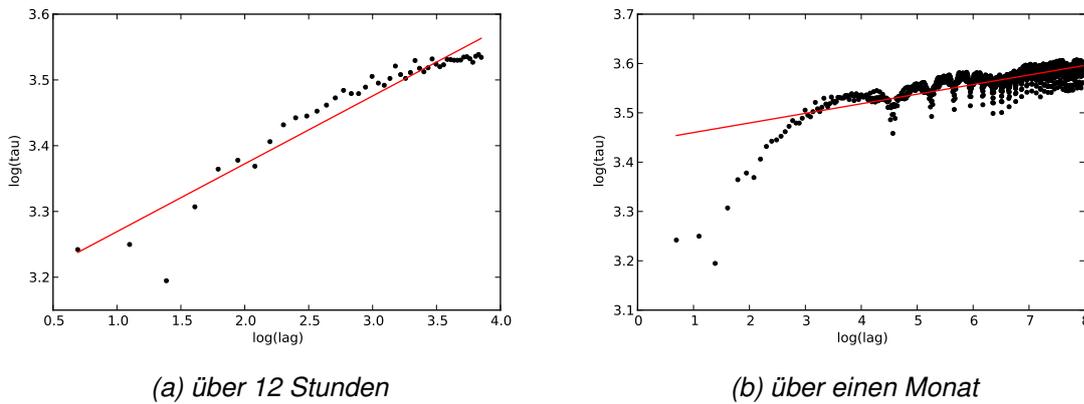


Abbildung 2.29: Berechnung des Hurst Exponenten für den NRV in 2012

mit steigender Verzögerung einer Waagerechten. Das heißt für globale Modelle mit genügend großen Zeitbereichen ergeben sich für den Regelzonensaldo zeitinvariante Mittelwerte und Varianzen, die Zeitreihe besitzt keinen Trend. Verringert man die Zeithorizonte jedoch und betrachtet lokale Modelle, lassen sich zum Beispiel stark ausgeprägte tägliche Autokorrelationen (siehe Abbildung 2.29b) finden.

Trägt man die Korrelationskoeffizienten zur Verzögerung r_τ über der Verzögerung τ auf, so erhält man das sogenannte "Korrelogramm", anhand dessen man zum Beispiel zeitliche Abhängigkeiten der Zeitreihe erkennen kann [KN06]. In Abbildung 2.30 sind beispielhaft zwei wöchentliche Autokorrelationsverläufe für den Netzregelverbund dargestellt. Während man bei beiden eine starke tägliche Autokorrelation feststellen kann, d.h. eine Tageszeitabhängigkeit, ist der Verlauf bzw. die Ausprägung der Autokorrelation sehr unterschiedlich.

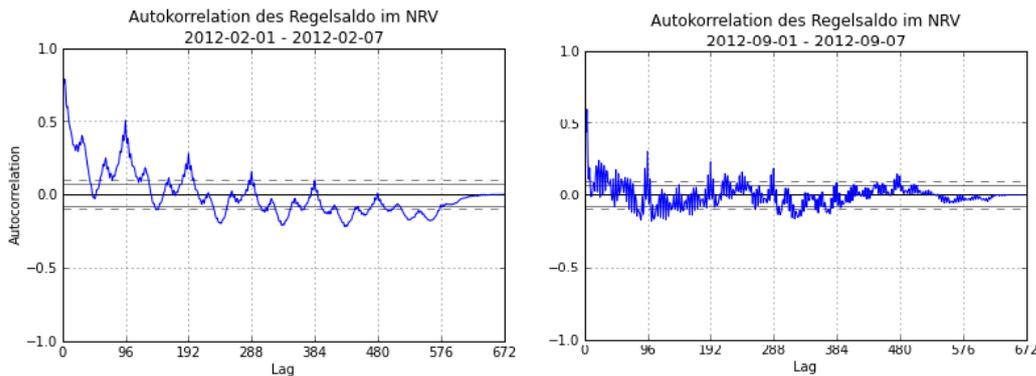


Abbildung 2.30: Autokorrelation des Regelsaldo im Netzregelverbund

Die Autokorrelation sowie die Tageszeitabhängigkeit des Regelzonensaldo sprechen daher für eine gewisse **Periodizität** der Zeitreihe, die sich für die Vorhersage nutzen lässt. Der zeitlich unterschiedliche Verlauf der Autokorrelation sowie die teilweise erheblichen Unterschiede zwischen den beiden Testjahren 2012 und 2013 sprechen jedoch auch dafür, dass sich die wesentlichen Informationen über die Verteilung der Zeitreihe nicht ausschließlich aus früheren Realisationen der Zeitreihe selbst ablei-

ten lassen. Dies bestätigt die Annahme, dass neben den Zeitmerkmalen noch weitere entscheidende Einflussgrößen für die Struktur und Dynamik des Saldos verantwortlich sind. Ein Zusammenhang zwischen dem Börsenpreis PHB an der EEX und der Regelleistungsaktivierung im Februar 2012 konnte bereits gezeigt werden. Der Effekt weiterer Einflussgrößen wird im nächsten Kapitel untersucht.

2.2.4 Effektanalyse der Einflussgrößen

Wie in der Einleitung erwähnt, ist eine geänderte Wissensbasis über den Ursache-Wirkungs-Zusammenhang im Bezug auf die Bilanzungleichgewichte innerhalb des Netzes die entscheidende Voraussetzung für eine optimierte Regelleistungsbemessung. Im Folgenden wird daher der Ursache-Wirkungs-Zusammenhang zwischen den einzelnen Einflussgrößen und deren Auswirkung auf den Regelzonensaldo und damit die Regelleistungsinanspruchnahme untersucht. Dazu werden die Zusammenhänge im Rahmen dieser Datenanalyse zunächst qualitativ anhand einer Korrelationsanalyse ermittelt, bevor anschließend im Rahmen des Prognosemodells eine quantitative Analyse der Einflussfaktoren mit Hilfe von Entscheidungsbäumen vorgenommen wird. Um einen möglichst exakten (nicht verrauschten) Zusammenhang zwischen Regelleistungsabruf und Regelsaldo zu erhalten, wird für die Analyse der korrigierte Regelzonensaldo verwendet. Die Analyse dieses Zusammenhanges ist entscheidend für die Gewichtung bzw. Auswahl der Merkmale. Dabei ist sowohl die Korrelation der Einflussgrößen zum Regelsaldo von Bedeutung, als auch die Korrelation/Wechselwirkung der Einflussgrößen untereinander, da diese ein Maß für die Unabhängigkeit der Einflussgrößen darstellt. Es werden sowohl regionale als auch zeitliche Korrelationen untersucht. Zum einen werden die regionalen Korrelation der einzelnen Zeitreihen über die Regelzonen hinweg und zum anderen die zeitliche Korrelation der Zeitreihen untereinander betrachtet.

Eine vorhandene Korrelation ist jedoch kein Garant dafür, dass es tatsächlich eine Ursache-Wirkungs-Beziehung in die eine und/oder andere Richtung gibt. Die Korrelation ist lediglich eine qualitative Aussage über die Ähnlichkeit des Kurvenverlaufs zweier Zeitreihen und damit über die Stärke der Abhängigkeit. Sie ist ein Maß für den linearen Zusammenhang zwischen zwei Zeitreihen, da der Korrelationskoeffizient dem Regressionskoeffizienten entspricht. Liegt allerdings tatsächlich eine Ursache-Wirkungs-Beziehung vor, erwartet man eine Korrelation von Ursache und Wirkung. Dabei gibt es prinzipiell 5 verschiedene Ursachen, die zu einem Zusammenhang (nicht verschwindender Korrelationskoeffizient) zwischen x und y führen [FK08]:

- x ist Ursache (oder Teil der Ursache) von y (kausaler Zusammenhang)
- y ist Ursache (oder Teil der Ursache) von x (umgekehrte Kausalität)
- x und y sind kausal unabhängig voneinander, aber hängen kausal von einer dritten Größe z ab (z. B. von der Zeit)
- Korrelation ist Folge eines systematischen Fehlers
- Korrelation ist Folge einer statistischen Fluktuation (zufälliger Zusammenhang)

Korrelation der Einflussgrößen mit der Zielgröße

Bei den Einflüssen auf den Regelsaldo hat in den vergangenen Jahren insbesondere der Einfluss der EE-Einspeisung zugenommen. So führten die durch ihre volatile Erzeugung entstehenden Prognosefehler zu einem vermehrten Bedarf an Regelenergie und einer höheren Varianz des Saldos. Dabei hängen die Auswirkungen der einzelnen EE-Fehler wesentlich von der Jahreszeit ab. So wirkt sich die Tatsache, dass die Wind- und PV-Einspeisung im saisonalen Verlauf gegenläufig sind, positiv auf den Saldo aus. Abbildung 2.31 zeigt die mittleren Einspeisemengen aus Wind und PV für den Netzregelverbund im Jahr 2012. Bildet man die Summe beider Einspeisungen, so bleibt diese über das Jahr nahezu konstant.

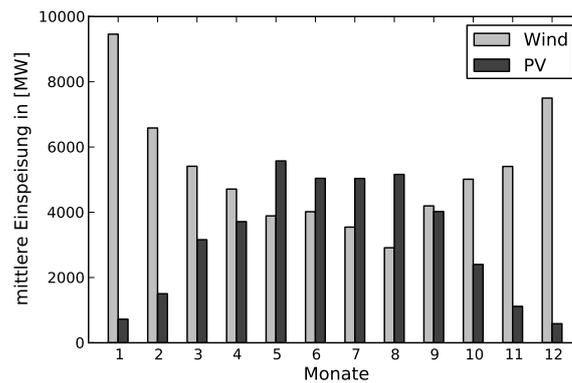
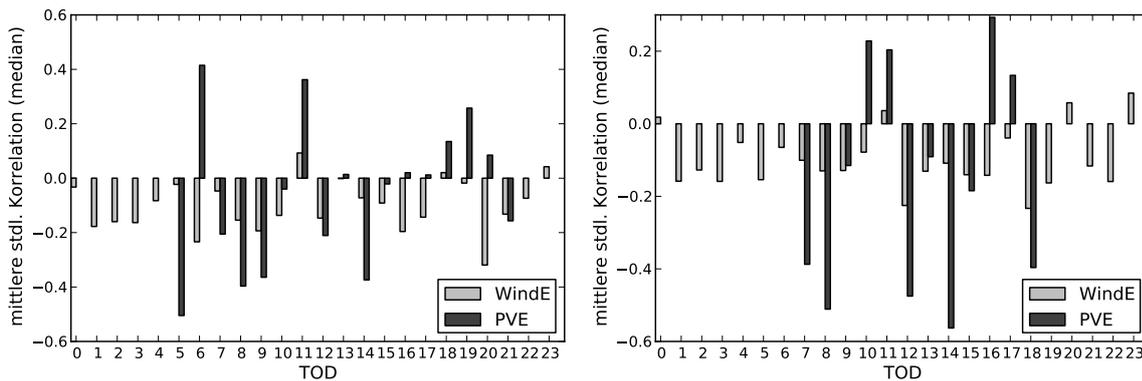


Abbildung 2.31: Mittlere Wind- und PV-Einspeisung im NRV 2012

In Bezug auf ihre Auswirkungen auf den Regelsaldo haben die Wind- und PV-Einspeisung jedoch eine unterschiedliche Charakteristik. Um diese zu analysieren, werden zunächst die stündlichen Korrelationen zwischen der Windeinspeisung und dem Regelsaldo sowie zwischen der PV-Einspeisung und dem Regelsaldo für den Netzregelverbund berechnet. Abbildung 2.32 zeigt die stündlichen Mittelwerte der Korrelationskoeffizienten getrennt nach Winter und Sommer.



(a) im Sommer (Mai - Sep.)

(b) im Winter (Jan.-Apr./Okt.-Dez.)

Abbildung 2.32: Korrelation der Wind- und der PV-Einspeisung mit dem Regelsaldo

Während die Windeinspeisung nahezu konstant schwach negativ mit dem Regelsaldo korreliert ist, besteht bei der PV-Einspeisung ein deutlich ausgeprägterer Zusammenhang mit dem Regelsaldo. Ins-

besondere in den Winterzeitmonaten besteht eine zum Teil recht deutliche negative Korrelation, die Werte bis $-0,6$ erreicht. Dabei ist im Unterschied zur Windeinspeisung eine hohe Dynamik der Wechselwirkung zwischen der PV-Einspeisung und dem Regelsaldo erkennbar, was sich aus dem stetigen Wechsel der Korrelationsvorzeichen ergibt. Gründe hierfür sind zum einen die Anpassung der PV-Einspeisung an die Strommarktprodukte (siehe Kapitel 2.1.3) und zum anderen die Wechselwirkung mit der Netzlast. So kommt es in den Wintermonaten in denen der Sonnenaufgang mit dem Lastanstieg zusammenfällt, zu einer anderen Korrelationscharakteristik als in den Sommermonaten, in denen der Sonnenaufgang eine zeitliche Verschiebung zum Lastanstieg hat. Die Solareinspeisung hat somit einen wesentlich direkteren bzw. kurzfristigeren Einfluss auf den Regelsaldo als die Windproduktion. Dies gilt insbesondere in Zeiten starker Volatilität des Regelsaldo aufgrund von Lastrampen; hier erreicht der Korrelationskoeffizient zwischen Wind und Regelsaldo seinen Minimalwert.

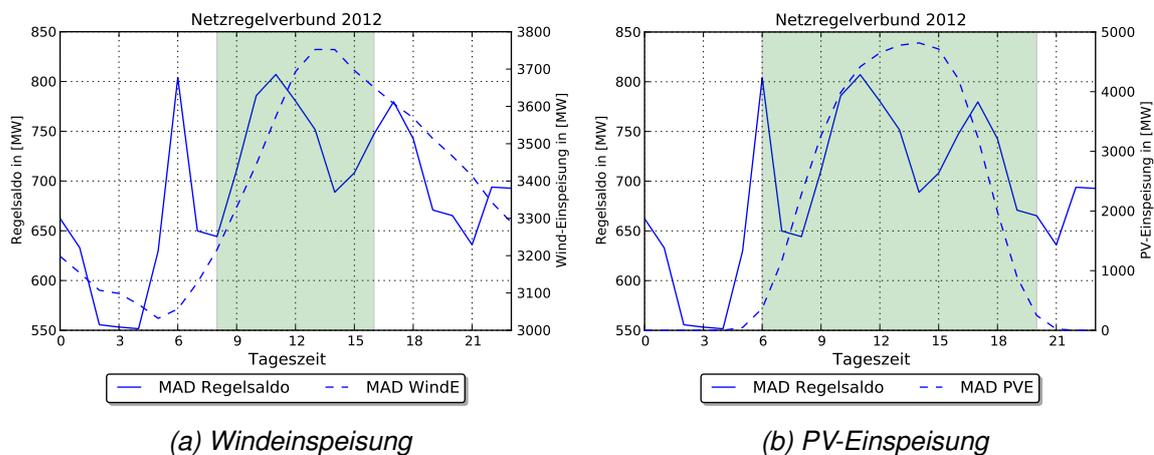


Abbildung 2.33: MAD des Regelsaldos im NRV in 2012

Um eine mögliche Wechselwirkung zwischen der EE-Einspeisung auf die Volatilität bzw. Varianz des Regelsaldos feststellen zu können, wird die MAD des Regelsaldos mit den MAD der Wind- sowie PV-Einspeisung verglichen. In Abbildung 2.33 ist erkennbar, dass der Anstieg des MAD des Regelsaldos um 9:00 Uhr sowohl eine Folge der erhöhten Volatilität der Wind- als auch der PV-Einspeisung ist; wobei die Spannweite des MAD der PV-Einspeisung ein vielfaches der Windeinspeisung beträgt. Der beachtliche Anstieg bzw. Peak um 06:00 Uhr ist dagegen eine Folge des Lastanstiegs. Abbildung 2.34 zeigt die MAD für die vertikale Netzlast sowie den PHB im Tagesverlauf. Sowohl die Volatilität der Netzlast als auch des Basepreises steigen zwischen 05:00 und 07:00 Uhr steil an. Die Verläufe der Kurven in Abbildung 2.34b zwischen 16:00 und 19:00 Uhr lassen zudem auf einen Zusammenhang zwischen dem Basepreis und dem Regelsaldo in diesem Zeitfenster schließen. Um dies näher zu untersuchen werden daher auch hier die stündlichen Korrelationen zwischen diesen Einflussgrößen und dem Regelsaldo nach Tageszeiten ausgewertet (Abbildung 2.35).

Es ist zu erkennen, dass sich sowohl für die Zeit zwischen 05.00 und 09:00 Uhr als auch zwischen 17:00 und 19:00 Uhr starke negative Korrelationen zwischen dem Basepreis und dem Regelsaldo ergeben. Weitere negative Korrelationen finden sich in der Nacht, wobei dies in erster Linie auf die abnehmende Netzlast zurückzuführen ist. Für die vertikale Netzlast ergibt sich eine fast durchgehend positive Korrelation. Auffällig ist der Zusammenhang zwischen beiden Korrelationen; so steigt die Korrelation des Basepreises in Zeiten in denen die Korrelation der vertikalen Netzlast abnimmt. Dies bestätigt die eindeutige Wechselwirkung zwischen dem Basepreis und der vertikalen Netzlast; je nied-

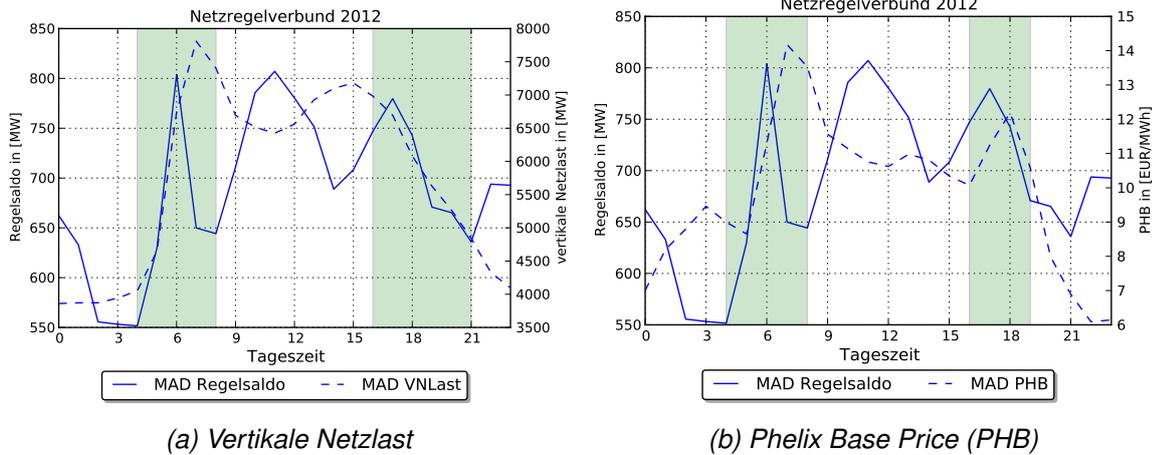


Abbildung 2.34: MAD des Regelsaldos im NRV in 2012

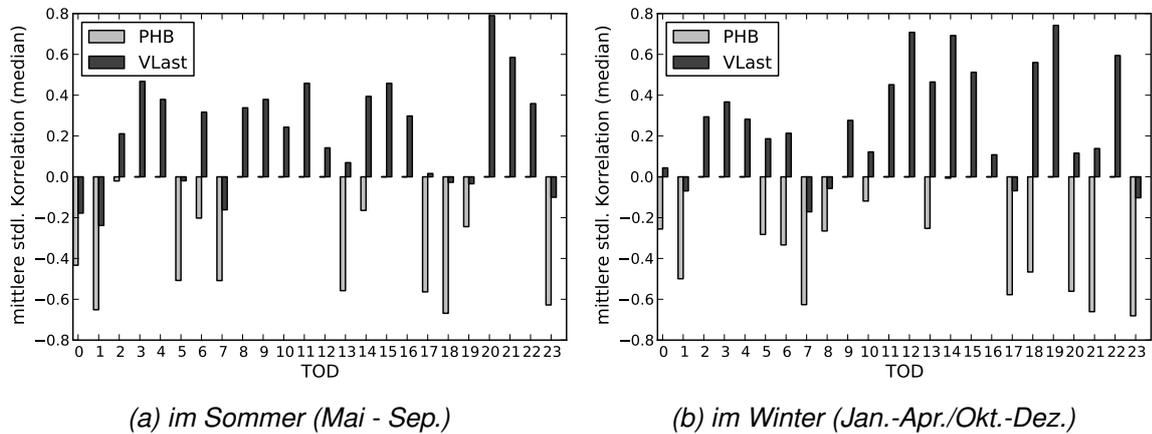


Abbildung 2.35: Korrelation des PHB und der vertikalen Netzlast mit dem Regelsaldo

riger die vertikale Netzlast, desto geringer der Basepreis. Um weitere Wechselwirkungen zwischen den einzelnen Einflussfaktoren zu analysieren wird im Folgenden die Korrelation der Einflussgrößen untereinander betrachtet.

Korrelation der Einflussgrößen untereinander

In den skandinavischen Ländern gibt es eine leichte positive Korrelation zwischen der Windproduktion und der Last; diese liegt bei 0,21 in Dänemark, 0,16 in Finnland, 0,37 in Norwegen; 0,24 in Schweden und im Mittel bei 0,31⁷³. "Diese Korrelation lässt sich allerdings nur für den Sommer feststellen und kommt aus der Tageszeitabhängigkeit der Windproduktion. Im Winter ist die Korrelation nahezu null"[Hol04]. Zum Vergleich mit den deutschen Verhältnissen ist in Abbildung 2.36 der wöchentliche Mittelwert der stündlichen Korrelation zwischen der Windeinspeisung und der vertikalen Netzlast dargestellt. Man erkennt auch hier eine geringe negative Korrelation in den Sommermonaten, die im Jahresmittel -0,16 beträgt. Jedoch ist die Korrelation im Unterschied zu den skandinavischen Ländern negativ, was damit zusammenhängt, dass hier nicht die nachgefragte Last sondern die ver-

⁷³ Zahlen aus [Hol04].

tikale Netzlast betrachtet wird. Und diese ist im Sommer in Zeiten starker PV-Einspeisung negativ. Nichts desto trotz lässt sich auch hier eine stärkere Korrelation in den Sommermonaten feststellen, die die Tageszeitabhängigkeit der Windproduktion in den Sommermonaten bestätigt.

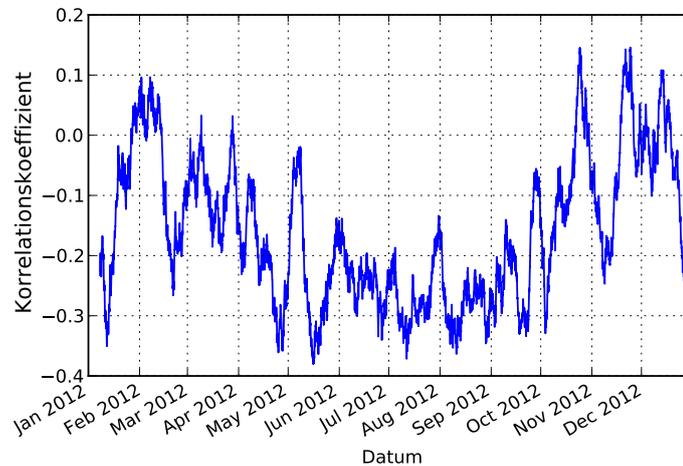


Abbildung 2.36: Korrelation der Windeinspeisung mit der vertikalen Netzlast

Zur Analyse der regionalen Korrelation der Einflussgrößen sind in den Tabellen 2.12 und 2.13 die Korrelationen der EE-Einspeisung und -Fehler zwischen den Regelzonen bzw. in Bezug auf den Netzregelverbund dargestellt⁷⁴. Dabei gibt die Korrelation mit dem NRV einen Aufschluss über die regionale Bedeutung einer Regelzone in Bezug auf die Einflussgröße, wobei die Korrelation bei der PV-Einspeisung aufgrund der Tageszeitabhängigkeit in allen Regelzonen ähnlich hohe Werte annimmt. So sind auch die Korrelationen der Regelzonen untereinander hoch, dennoch lässt sich anhand des geringen Korrelationskoeffizienten zwischen der Regelzone von 50 Hertz und der Regelzone von TransnetBW ein klares Nord-Süd-Gefälle erkennen. Während man für die Einspeisungen klare regionale Abhängigkeiten feststellen kann, sind diese für die Prognosefehler wesentlich geringer.

	NRV		50Hertz		Amprion		Tennet		TrBW	
	WE	W_Err	WE	W_Err	WE	W_Err	WE	W_Err	WE	W_Err
NRV	1,000	1,000	0,946	0,755	0,830	0,579	0,967	0,786	0,566	0,115
50Hertz	0,946	0,755	1,000	1,000	0,665	0,172	0,856	0,302	0,510	0,056
Amprion	0,830	0,579	0,665	0,172	1,000	1,000	0,794	0,333	0,650	0,128
Tennet	0,967	0,786	0,856	0,302	0,794	0,333	1,000	1,000	0,479	0,028
TrBW	0,566	0,115	0,510	0,056	0,650	0,128	0,479	0,028	1,000	1,000

Tabelle 2.12: Korrelation zwischen den Regelzonen 2012 - Wind-einspeisung und -fehler

Zwar lässt sich auch hier eine positive regionale Korrelation feststellen, die Maximalwerte liegen jedoch deutlich unter denen für die Einspeisung. Während für die Windeinspeisung eine maximale Korrelation zwischen den Regelzonen von 50 Hertz und Tennet von 0,856 berechnet wurde, liegt die Korrelation der Windfehler zwischen beiden Regelzonen nur noch bei 0,302. Bei der PV-Einspeisung

⁷⁴ Für die PV-Einspeisung wurden nur die Intervalle zwischen Sonnenauf und -untergang betrachtet.

	NRV		50Hertz		Amprion		Tennet		TrBW	
	PVE	P_Err	PVE	P_Err	PVE	P_Err	PVE	P_Err	PVE	P_Err
NRV	1,000	1,000	0,926	0,515	0,979	0,565	0,985	0,791	0,906	0,437
50Hertz	0,926	0,515	1,000	1,000	0,872	0,047	0,892	0,345	0,770	0,080
Amprion	0,979	0,565	0,872	0,047	1,000	1,000	0,959	0,159	0,881	0,054
Tennet	0,985	0,791	0,892	0,345	0,959	0,159	1,000	1,000	0,854	0,104
TrBW	0,906	0,437	0,770	0,080	0,881	0,054	0,854	0,104	1,000	1,000

Tabelle 2.13: Korrelation zwischen den Regelzonen 2012 - PV-einspeisung und -fehler

besteht eine maximale regionale Korrelation zwischen den Regelzonen von Amprion und Tennet von 0,959, die Korrelation des PV-Fehlers in beiden Regelzonen liegt mit 0,159 im nicht mehr signifikanten Bereich. Die maximal regionale Abhängigkeit zwischen den PV-Fehlern besteht mit einem Koeffizienten von 0,345 zwischen den Regelzonen von 50 Hertz und Tennet. Sowohl Wind- als auch PV-Fehler sind somit stark regional gebunden und ihre deutschlandweite Korrelation ist gering. Dies bestätigen die geringen stündlichen Korrelationen der Regelsalden der einzelnen Regelzonen (siehe Tabelle 2.10.). Die vier Regelzonensalden können somit als unabhängig voneinander betrachtet werden und die Bildung eines Gesamtregelsaldos aus den viertelstündlichen Summe der Einzelsalden ist statistisch korrekt.

2.3 Problemformulierung

2.3.1 Gegenüberstellung Prozess- und Datenanalyse

In der vorausgegangenen Prozess- und Datenanalyse konnte gezeigt werden, dass sich die „Energie-wende“ und der dadurch vermehrte Anteil dezentraler fluktuierender Einheiten in zweierlei Hinsicht auf den Bedarf und die Bereitstellung von Regelleistung auswirkt. Zum einen ergibt sich ein *veränderter Regelleistungsbedarf*, durch die Zunahme der durch Prognosefehler ausgelösten Leistungs-differenzen und zum anderen führt der Rückgang von konventioneller Erzeugung im Netz zu einer *veränderten Regelleistungsbereitstellung*. Tabelle 2.14 zeigt die geänderten Randbedingungen für den Bedarf an Regelleistung.

Der **veränderte Regelleistungsbedarf** ergibt sich aus den geänderten Risikofaktoren bzw. dem sich daraus ergebenden geänderten Einfluss auf die Frequenz. So wird die Regelleistung heute nicht mehr in erster Linie zur Kompensation von Kraftwerksausfällen und damit zur Frequenzanhebung eingesetzt, sondern dient vielmehr dem flexiblen Ausgleich von fluktuierenden Leistungen aus erneuerbaren Energien, was insbesondere zu einer verstärkten Inanspruchnahme negativer Regelleistung geführt hat. Im Unterschied zu Kraftwerksausfällen sind die daraus resultierenden Systemungleichgewichte jedoch nicht zufällig und unabhängig vom Systemzustand. So konnten im Zuge der Datenanalyse eindeutige saisonale und zeitabhängige Muster in Bezug auf die Regelleistungsaktivierung nachgewiesen werden. Des Weiteren wurde eine Zunahme der Varianz bzw. der Volatilität des Regelsaldos gezeigt sowie eine verstärkte Dynamik im Wechsel zwischen positiver und negativer Regelleistungsaktivierung, die in der Folge immer flexiblere Leistungsanpassungen erfordert. Aufgrund von technischen Restriktionen wie zum Beispiel relativ niedrigen Leistungsänderungsgeschwindigkeiten oder Stillstands- und Mindestlaufzeiten ist es für Großkraftwerke technisch immer schwerer

	Vor der Energiewende	Aktueller Zustand / 2030
Risikofaktoren	<ul style="list-style-type: none"> ● Kraftwerksausfälle ● Lastrauschen 	<ul style="list-style-type: none"> ● Prognosefehler ● Lastrauschen
Eigenschaften	<ul style="list-style-type: none"> ● zufällig ● unabhängig vom Systemzustand 	<ul style="list-style-type: none"> ● vorhersehbar ● abhängig vom Systemzustand
Einfluss auf Frequenz	<ul style="list-style-type: none"> ● Frequenzabfall 	<ul style="list-style-type: none"> ● Schwankungen pos./neg.
Einflussgrößen	<ul style="list-style-type: none"> ● Netzlast ● (Alter der Kraftwerke) 	<ul style="list-style-type: none"> ● Netzlast ● EE-Erzeugung ● Prognosegüte ● Wetter ● Strompreise/Strategie
Bereitstellung	<ul style="list-style-type: none"> ● dediziert ● thermische Kraftwerke ● hohe Zuverlässigkeit ● lange Planungshorizonte 	<ul style="list-style-type: none"> ● dynamisch ● Verbünde dez. Einheiten ● geringe Zuverlässigkeit ● kurze Planungshorizonte

Tabelle 2.14: Vergleich Zustand vor der Energiewende - aktueller Zustand

möglich, diesen Anforderungen gerecht zu werden. So haben beispielsweise Kohlekraftwerke eine Änderungsgeschwindigkeit von maximal vier Prozent ihrer Leistung pro Minute. Die Stillstands- bzw. Mindestlaufzeit betragen für Braunkohlekraftwerke jeweils sechs Stunden, was sie für die kurzfristige Bereitstellung von Regelleistung unbrauchbar macht, sollten sie nicht bereits im Netz einspeisen. Dieses Einspeisen wird durch die stark gesunkenen Preise an der Strombörse zusehends unattraktiver bzw. nicht mehr gewinnbringend. Zudem reduzieren große Leistungsänderungen bei Großkraftwerken kurzfristig deren Wirkungsgrad und langfristig, wegen der dabei auftretenden zusätzlichen Materialspannungen, auch deren Lebensdauer und damit ihre Wirtschaftlichkeit⁷⁵ [FNE10]. Die dadurch entstehenden Opportunitätskosten oder auch Alternativkosten, die durch die entgangenen Erlöse am Strommarkt entstehen, können durch die stark gesunkenen Preise beispielsweise für positive Minutenreserve zunehmend schwerer kompensiert werden.

Der marktwirtschaftlich induzierte Rückzug der konventionellen Erzeugung – auch Merit-Order-Effekt⁷⁶ genannt – führt zu einem veränderten Kraftwerkspark im Netz und damit auch zu einer **veränderten Regelleistungsbereitstellung**. Diese veränderte Erzeugungszusammensetzung hat zum einen Auswirkungen auf die zukünftige Bereitstellung der ausgeschriebenen Regelleistung und zum anderen auf die Netzleistungszahl. So wird der Netzselbstregelungseffekt – und damit die Netzleistungszahl – durch einen Rückgang der rotierenden Massen im System sinken. Daher müssen in Zukunft auch die Wechselrichter-geführten erneuerbaren Erzeuger wie Windkraftanlagen und große PV-Einspeiser netzstabilisierende Aufgaben übernehmen. Das heute von rotierenden Generatoren gebildete Netz wird in langer Sicht in ein „leistungselektronisch, stromrichtergeführtes Netz“ übergehen [FNE10], [HatT14]. So werden sich in Zukunft mehr primärgeregelte Einheiten in den Verteilungsnetzen finden, die ebenfalls „in das Monitoring, die Automatisierung und den Datenverkehr (auch zwischen Übertragungsnetzbetreiber und Verteilnetzbetreiber (VNB))“ einzubinden sind [bde12]. Dies führt wiederum zur Notwendigkeit einer viel stärker informationstechnischen Integration über das gesamte System der Elektrizitätsversorgung und –nutzung, die unter dem Oberbegriff „Smart Grids“

⁷⁵ So reduziert sich beispielsweise der Wirkungsgrad einer Gasturbine um 22 % wenn sie auf Minimallast gefahren wird.

⁷⁶ Zur weiteren Erläuterung siehe Glossar am Ende der Arbeit.

zusammengefasst wird. Mit der Umsetzung des Netzregelverbundes wurden insbesondere im Bereich der Sekundärregelleistung und der Minutenreserve bereits zahlreiche Neuerungen umgesetzt, so dass sich heute bereits zahlreiche Anbieter von erneuerbaren Energien als Anbieter für Regelleistung finden. So wurden unter anderem die Ausschreibungszeiträume verkürzt und die Angebotsmengen reduziert. Diese Änderungen konzentrierten sich in der Vergangenheit jedoch ausschließlich auf das Marktdesign des Regelleistungsmarktes, während das Bemessungskonzept der auszuscheidenden Regelleistungsmengen nahezu unverändert beibehalten wurde. Im Folgenden wird ein Überblick über die Entwicklung der RL-Bemessung sowie den aktuellen Stand der Technik gegeben.

2.3.2 Entwicklung der RL-Bemessung -Stand der Technik

Einer der Vorreiter und Wegbereiter der analytischen Regelleistungsbemessung war Prof. Dr. Kurt Edwin, der bereits im Jahr 1979 Untersuchungen zu Kraftwerksreserven im Verbundsystem anstellte [EKT79]. Dabei lag der Fokus zu der damaligen Zeit allein auf dem Ausfall von Kraftwerksblöcken und deren Kompensation. So galt beispielsweise die Regel, dass die Minutenreserve mindestens der Leistungsmenge des größten im Betrieb befindlichen Blocks entsprechen solle ([EKT79], Seite 31). Erst mit dem Aufkommen der erneuerbaren Energien als Bestandteil der Stromproduktion ging die Bemessung mehr in eine wahrscheinlichkeitstheoretische Bestimmung des Regel- und Reservebedarfs vor dem Hintergrund der zunehmend volatilen Erzeugung über. So wurde das Verfahren im Jahr 2000 durch Dany weiterentwickelt, der als erster die Veränderungen auf die „Kraftwerksreserve“ bei großen Anteilen an Windenergie untersuchte [Dan00].

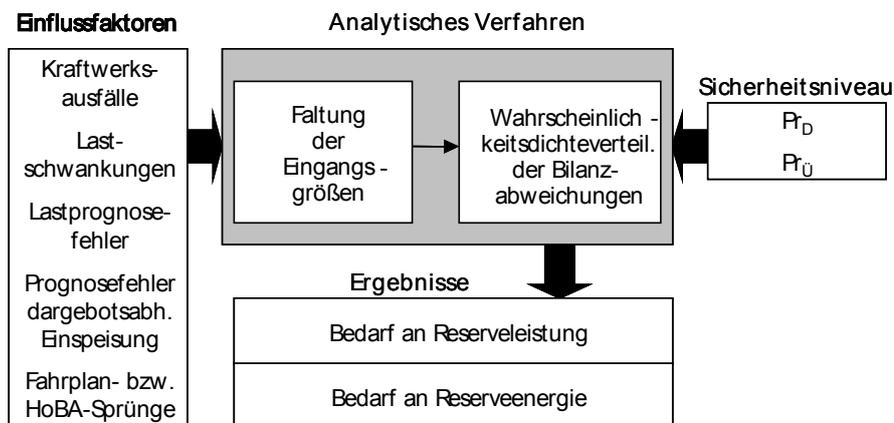


Abbildung 2.37: Vorgehen zur Regelleistungsbemessung nach Graf/Haubrich⁷⁷

Im Zuge der Liberalisierung musste dieses Verfahren an die neuen rechtlichen Rahmenbedingungen, insbesondere die Aufteilung in Regelzonen und die geänderte Verantwortung beim Regelzonenbetreiber, angepasst werden. Daher erstellte die E-Bridge-Consulting in Zusammenarbeit mit der Universität Dortmund im Jahr 2006 ein Gutachten im Auftrag der Bundesnetzagentur mit dem Ziel der Bestimmung des regelzoneninternen Regelleistungsbedarfs für Sekundärregelung und Minutenreserve, in der zudem vermehrt auf den Einfluss des EEG und der Windprognosefehler eingegangen wurde [EL06]. Ein vergleichbares Gutachten entstand zwei Jahre später unter der Leitung von

⁷⁷Abbildung aus [Con08, Seite 27]

Prof. Hans Jürgen Haubrich und der Consentec ebenfalls im Auftrag der Bundesnetzagentur [Con08]. Daraufhin erfolgte eine erneute Untersuchung des Bemessungsverfahrens durch die Consentec im Auftrag der Bundesnetzagentur im Jahr 2010 [Con10]. Hier lag der Fokus auf der Untersuchung einer gesamtdeutschen Regelleistungsvorhaltung im zuvor eingeführten Netzregelverbund (NRV). Auch heute erfolgt die Bemessung des Regelleistungsbedarfs auf diesem nach Graf und Haubrich [Con08][EL06] benannten Verfahren. Dieses Verfahren analysiert zunächst die für den Reservebedarf relevanten Einflussfaktoren und bildet aus den einzelnen Wahrscheinlichkeitsdichteverteilungen durch die mathematische Methode der Faltung eine gemeinsame Wahrscheinlichkeitsverteilung. Voraussetzung ist eine Unkorreliertheit der einzelnen Einflussfaktoren. Andernfalls wäre eine mehrdimensionale Copula-Funktion mit entsprechender Kovarianzmatrix zu berücksichtigen. Eine Übersicht des Verfahrens zeigt Abbildung 2.37.

Dabei waren die Regelleistungsmengen anfänglich so dimensioniert, dass für den Verbundbetrieb die für jede Regelzone vorgehaltene Sekundärregelleistung und Minutenreserve – Gesamtregelleistung (GRL) – mit einer Defizitwahrscheinlichkeit von rund 0,1 % ausreichte [EL06]. Im Zuge des Gutachtens zum NRV im Jahr 2010 wurden für die deutschlandweite Bemessung neue Grenzwerte für die Defizitwahrscheinlichkeiten eingeführt; diese liegen aktuell für Gesamtdeutschland jeweils bei 0,025 %. Dabei werden zwei Arten von Defiziten unterschieden[Con08]:

- **Leistungsdefizit infolge unzureichender GRL:**

Wird eine vollständige Substituierbarkeit von MRL durch SRL vorausgesetzt (was einer Vorwärts-poolung entspricht) kann die in Summe in beiden Qualitäten vorgehaltene Gesamtregelreserve (GRL, Summe aus SRL und MRL) zu gering sein, um eine auftretende Bilanzabweichung auszuregulieren. In diesem Fall entsteht ein Leistungsdefizit infolge unzureichender Gesamtreserve.

- **Leistungsdefizit infolge mangelnder SRL:**

Ein Defizit kann auch auftreten, wenn zwar ausreichend Gesamtregelreserve vorhanden ist, diese jedoch nicht zeitgerecht verfügbar ist, weil die Sekundärregelreserve allein nicht ausreicht und die Minutenreserve erst zeitverzögert vollständig aktivierbar ist. In diesem Fall entsteht ein Leistungsdefizit infolge unzureichender Sekundärregelreserve.

Diesem Problem wird mit der Aufteilung der Defizitwahrscheinlichkeiten auf die einzelnen Regelleistungsarten begegnet. Seit dem Jahr 2010 wird das Defizitniveau für die Regelzonenbemessung im Verhältnis 50/50 aufgeteilt, das entspricht einem Einzeldefizitniveau von jeweils 0,05 %. Für den Netzregelverbund wurde das Defizitniveau zwischen SRL und GRL im Verhältnis von 10 % zu 90 % (entsprechend absoluter Defizite von 0,0025 % und 0,0225 %) aufgeteilt. Dies unterstreicht die systemkritische Bedeutung der Sekundärregelleistung.

In den vergangenen Jahren fanden sich zunehmend Arbeiten, die statt einer analytischen Bemessung, eine simulative Vorgehensweise untersucht haben. So hat Brückl im Jahr 2006 [Brü08], in Anlehnung an das verwendete Verfahren, eine wahrscheinlichkeitstheoretische Bestimmung des Regel- und Reserveleistungsbedarfs als Monte-Carlo-Simulation vorgestellt, die den RL-Bedarf für jede RL-Art separat anhand der jeweiligen Wahrscheinlichkeitsdichten ermittelt. Des Weiteren wurden kraftwerks-, last- und windbedingte Leistungsausfälle statistisch analysiert mit dem Ergebnis, dass die Windprognosefehler den größten Einfluss auf die Höhe der bereitgestellten Menge haben, sollte der relative hohe Wert der Defizitwahrscheinlichkeit beibehalten werden. So stellte [Brü08] die Frage, bis zu welchem Ausmaß die bisherige Zuverlässigkeitsstrategie volkswirtschaftlich zu vertreten sei.

Viele nachfolgende simulative Arbeiten waren weniger darauf fokussiert die Regelleistungsbemessung zu verändern, als vielmehr einzelne Anlagentypen in den Regelleistungsmarkt zu integrieren [Spe11], [Klo07], [Bur11]. Ziel der Simulationen waren hauptsächlich die Veränderung von Regelleistungsmengen und -preisen sowie deren Abrufwahrscheinlichkeit. So gibt es unter anderem an der TU Chemnitz Arbeiten, die sich mit der stochastischen Modellierung des Minutenreserveabrufs und dessen Vorhersage beschäftigen, insbesondere zur Bereitstellung positiver Minutenreserve durch dezentrale Klein-KWK-Anlagen. [Kur09] hat die Minutenreserveabrufe der Jahre 2006 und 2007 analysiert und darauf aufbauend die Charakteristik der Inanspruchnahme positiver Minutenreserve als zusammengesetzten Poisson-Prozess modelliert. Dieser Ansatz beruht auf gewissen Annahmen, wie einer Tageszeitunabhängigkeit oder einer log-Normalverteilung der Nachfrage. Desweiteren ist ein Poisson-Prozess nur vom Erwartungswert und der Varianz der Einzelzeitreihe abhängig, was für die wirtschaftliche Bemessung einer KWK-Anlage vollkommend ausreichend ist, für die Zuverlässigkeit eines Versorgungssystems jedoch unzureichend ist.

Neben den Arbeiten zur Regelleistungsbereitstellung durch einzelne Technologien, gibt es ebenfalls bereits verwandte Arbeiten, die sich mit der Umgestaltung des gesamten Systems der Regelleistungsvorhaltung beschäftigen. So untersucht die TU Dortmund aktuell die Ausgestaltung eines adaptiven Regelleistungsmarktes mit Kapazitätsreserve [KS12]. Ziel dieses Forschungsvorhabens ist ein erweiterter Ansatz, der die flexible Minutenreserveausschreibung mit den Grundprinzipien eines Kapazitätsmarktes verbindet. Ein weiterer Schwerpunkt im Zuge dieser Arbeit ist die Berechnung der Entwicklung der RL-Mengen für ausgewählte Zukunftsszenarien. So errechneten die Forscher beispielsweise einen Anstieg des Bedarfs an positiver MRL für das Jahr 2040 im Vergleich zum Jahr 2008 um das 1,8-fache. Für die Berechnungen wurde dabei ebenfalls das faltungsbasierte Verfahren nach Graf-Haubrich zugrunde gelegt.

Diese Art der Bemessung entspricht dem „Value at Risk“ (VaR) Verfahren, und ist eine statistische Analyse über einen langen Zeitraum, in der der tagesaktuelle Systemzustand keinerlei Einfluss auf die Bemessung hat. So wird zu jedem Zeitpunkt die gleiche Menge an Regelleistung vorgehalten, obwohl diese für einen Zeitraum von einem Jahr berechnet wurde. Holtinen (2012) und dena (2014) schlagen daher eine dynamische bzw. adaptive Regelleistungsbemessung vor. Und auch die aktuelle DESIRE Studie [Buc14] der Universität Duisburg zusammen mit BET und Trianel untersucht die Weiterentwicklung der aktuellen Bemessungspraxis in Form einer „situativen Bemessung“. Dabei erfolgt im Rahmen dieser Studie eine gesonderte Bemessung der einzelnen Ausschreibungszeitscheiben und insbesondere die Prognosefehler werden jeweils für einen Prognosehorizont von einer Stunde angesetzt. Auf diese Weise werden nur die Prognosefehler erfasst, die sich nicht am Intraday Markt ausgleichen lassen und damit mutmaßlich für den Bedarf an Regelleistung verantwortlich sind. Abbildung 2.38 zeigt das Prinzip der *situativen Faltung* der Wahrscheinlichkeitsfunktionen zu einer Gesamtwahrscheinlichkeitsdichte. Entsprechend den Prognosehorizonten und den gegebenen Defizitwahrscheinlichkeiten ergeben sich anschließend die vorzuhaltenden Regelleistungsmengen. Die Bemessung der GRL⁷⁹ erfolgt anschließend mit einem Sicherheitsniveau von 99,9971%⁸⁰. Für das Jahr 2011 hat die Studie einen RL-Bedarf von 4.739 MW (positiv) und 4.426 MW (negativ) errechnet. Zudem wurden die Bedarfe für das Ausbauszenario der dena [DEN10] für das Jahr 2020 berechnet; dazu wurde eine 47%-tige Verbesserung der Prognosegüten in Bezug auf Wind- und PV-Einspeisung unterstellt. Bei einem gewählten Defizitniveau von 0,0029 % ergäbe sich laut Studie ein Bedarf von 7.838 MW (po-

⁷⁸Abbildung aus [Buc14, Seite 105]

⁷⁹ eine vollständige Substituierbarkeit von SRL und MRL wird in der Studie vorausgesetzt

⁸⁰ Dies entspricht einem tolerierten Defizitzeitraum von 15 Minuten pro Jahr, jeweils für jede Zeitscheibe.

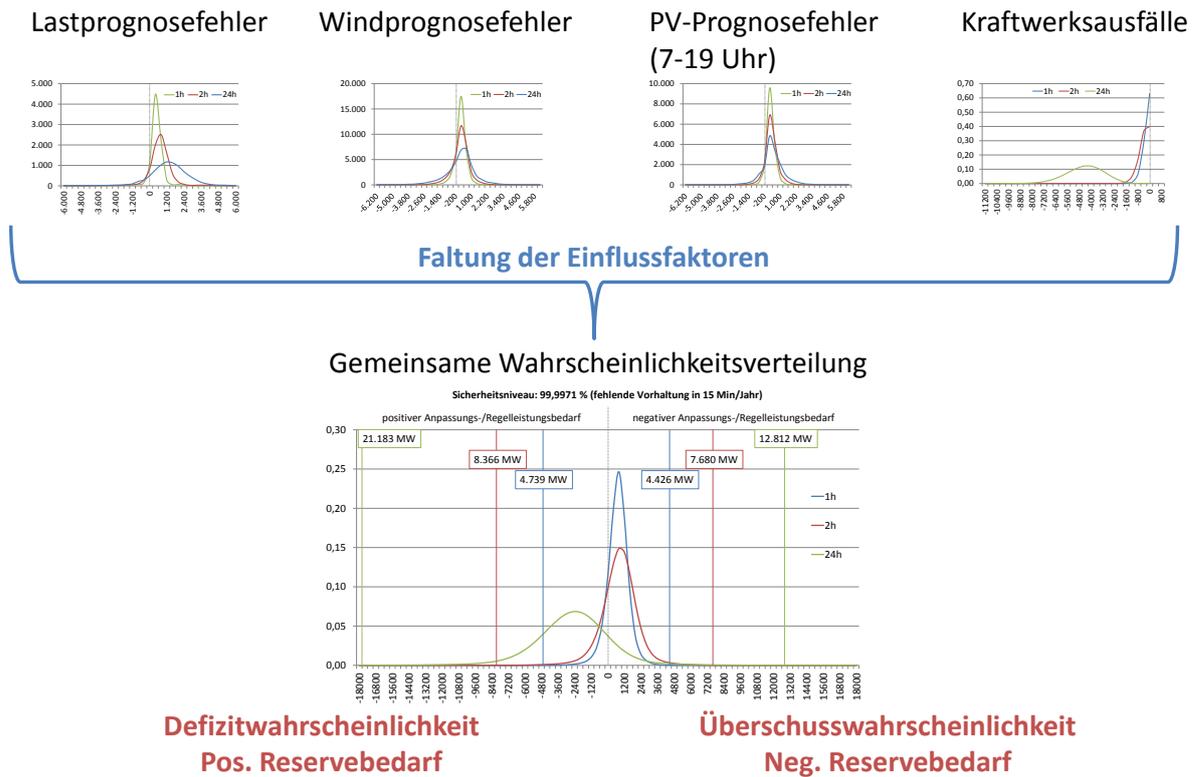


Abbildung 2.38: Berchnung der Gesamtwahrscheinlichkeitsverteilung⁷⁸

sitiv) und 5.699 MW (negativ). Das wäre ein relativer Anstieg um das 1,65-fache bzw. 1,29-fache und würde somit den Ergebnissen der Universität Dortmund [KSWR10] entsprechen. Die dynamischen Anpassungen der Einflussgrößen basieren in der Studie ausschließlich auf den zeitlichen Merkmalen, etwaige Prognosen über erwartete EE-Einspeisungen bleiben unberücksichtigt. Im Folgenden Kapitel wird daher ein kurzer Überblick über mögliche Alternativmethoden zur Prognose des Regelsaldos und damit der Bemessung der RL-Mengen gegeben.

2.3.3 RL-Bemessung als Prognosemodell

Aus mathematischer Sicht lässt sich ein Prognoseprozess auf folgende Weise beschreiben [Mer11]:

Prognoseprozess

Gegeben ein Zufallsprozess mit Realisationen $\{y_1, \dots, y_T\} \subset \mathbb{R}^d$ ist es das Ziel der Prognose für einen Prognosehorizont $\tau \in \mathbb{N}$ einen Wert $y_{t+\tau} \in \mathbb{R}^d$ zu finden.

Jede Prognose hat damit einen sogenannten *Prognoseursprung* $t(t = 1, \dots, T)$, d.h. einen spezifischen Zeitpunkt, zu dem die Prognose erstellt wird und einen sogenannten *Zeitpunkt der Entscheidung* $t + \tau$; der Zeitraum zwischen diesen Werten wird *Prognosehorizont* τ genannt [Mer11]. Je nach Wahl des Prognosehorizontes unterscheidet man zwischen Kurz-, Mittel-, und Langzeitprognosen. Bis zu einem Tag im voraus sind Kurzzeitprognosen, Mittelprognosen sind zwischen einem Tag und

einem Jahr, während Langzeitprognosen einen Prognosehorizont über mehrere Jahre haben [PS13]. Das hier aufzustellende Prognosemodell fällt damit in den Bereich der Kurzfristprognose (engl. short-term forecasting (STF)) mit Prognosehorizonten zwischen einer Viertelstunde ($\tau = 1$) und einem Tag ($\tau = 96$)⁸¹. Ist dabei lediglich die Eintrittswahrscheinlichkeit eines Ereignisses Ziel der Prognose, entspricht dies einer Prognose (engl. prediction) im engeren Wortsinn, wird dagegen auch ein mit dem Ereignis verbundener Wert (Ausprägung) prognostiziert, spricht man im engeren Wortsinn von Vorhersage (engl. forecast) [Cro10]. In diesem Fall lassen sich anhand der prognostizierten Wahrscheinlichkeitsverteilung für zukünftige Ereignisse sowohl geeignete Punktschätzer als Prognosewert, sowie eine Abschätzung der Unsicherheit bezüglich des Prognosewertes extrahieren⁸².

In den aktuellen statistischen Bemessungsverfahren wird davon ausgegangen, dass die Systemungleichgewichte, bzw. die Zeitreihe des Regelsaldos einem Gaußprozess entspricht, der durch die Angaben eines Mittelwertes und einer Kovarianzfunktion charakterisiert ist, die über den Bemessungszeitraum als konstant angenommen werden können. Die Prognose des erwarteten zukünftigen Systemungleichgewichts bzw. der zum Ausgleich benötigten Regelleistungsmenge erfolgt daher analytisch in Form einer sogenannten *unbedingten* Prognose. Der *unbedingte* Erwartungswert des Regelsaldos entspricht somit dem univariaten (unbedingten) Mittel von y_t über die Zeit. Setzt man dabei eine gleiche Wahrscheinlichkeitsverteilung aller x_i voraus bzw. ist das T genügend groß gewählt, so ergibt sich nach dem „Gesetz der großen Zahlen“ der Mittelwert μ_y aller y_t über die Zeit als (Punkt-)Schätzung [Koc12]:

Unbedingte Prognose

$$\hat{y}_{t+\tau} = E(Y) = \sum_{i=1}^T y_i f(y_i) \approx \frac{1}{T} \sum_{i=1}^T y_i \approx \mu_{y,T} \quad (2.6)$$

Diese Normalitätsannahme ist abzulehnen, wenn die vorliegende Zeitreihe unregelmäßige Ausschläge aufweise, die von der Mehrzahl der Daten abweicht, bzw. wenn der Mittelwert und die Kovarianzen über die Zeit stark schwanken. In diesem Fall konnte in Kapitel 2 gezeigt werden, dass sowohl der Mittelwert als auch die Varianz über das Jahr sehr stark streuen. Geht man von der Zeit t als einzigem Einflussfaktor aus, d.h. unterstellt man, dass alle Informationen implizit in der Zielzeitreihe enthalten sind, ist die einfachste Form der (statischen) direkten univariaten Prognose die elementare Fortschreibung des aktuellen Wertes oder auch „Persistenz“.

Persistenz

$$\hat{y}_{t+1} = y_t \quad (2.7)$$

⁸¹ Dabei wird die Prognose des direkt folgenden Zeitschrittes ($\tau = 1$) auch als Einschrittprognose (engl. one-step forecast) bezeichnet, während man bei größeren Prognosehorizonten zwischen iterativen Einschrittprognosen und direkten Mehrschrittprognosen unterscheidet, je nachdem ob Realisationen vorangegangener Perioden berücksichtigt werden [Gra80]. In unserem Fall geschieht die Prognose jeweils als Einschrittprognose.

⁸² Im Weiteren wird der Begriff Prognose bzw. Prognosemodell verwendet auch wenn hier die Höhe des Regelzonensaldos vorhersagt werden soll und es sich daher genau genommen um eine Vorhersage und damit um ein Vorhersagemodell handelt.

Die Persistenz ist ein Sonderfall der *Autoregression*⁸³, bei der Realisationen einer Zeitreihe als lineare Kombinationen früherer Realisationen modelliert werden. Beim AR(1)-Modell für den einstufigen Prognosehorizont hängt der nächste vorherzusagene Wert y_{t+1} lediglich vom Gegenwartswert y_t ab. Derartige Modelle werden auch *Markov-Modelle* genannt [Kur09]. In diesem Fall konnte jedoch eine phasenweise starke Autokorrelation gezeigt werden, so dass die Zeitreihe nicht „ohne Gedächtnis“ ist. Sind starke Ähnlichkeiten zu früheren Realisationen der Zeitreihe erkennbar spricht dies gegen eine Modellierung als Markov-Prozess.

Des Weiteren erschwert der recht unterschiedliche Verlauf der Autokorrelation die Festlegung auf eine *funktionale Hypothesenklasse* (zum Beispiel AR-Modelle) für den gesamten Datenraum. So wären im Fall einer Darstellung des Regelsaldos als Linearkombination vergangener Realisationen die Zeitpunkte dieser vergangenen Realisationen nicht für jeden Punkt im Datenraum gleich. Dies ist jedoch eine Grundannahme für die Hypothesenklasse der AR-Modelle. Vielmehr ist es sinnvoll, innerhalb der Zeitreihe nach wiederkehrenden Mustern bzw. Kurvenverläufen zu suchen unabhängig ihres Abstandes vom Prognoseursprung. Man geht dabei von der Hypothese aus, dass wenn sich zwei Muster, d.h. die Sequenzen der Zeitreihe, ähnlich sind, wird auch der Fortgang der Sequenzen ähnlich sein, bzw. ähnliche Systemzustände werden zu ähnlichen Systemungleichgewichten führen. In der Datenanalyse konnte gezeigt werden, dass diese Muster sich nicht ausschließlich aus zeitlichen Merkmalen herleiten lassen, sondern dass der Regelsaldo außer vom Zeitpunkt t von weiteren Einflussgrößen (zum Beispiel der EE-Einspeisung oder der aktuell nachgefragten Last) abhängt. Der Regelsaldo, bzw. der dahinter liegende Zufallsprozess hängt daher vom aktuellen Systemzustand \mathbf{x}_t ab, welcher sich aus beobachtbaren Merkmalsgrößen und weiteren Störgrößen, die die Ausprägungen des Saldos "verrauschen", zusammensetzt.

Das Ziel des Prognoseprozesses ist es, Aussagen über die Wahrscheinlichkeitsverteilung bzw. die zugrunde liegende Verteilungsfunktion des Regelsaldos bzw. der dahinter liegenden Zufallsvariable zu treffen. Setzt man nun einen Einfluss des aktuellen bzw. erwarteten Systemzustandes auf den Regelsaldo voraus, erhält man eine *bedingte* Prognose⁸⁴. Die bedingte Prognose ergibt sich mit $f(y_t|x)$ als jeweilige Wahrscheinlichkeit der Ausprägung y_t unter der Voraussetzung des Systemzustandes x wie folgt [Dra14]:

Bedingte Prognose

$$\hat{y}_{t+\tau} = E(Y|X = x) = \sum_{i=1}^T y_i f(y_i|x) \quad (2.8)$$

Aufgabe der bedingten Prognose ist es, die bedingte Wahrscheinlichkeitsfunktion $f(\cdot)$ geeignet zu schätzen, so dass der vorhergesagte erwartete Wert $\hat{y}_{t+\tau}$ möglichst nah am realisierten Wert $y_{t+\tau}$ liegt⁸⁵. Aus dieser geschätzten Verteilung können anschließend ein geeigneter Punktschätzer als Prognosewert sowie eine Abschätzung der Unsicherheit auf den Prognosewert extrahiert werden. Diese Schätzung ist jedoch mit zunehmender Dimension von d schwieriger/ungenauer da das Auftreten gleicher Realisationen $x_t \in \mathbb{R}^d$ immer seltener wird, und der hoch-dimensionale Datenraum selbst

⁸³ Diese werden als AR-Modelle oder auch Box-Jenkins-Modelle bezeichnet.

⁸⁴ Kritiker gehen davon aus, dass jede Prognose bedingt ist, da sie bestimmten Annahmen unterliegt.

⁸⁵ Der Prognosefehler der bedingten Verteilung ist dementsprechend ein Maß das ausdrückt, wie sehr die geschätzte Verteilung von der „richtigen“ Verteilung abweicht.

bei zunehmender Datenmenge immer „spärlicher“ besetzt ist. Dies führt zum sogenannten „Fluch der Dimensionen“ [Bel61]. Dabei sind die Systemzustände $\mathbf{x}_t = (x_{t,1}, \dots, x_{t,d})' \in \mathbb{R}^d$ ebenfalls Realisationen von Zufallsprozessen. Um Aussagen über den Erwartungswert von Y treffen zu können, muss daher der Erwartungswert der auf X bedingten Erwartungswerte gebildet werden. Nach dem Gesetz der integrierten Erwartungen⁸⁶ folgt damit (über alle x) [Dra14]:

Bedingte Erwartung der Zielvariablen

$$E(Y) = E_x[E(Y|X)] \quad (2.9)$$

Diese bedingte Erwartung (engl. conditional mean) wird auch Regressionsfunktion $h(\cdot)$ von Y gegen X genannt. Unter allen Funktionen ist nun die Funktion $h^*(\cdot)$ gesucht, die den Prognosefehler $err(h(\cdot))$ bzw. den Erwartungswert der Kosten- oder auch Verlustfunktion (engl. Lossfunction) $\|\cdot\|$ über alle y_t minimiert:

Verlustfunktion der Prognose

$$err(h(\cdot)) = E\{\|Y - E(Y)\|\} = E\{\|Y - h(X)\|\} = E\left\{\sum_{i=1}^T L(y_i, h(x_i))\right\} \Rightarrow \min_{h(\cdot)} \quad (2.10)$$

Bekannte Verlustfunktionen im Bereich der Regression sind zum Beispiel die sogenannte „L1-Norm“ $L_1(y_i, h(x_i)) = |y_i - h(x_i)|$ oder die quadratische Lossfunktion die sogenannte „L2-Norm“ $L_2(y_i, h(x_i)) = (|y_i - h(x_i)|)^2$ ⁸⁷.

Der Erwartungswert des Prognosefehlers ergibt sich damit als mittlerer absoluter Fehler (engl. mean absolute error (MAE)) bzw. als mittlerer quadratischer Fehler (engl. mean squared error (MSE)). Die quadratische Verlustfunktion ist dabei gleichbedeutend mit dem zweiten Moment der Wahrscheinlichkeitsfunktion, d.h. der Varianz. Dabei ist die Gesamtvarianz einer Verteilung gleichbedeutend mit dem totalen Fehler vom Mittelwert. Es gilt: $SST = SSR + SSE$ ⁸⁸. Das heißt der totale Fehler ist die Summe aus dem durch die Regression erklärten Fehler (SSR) und des unerklärten Fehlers bzw. der Varianz der Residuen (SSE). Die Regression erklärt somit einen Teil der Variationen bzw. Volatilität von y_t ⁸⁹[Ley06]. Die *Konfidenz* ist die bedingte Wahrscheinlichkeit und sollte immer höher sein, als die unbedingte Wahrscheinlichkeit $P(Y|X) \gg P(Y)$ [Ley06].

Hat das Modell einen Erklärungswert, so muss die bedingte Varianz kleiner sein, als die unbedingte Varianz und es folgt $Var(y_t) > Var(y_t|x_t) = E(\epsilon_t^2)$ [Ley06]. Es verbleibt die erwartete Varianz

⁸⁶ Das Gesetz der iterierten Erwartungen ist „ein Spezialfall eines allgemeineren Prinzips, nach dem bei mehrfacher Anwendung der bedingten Erwartung die Erwartung mit der geringsten Information dominiert. Die unbedingte Erwartung besitzt in dieser Interpretation die geringste Information“ [Kun08].

⁸⁷ Eine Norm $\|\cdot\|$ bildet ein mathematisches Objekt, hier das Vektorenpaar $(y_i, h(x_i))$, auf einen skalaren Wert ab.

⁸⁸ SST: sum of squares total; SSR: sum of squares from regression; SSE: sum of squares error

⁸⁹ Dieser Anteil an erklärter Varianz wird mit dem sogenannten Bestimmtheitsmaß R^2 angegeben. Dieser ist definiert als der Quotient aus der Summe der Abweichungsquadrate im geschätzten Modell (SSR) und der Summe der Abweichungsquadrate in der beobachteten Zeitreihe (SST). Idealerweise bleibt nur die unerklärte Varianz der Residuen.

der Regressionsfunktion bzw. die erwartete Quadratsumme der Residuen. Dabei erhält man je nach Art des funktionalen Zusammenhangs entweder sogenannte *parametrische* oder *nicht parametrische* Modelle.

Unbedingte Varianz

$$\text{Var}(y_t) \equiv \sigma_t^2 = E([y_t - E(y_t)]^2) \quad (2.11)$$

mit $E(y_t) = \mu_t$ und $f(\cdot)$ als Wahrscheinlichkeitsfunktion folgt für diskrete Zeitreihen

$$\sigma_t^2 = \sum_i^T (y_i - \mu_t)^2 f(y_i) \quad (2.12)$$

Im Falle der Information zum Zeitpunkt t ergibt sich die

Bedingte Varianz

$$\text{Var}(y_t|x_t) \equiv \sigma_t^2 = E([y_t - E(y_t|x_t)]^2|x_t) = E(\epsilon_t^2|x_t) = E(\epsilon_t^2) \quad (2.13)$$

mit ϵ_t als Residuum der Regressionsfunktion⁹⁰.

Parametrische Modelle bilden den statistischen Prozess auf ein mathematisches Zeitreihenmodell ab. Dabei unterscheidet man zwischen *univariaten* und *multiplen/multivariaten* Modellen. Ein Beispiel für einen *univariates* Modell ist der zuvor erwähnt Autoregressive Prozess, der die Zeitreihe auf eine lineare Kombination früherer Realisationen abbildet. Die sogenannte „direkte“ oder „autoregressive“ Prognose zukünftiger Realisationen erfolgt daraufhin ausschließlich aus Werten derselben Variablen aus der Vergangenheit heraus⁹¹. Im Bezug auf die Regelleistung würde dies bedeuten, dass alle Informationen über das Systemungleichgewicht implizit im Wert des Regelzonensaldos enthalten sind und eine Vorhersage zukünftiger Systemungleichgewichte anhand vergangener Zeitschritte dieser Zeitreihe realisiert werden kann. Im Gegensatz dazu gehen die *multiplen* Modelle davon aus, dass auch andere Faktoren/Prädiktoren (unabhängige Variablen) einen Einfluss auf die Realisationen der Zielvariablen (engl. response variable) haben. Bei der „indirekten“ oder „regressiven“ Prognose wird dieser Wirkungszusammenhang zwischen den verschiedenen Prädiktoren (engl. predictor) in die Prognose einbezogen. In diesem Fall ist die Prognose Bestandteil einer *multiplen Regression*. Der Prognoseprozess unterteilt sich somit in die Regressionsanalyse im engeren Sinne, d.h. die Ursache-Wirkungsanalyse zwischen den Prädiktoren und der Zielvariablen und der Anwendung dieser Erkenntnisse für die Prognose zukünftiger Realisationen der Zielvariablen in Abhängigkeit der Prädiktoren [Cro10]. Die im Zeitreihenmodell enthaltenen Parameter θ der Regressionsfunktion $h(\cdot)$ werden durch ein Schätzverfahren mit Hilfe der gewählten Verlustfunktion optimiert. Dabei wird die Parameterschätzung auf der gesamten Zeitreihe durchgeführt; zum Beispiel mit dem Verfahren der kleinsten Quadrate (lineare Regression) oder dem Maximum-Likelihood-Schätzer (Entscheidung nach Bayes).

⁹⁰Zur genauen Herleitung der Formeln siehe zum Beispiel [Koc12].

⁹¹ Diese Modelle werden auch Zeitreihenprognose oder Entwicklungsprognose genannt [Cro10].

Die Prognose, d.h. der erwartete Punktschätzer der Zielvariablen $\hat{y}_{t+\tau}$ erfolgt, indem die optimierte Funktion auf den Systemzustand x_t angewendet wird [KS09]:

Parametrische Prognose

$$\hat{y}_{t+\tau} = h(\mathbf{x}_t; \theta^*) \quad (2.14)$$

Diese Verfahren gehen davon aus, dass die gesamte Zeitreihe einer Verteilung F mit einer Dichte f entstammt. Dabei unterstellt man die Zugehörigkeit zu einer bestimmten parametrisierten Klasse von Verteilungsfunktionen. Das aktuelle RL-Bemessungsverfahren stellt eine derartige parametrische Prognose dar, indem Verteilungen für die einzelnen Einflussfaktoren vorgegeben werden, deren Parameter empirisch für den gesamten Datenraum hergeleitet werden.

Im Gegensatz dazu wird der funktionale Zusammenhang bei **nicht parametrischen Verfahren** nicht vorgegeben sondern leitet sich weitestgehend aus den Daten ab [HLC07]. Das nicht parametrische Modell ist daher keine Funktion eines einzelnen Merkmalsvektors \mathbf{x}_t sondern eine Funktion auf der Datenmenge $\mathbf{x}_i (i = 1, \dots, T)$. Eine Prognose erfolgt dementsprechend, indem das so abgeleitete Modell $g(\cdot)$ auf den gesamten Daten angewendet wird [KS09]. Daher bezeichnet man diese Verfahren auch als instanzbasiert (engl. instance-based).

Nicht parametrische Prognose

$$\hat{y}_{t+\tau} = \sum_{i=1}^T y_i g(\mathbf{x}_i; \mathbf{x}_t) \quad (2.15)$$

Dieses Vorgehen führt jedoch zu einer höheren Komplexität, die mit einem entsprechend höherem Rechenaufwand verbunden ist. Dieser liegt bei $\mathcal{O}(T)$, weil für jede Prognose eine erneute Berechnung zwischen dem angefragten Datenvektor (engl. query vector) \mathbf{x}_t und den im Datensatz vorhandenen T Vektoren $\mathbf{x}_i (i = 1, \dots, T)$ erfolgt. Daher haben nicht parametrische Verfahren ihren Erfolg auch dem rasanten Fortschritt in der Computertechnologie zu verdanken, da es ohne die heutigen Rechengeschwindigkeiten nur schwer möglich wäre, komplexe Zusammenhänge nur anhand von Datenauswertungen zu erkennen [Ber08]. Nicht parametrische Prognosemodelle lassen sich daher auch dem Themengebiet der *Künstlichen Intelligenz* (KI) (engl. computational intelligence CI) im Bereich der Informatik zuordnen. So können Prognoseaufgaben auch als Probleme des „maschinellen Lernens“ aufgefasst werden, wobei aus vorhandenen Daten auf einen möglichen nichtlinearen Zusammenhang zwischen den Merkmalen (engl. feature) $x_{t,i}$ auf die Zielvariable (engl. label) y_t geschlossen wird [Alp08]. Abbildung 2.39 zeigt einen Überblick über bekannte Beispielmodelle, die sich zur Prognose einsetzen lassen mit ihrer Einteilung in die zuvor eingeführten Kategorien.

Nicht parametrische Verfahren eignen sich für Zeitreihen, deren Verläufe weder Trends noch deutliche Saisonfiguren aufweisen [Mic92]. Insbesondere im ökonomischen und ökologischen Systemen mit komplexen Abläufen ist eine parametrische Modellierung häufig nicht geeignet die Eigenheiten der Systeme wiederzugeben [Mic92]. So ist der Fehler, den man bei einer fälschlich angenommenen Normalverteilung macht größer, als wenn man nicht parametrische Verfahren einsetzt, obwohl die Daten normalverteilt sind [MLR11]. Voraussetzung ist jedoch eine genügend große Anzahl Daten.

Vorgehen	(Zufalls-) prozesse	Funktionaler Zusammenhang	Beispielmodelle	
statisch	univariat/ multivariat	parametrisch	VaR	Mathematische Modellierung
statisch	univariat	parametrisch	Persistenz Einfache Lineare Regression	
statisch	multivariat	parametrisch	Multiple lineare Regression Additive/Multipl. Zeitreihenanalyse	
dynamisch	univariat	parametrisch	Autoregression	
dynamisch	univariat/ multivariat	parametrisch	Kernbasierte lineare Regression ARMA (autoregressive moving average)	
adaptiv	univariat/ multivariat	nicht parametrisch	Kernbasierte Regression k-nächste Nachbarn (KNN) Entscheidungsbäume	Maschinelles Lernen
adaptiv	univariat/ multivariat	parametrisch	Künstliche Neuronale Netze	
adaptiv	univariat/ multivariat	nicht parametrisch	Gradient Boosting Trees (GBT) Random Forest Support Vektor Machines MARS (Multivar. Adapt.Regress. Splines)	

Abbildung 2.39: Prognosemodelle

Daher findet man im Energiekontext bereits zahlreiche Prognosemodelle auf Basis nicht parametrischer Verfahren des maschinellen Lernens. Einen Überblick über die Anwendung von Maschinellen Lernverfahren in der Lastprognose bieten Hemachandra & Satyanarayana 2013 [HS13]; Dudek 2010 [Dud10]]. Bei der Lastprognose werden hauptsächlich Neuronale Netze, Support Vector Machines oder Expertensysteme verwendet [HMNP09], [IEE04], [SB13]. Für die Prognose der EE-Einspeisung werden ebenfalls bereits erfolgreich KI-Methoden eingesetzt [PS13], [MA14], [FAC14]. Aufgrund der Komplexität der Ursache-Wirkungs-Zusammenhänge werden für das zu entwickelnde Prognosemodell daher im Folgenden ebenfalls nicht parametrische Methoden des maschinellen Lernens eingesetzt.

2.4 Zusammenfassung und Diskussion

Im vorangegangenen Kapitel wurde zunächst der Anwendungskontext der Regelleistungsvorhaltung vorgestellt. Dazu wurde sowohl auf die technischen, wirtschaftlichen und politischen Rahmenbedingungen genauer eingegangen. Anschließend wurde ich einer Datenanalyse der Jahre 2011 bis 2013 der Abruf und die Charakteristik der Regelleistung genauer untersucht. Abschließend wurden beide Ergebnisse gegenübergestellt. Es konnte gezeigt werden, dass das aktuelle Bemessungskonzept die aktuellen Randbedingungen für den Bedarf an Regelleistung nur unzureichend berücksichtigt. Dadurch kommt es aktuell zu Ineffizienzen. Daraufhin wurde ein Überblick über den aktuellen Stand der Forschung auf dem Gebiet der Regelleistungsbemessung gegeben.

Die vorgestellten Bemessungskonzepte lassen sich in Bezug auf die eigene Datenanalyse wie folgt bewerten:

- Brückel (Monte Carlo Simulation)
Das Verfahren erlaubt eine getrennte Betrachtung der einzelnen Regelleistungsmengen, erfolgt jedoch trotzdem auf der gesamten Datenmenge und lässt keine tägliche Dimensionierung zu.
- Kurscheit (Poisson Prozess)
Das Verfahren simuliert „nur“ den Abruf positiver Minutenreserve. Für die Prognose künftiger Systemungleichgewichte ist dieses Verfahren nicht ausreichend.
- Kays (analytisch faltungsbasiert)
Das Verfahren untersucht in erster Linie die Entwicklung der Regelleistung für große Prognosehorizonte von mehreren Jahren. Eine tägliche Dimensionierung ist mit diesem Verfahren nicht möglich. So werden zum Beispiel nicht die prognostizierten Windeinspeisemengen sondern die prognostizierten installierten Windleistungen in die Simulation aufgenommen.
- DESIRE (faltungsbaisert)
Das Verfahren erweitert den faltungsbasierten Ansatz zu einem situativen faltungsbasierten Modell, bei dem die Bemessung für die jeweiligen Ausschreibungs-Zeitsscheiben getrennt vorgenommen wird. Des Weiteren werden für die Prognose der EE-Einspeisung die 1-h-Prognosen verwendet. Dieses Verfahren nimmt jedoch nur die Tageszeit als Hauptmerkmal zur Einschränkung der Varianz des Regelsaldos. Es ist daher zu untersuchen, ob eine Berücksichtigung weiterer Merkmale eine weitere Einschränkung der Varianz ermöglicht.

Im Anschluss an die Vorstellung aktueller Forschungsarbeiten auf dem Gebiet der Regelleistung wurde allgemein ein Überblick über mögliche Prognosemodelle gegeben. Diese Modelle wurden abschließend nach den zuvor eingeführten Merkmalen kategorisiert. Für die Regelleistungsbemessung als komplexen Prozess konnten nicht parametrische Verfahren auf Basis maschineller Lernverfahren als bester Lösungsansatz identifiziert werden. Diese Verfahren werden in der Energiewirtschaft bereits seit Jahren erfolgreich zur Einspeiseprognose erneuerbarer Energiequellen sowie in der Lastprognose eingesetzt.

3 Modellbildung

Im folgenden Kapitel wird das entwickelte dynamische Prognosemodell vorgestellt. Dazu werden zunächst kurz die wesentlichen Begriffe des maschinellen Lernens (ML) eingeführt bevor anschließend die einzelnen Prozessschritte des Vorgehensmodells für die Erstellung eines Prognosemodells auf Basis des ML näher erläutert werden.

3.1 Grundlagen dynamische Prognosemodelle

3.1.1 Prognose als überwachtetes Lernen

Während statistische Methoden davon ausgehen, dass die Daten eine innere Struktur haben, die sich durch eine mathematische Beziehung zwischen In- und Output formulieren lässt, stellen Methoden der künstlichen Intelligenz nur schwache Anforderungen an den funktionalen Zusammenhang zwischen den zuletzt realisierten und den zukünftigen Werten [Dud10]. Es wird lediglich unterstellt, dass gleiche Eingaben zu gleichen Ausgaben führen. Dies hat den Vorteil, dass sie auch mit Nichtlinearitäten umgehen können. Prognosen lassen sich somit als Aufgabe des überwachten Lernens betrachten, indem für neue unbekannte Systemzustände x_t das passende Label y_t – in Bezug auf die Regelleistungsbemessung das erwartete Systemungleichgewicht (Regelsaldo) – vorhergesagt werden soll, bzw. die bedingte Verteilung. Entsprechend dem „Postulat des Induktiven Lernens“ [ST14] werden dazu die bekannten Merkmal-Zielvariable-Paare $(\mathbf{x}_i, y_{i+\tau})$ gelernt, um anschließend auf die Realisation von $y_{t+\tau}$ anhand von unbekanntem \mathbf{x}_t schließen zu können.

Postulat des Induktiven Lernens:

WENN Hypothese h die Zielfunktion auf genügend großer Lernstichprobe approximiert
DANN approximiert Hypothese h die Zielfunktion auf bisher unbekanntem Daten

Abbildung 3.1 zeigt einen Überblick über die unterschiedlichen Prozesse der mathematisch parametrischen Verfahren auf der rechten Seite und den datengetriebenen nicht parametrischen Verfahren des maschinellen Lernens auf der linken Seite. Bei der mathematischen Modellierung erfolgt grundsätzlich eine theoriegeleitete (a priori) Entwicklung eines Modells, das aus der Analyse des Ursache-Wirkungs-Zusammenhangs zwischen den Merkmalen und der Zielgröße hervorgeht. Die anhand dieser Modelle simulierten Prognosewerte werden anschließend mit den realisierten Zeitreihen verglichen und die Modellparameter entsprechend der Zielfunktion optimiert.

Bei den nicht parametrischen Modellen erfolgt die Modellbildung direkt auf der bereits realisierten vorhandenen Datenmenge. Die Optimierung der Modellparameter wird hier durch *Maschinelles Lernen* erreicht, indem ein bestimmtes Leistungskriterium anhand von Beispieldaten oder Erfahrungswerten aus der Vergangenheit iterativ verbessert wird [Alp08]. Dies wird durch eine Trennung der Datenmenge ermöglicht; so wird das Modell auf der Trainingsmenge gelernt und anschließend auf der Validierungsmenge evaluiert. Durch eine wiederholte Trennung der Datenmenge, der sogenannten Kreuzvalidierung (engl. cross validation CV) wird dabei eine Überanpassung (engl. overfitting) auf einem zu geringen bzw. speziellen Datensatz verhindert. Die Kreuzvalidierung bietet somit die

Möglichkeit des Testens auf Generalisierungsfähigkeit unter Einhaltung einer Komplexitätsklasse. In beiden Verfahren werden demnach empirische Beobachtungen in ein Modell abgebildet, indem aus diesen Beispieldaten induktiv auf die Grundgesamtheit geschlossen wird. Daher liegt der Unterschied beider Verfahren weniger in der Art des statistischen Schließens sondern vielmehr auf dem funktionalen Zusammenhang, der entweder über die Einflussgrößen oder über die Datenmenge modelliert wird. Eine Ableitung von Ursache-Wirkungs-Zusammenhängen zwischen den Einflussgrößen und der Zielvariablen erfolgt bei den nicht parametrischen Verfahren nicht vor der eigentlichen Modellierung sondern iterativ innerhalb der Modelle.

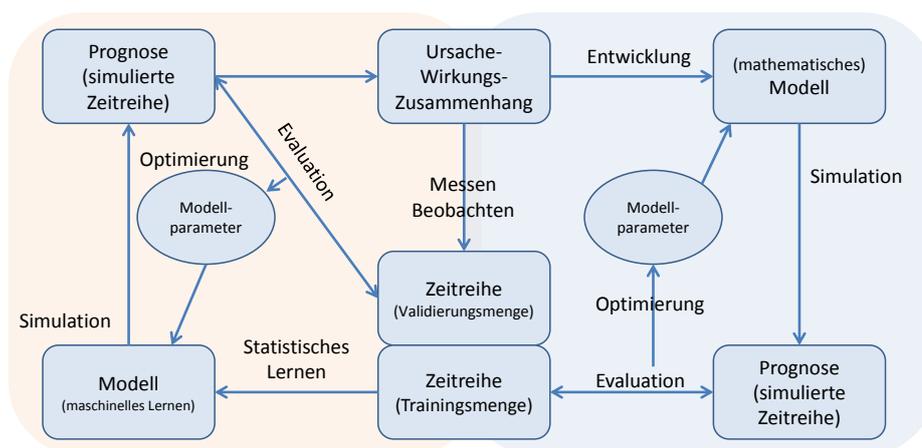


Abbildung 3.1: Deduktive und Induktive Prognosemodelle¹

Dabei liegen die Ursprünge des maschinellen Lernens nicht in der Zeitreihenprognose, sondern in der sogenannten "Klassifikation", d.h. dem Zuordnen eines Datenpunktes (Systemzustandes) anhand bestimmter Merkmale zu einer sogenannten "Klasse". Dies geschieht indem das Modell die Datenmenge in Unterbereiche „möglichst“ gleicher Klassenlabel einteilt². Diese Aufteilung erfolgt entweder linear (z.B. bei einfachen *Neuronalen Netzen* oder *Entscheidungsbäumen*) oder nichtlinear (z.B. bei *Support Vector Maschinen*³). Diese Modelle lassen sich nun auf die Regression bzw. Zeitreihenanalyse übertragen, indem statt einer Optimierung der „Klassenhomogenität“ innerhalb der Gruppen, die Intergruppenvarianz minimiert und gleichzeitig die Intragruppenvarianz maximiert wird⁴. Die Prognose erfolgt anschließend über die Zuordnung des Systemzustandes x_t in einen Unterbereich und der Punktschätzer entspricht dem bedingten Erwartungswert der entsprechenden Unterbereichsmenge. Diese Zuordnung der Datenpunkte in die einzelnen Unterbereiche erfolgt z.B. anhand einer Baumstruktur (Entscheidungsbäume), mit Hilfe sogenannter Stütz Vektoren (engl. support vector), mit deren Hilfe eine (d-1)-dimensionale Hyperebene aufgespannt werden kann und die damit den d-dimensionalen Datenraum unterteilen, oder mit Hilfe von Distanzmaßen.

Dazu werden im Unterschied zu den parametrischen Verfahren nicht einzelne fest vorgegebene Zeitreihenwerte parametrisiert, sondern es werden ähnliche Zeitreihenabschnitte auf der gesamten

¹Abbildung in Anlehnung an www.vwi.tu-dresden.de/treiber/statistik2/statistik_download/fohlen12.pdf

² Um eine Trennung zu ermöglichen wird eine Fehlertoleranz ϵ zugelassen.

³ Dazu wird der Datenraum in eine höhere Dimension abgebildet in der eine lineare Trennung möglich ist - sogenannter Kernel-Trick.

⁴ Bei bekannten Verteilungen spricht man in der Statistik in diesem Fall von sogenannter Diskriminanzanalyse.

Zeitreihe gesucht, bzw. ähnliche Zeitreihenwerte. Die Ähnlichkeit zweier Eingaben bzw. Datenpunkte wird durch sogenannte Ähnlichkeits- bzw. Unähnlichkeitsmaße (Distanzmaße) definiert. Die Prognose ergibt sich anschließend als gewichtete Summe der "ähnlichen" Beobachtungswerte. Die Auswahl dieser „ähnlichen“ Zeitreihenabschnitte bzw. die Unterscheidung zwischen zu berücksichtigenden Werten und nicht zu berücksichtigenden Werten erfolgt dabei entweder anhand eines Grenzwertes für den Abstand (z.B. Kerndichteschätzer) oder anhand eines Grenzwertes für die Anzahl zu berücksichtigender Werte (z.B. k-Nächste-Nachbarn). Während im ersten Fall alle Datenpunkte mit Hilfe von Kernfunktionen (engl. kernel function) $K_\theta(\mathbf{x}_i, \mathbf{x}_t)$ gewichtet werden, besteht bei den KNN die Möglichkeit entweder alle k Werte gleich zu gewichten (uniform) oder sie ebenfalls in Relation ihres Abstandes zum gesuchten Datenpunkt zu gewichten (distance). So erhalten Werte deren Abstand mit dem gesuchten Kurvenverlauf geringer ist (d.h. die sich mehr ähneln) ein höheres Gewicht, als solche die weiter entfernt liegen; das Gewicht entfernt liegender Punkte tendiert dabei gegen Null⁵. Diese Kernfunktionen zur Schätzung von Dichten wurden erstmals von Rosenblatt (1956) vorgestellt und später von Nadaraya/Watson (1964) weiterentwickelt⁶[And10].

Die nicht parametrischen „datengetriebenen“ Modelle sind daher adaptiv, d.h. sie passen sich dem aktuellen Systemzustand an, und erfüllen damit die Anforderungen, die an das Prognosemodell gestellt werden. Bei der Wahl eines geeigneten Modells besteht die Herausforderung in einem dreifachen Zielkonflikt, dem sogenannten Triple-Trade-Off [Die02], da die Wahl von drei Faktoren abhängt, die sich gegenseitig negativ bedingen:

- Komplexität der Hypothesenklasse
- Größe der Trainingsmenge
- Generalisierungsfehler auf unbekanntem Mustern

Zwar verbessert sich der Generalisierungsfehler auf unbekanntem Mustern mit einer Zunahme der Trainingsmenge, insbesondere was die induktive Verzerrung (Bias) des Vorhersagewertes anbetrifft, jedoch sind die beiden Größen nicht proportional, d.h. die Verbesserung des Generalisierungsfehlers ist umgekehrt proportional zur Größe der Trainingsmenge⁷. Der zweite Trade-Off existiert zwischen der Modellkomplexität und der Größe der Trainingsmenge; während eine Änderung der Trainingsmenge bei einer niedrigen Modellkomplexität nur einen geringen Einfluss hat, hat die Zunahme weiterer Trainingsamples bei komplexen Modellen unter Umständen eine Überanpassung des Modells und damit eine Verschlechterung des Generalisierungsfehlers zur Folge. So steigt die Varianz mit Zunahme der Komplexität, während der Bias sinkt (sogenanntes Varianz-Bias-Dilemma [HTF11]). Die Optimierung der Prognosemodelle konzentriert sich daher auf zwei wesentliche Aspekte; die Vorhersagegenauigkeit und die räumliche und zeitliche Komplexität, d.h. die Effizienz des Lern- und Inferenzalgorithmus [Alp08]. Dazu wird die Komplexität in die Funktion des erwarteten Fehlers aufgenommen, und man berechnet entsprechend den regularisierten empirischen Fehler, wobei die Komplexität des Modells durch den Regularisierungsterm λ „bestraft“ wird [Kra09], [HTF11].

$$E_{reg}(g, \lambda) = E_{emp}(g) + \lambda \|g\| \quad (3.1)$$

⁵ Ein Beispiel ist die kernbasierte lineare Regression, bei dem die aktuellsten Werte stärker gewichtet werden.

⁶ siehe Anhang

⁷ Das heißt eine Erweiterung einer kleinen Trainingsmenge hat einen größeren Effekt, als die Vergrößerung einer ohnehin schon genügend großen Trainingsmenge.

Die Komplexität einer Hypothesenklasse wird zum Beispiel in der sogenannten „VC Dimension“ (Vapnik-Chervonenkis-Dimension) gemessen [Va08]; sie beschreibt wie viele Muster durch ein Modell eindeutig in zwei Klassen getrennt werden können⁸. Im Fall der Entscheidungsbäume besteht die Hypothesenklasse z.B. aus Rechtecken, die den Merkmalsraum einschränken. Bei den KNN hat nun eine Zunahme der Komplexität, die in diesem Fall der Merkmalsdimension entspricht, aufgrund des „Fluchs der Dimensionen“ negative Auswirkungen auf die Performance des Modells. So erfordert die Zunahme weiterer Merkmale eine genügend große Trainingsdatenmenge, um ein Overfitting bzw. ein zu großes Bias zu vermeiden. Ist die Trainingsmenge ausreichend groß und die Merkmalsdimension ausreichend gering, so wird die Verzerrung bei einem k von eins gegen null konvergieren. Ziel der sogenannten *Modellselektion* ist daher die Auswahl des richtigen Grades an induktiver Verzerrung, die sich aus einer Einschränkung des Hypothesenraumes ergibt, wobei inkonsistente Hypothesen eliminiert werden sollten [Alp08]. So soll durch die Minimierung des Trainingsfehlers $E_{emp}(g)$ in Gleichung 3.1 eine möglichst genaue Abbildung der Verteilung erreicht werden, während gleichzeitig – durch eine Minimierung der Modellkomplexität – ein möglichst stabiles Prognosemodell mit einer geringeren Varianz erreicht werden soll. Dabei ist das Prinzip des Ockham’s Rasiermesser (engl. Ockham’s razor) zu beachten. Dieses besagt, dass wenn zwei gleichberechtigte Hypothesen zur Wahl stehen, die einfachere, in diesem Fall mit der geringeren Komplexität, zu wählen ist⁹.

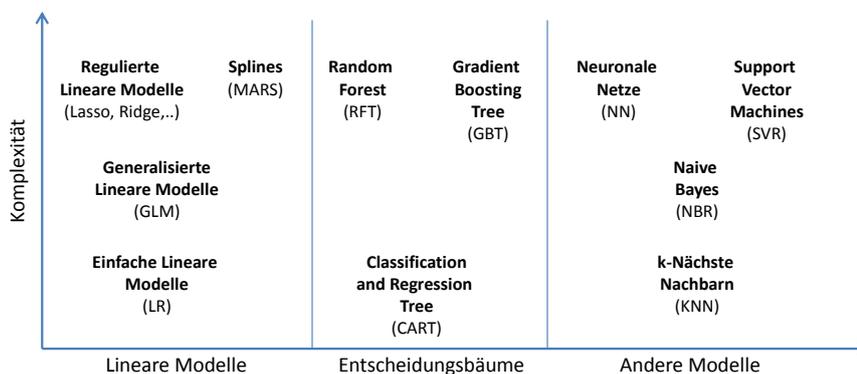


Abbildung 3.2: Prognosemodelle in Hinblick auf ihre Komplexität¹⁰

Abbildung 3.2 zeigt eine Auswahl parametrischer und nicht parametrischer Prognosemodelle in Abhängigkeit ihrer Komplexität. Aufgrund seiner guten Performance bei gleichzeitig geringer Komplexität wird das Modell der k-Nächsten-Nachbarn (KNN) [CH67] gewählt. Insbesondere ermöglicht es auch in großen Dimensionen gute Ergebnisse. Des Weiteren wird dieses Modell bereits erfolgreich in der Energiewirtschaft im Bereich der Prognose eingesetzt (unter anderem [PS13], [MA14], [FSM14], [WM14]). Ferner werden, aufgrund der impliziten Merkmalsgewichtung bzw. Ursache-Wirkungsanalyse, die Modelle der Gradient Boosting Trees (GBT) und des Random Forest (RFT) gewählt. Derartige Ensemble Methoden von Entscheidungsbäumen bieten die Möglichkeit einer quasi impliziten Variationsrechnung, indem durch die unterschiedliche Baumteilung verschiedene Szenarien bzw. Konstellationen der Einflussgrößen untersucht werden. Damit bieten sie eine wesentliche Weiterentwicklung gegenüber bereits vorhandenen Arbeiten; so stellten Kays/Schwippe [KSWR10] dar, dass „der Einfluss der Unsicherheit einzelner Dimensionierungsgrößen auf den Regelleistungs-

⁸ Dabei gibt es für N Datenpunkte 2^N verschiedene Möglichkeiten der binären $[0,1]$ Codierung.

⁹ Wolfgang Hübener: Ockham’s Razor not Mysterious. In: Archiv für Begriffsgeschichte. 27/1983. S. 73–92

¹⁰ Abbildung aus [http://caret.et.r-forge.r-project.org/modellList.html]

bedarf aufgrund zeitaufwendiger Variationsrechnungen aktuell schwierig ist und es daher schwer ist, Abhängigkeiten zwischen einzelnen Faktoren zu identifizieren“. Mit Hilfe der GBT ist es neben der Bewertung einzelner Einflussgrößen auf die Zielgröße ferner möglich, Wechselwirkungen zwischen den einzelnen Einflussgrößen aufzuzeigen. Ein weiterer Vorteil der Analyse mit Hilfe von Entscheidungsbäumen gegenüber der Korrelationsanalyse besteht darin, dass auch scheinbare „Ursache-Wirkungs-Zusammenhänge“ ausgeschlossen werden können. Die Korrelationsuntersuchung in Kapitel 2 diente daher im ersten Schritt des Auffindens der entscheidenden Parameter, die nun anschließend im zweiten Schritt mit den Gradient Boosting Trees genauer quantifiziert werden.

3.1.2 k-Nächste-Nachbarn (KNN)

Die k-Nächste-Nachbarn Methode wurde bereits in den 60er Jahren entwickelt, aufgrund des Bedarfs an umfangreichen Speicherplatz und Rechenaufwand gewann der Ansatz jedoch erst mit Beginn der computergestützten Datenverarbeitung an Popularität [Alp08]. KNN erzielt im Verhältnis seiner geringen Modellkomplexität erstaunliche Erfolge. So haben Cover und Hart 1967 [CH67, Seite 27] und Duda Hart Stork 2001 [DSH00] gezeigt, „dass für große Stichproben das Risiko des nächsten Nachbarn nie schlechter ist als das zweifache Bayes Risiko“. In dieser Hinsicht lässt sich behaupten, „dass die Hälfte der verfügbaren Information in einer unendlichen Sammlung von zu klassifizierenden Stichproben im nächsten Nachbarn enthalten sind“ [Alp08, Seite 179]. Dies liegt darin begründet, dass die Nachbarn ihrerseits komplexe nichtlineare Muster enthalten.[YDK06]. So kam die Grundidee der KNN Methode von Takens „Delay-Coordinate- Embedding-Theorem“ [Tak81],[YDK06]. In diesem Theorem wird die Grundidee beschrieben, dass die Komplexität eines Systems in seinen einzelnen Systemzuständen gespeichert werden kann. Und wenn die Anzahl der Systemzustandsbeobachtungen groß genug ist, kann für einen unbekanntem Systemzustand das Ergebnis vorhergesagt werden.

KNN

Gegeben ein Merkmalsvektor mit unbekanntem Label $x_q \in \mathbb{R}^d$ und eine Menge von N d -dimensionalen Vektoren $X = x_1, \dots, x_N$, dann ist es das Ziel des KNN Suchalgorithmus, die Untermenge von k Instanzen $N_k(x_q)$ aus X zu finden, so dass ihr Abstand zum gesuchten Merkmalsvektor minimal wird. Der Vorhersagewert kann dann wie folgt berechnet werden [Kra09]:

$$\hat{y}_q = g_{KNN}(x_q) = \frac{\sum_{i \in N_k(x_q)} w_i y_i}{\sum_{i \in N_k(x_q)} w_i} \quad (3.2)$$

w_i ist das Gewicht, das jedem Nachbarn x_i und damit auch dem zugehörigen Label y_i zugeordnet wird. Dies kann entweder mit einem gleichmäßigem Gewicht erfolgen, dem sog. *uniform kernel*, d.h. die Formel (3.2) vereinfacht sich in diesem Fall zu $g_{kNN}(x_q) = \frac{1}{k} \sum_1^k y_i$ oder in Relation zum Abstand. Das genaue Gewicht, das jedem einzelnen Nachbarn zugewiesen wird, hängt in diesem Fall von der implementierten Gewichtungsfunktion ab. Dies sind in der Regel Kernfunktionen, d.h. Funktionen mit dem Nachbarschaftsmaß als Funktionswert. Eine mögliche Kernfunktion ist der Gaußkernel, wobei die Glockenkurve ihren Mittelpunkt beim gesuchten Merkmalsvektor x_q hat, und dementspre-

chend mit wachsendem Abstand zum Mittelpunkt abnimmt. Eine andere Möglichkeit der lokalen Gewichtung ist die Multiplikation mit dem Kehrwert des quadrierten Abstandes, dies ist [Ert09]:

$$w_i = \frac{1}{d(\mathbf{x}, \mathbf{x}_q)^2} \quad (3.3)$$

Bei der lokalen Gewichtung geht man davon aus, dass es zu jedem gesuchten Merkmalsvektor eine Linearkombination seiner Nachbarn gibt, die das beste Ergebnis liefert. Untersuchungen haben gezeigt, dass dies nur für einen sehr kurzen Zeithorizont zutrifft, für längere Prognosehorizonte oder stark verrauschte Datenmengen liefert der uniforme Kernel bessere Ergebnisse [YDK06]. Abbildung 3.3 zeigt beispielhaft die Ergebnisse für KNN auf einer verrauschten Sinuskurve¹¹. In diesem Fall bietet der uniforme Kernel eine bessere Generalisierungsfähigkeit auf den Daten. Alternativ kann statt der Wahl einer festen Anzahl Nachbarn auch ein festes Nachbarschaftsmaß (z.B. radiale Basisfunktion) vorgegeben werden, wobei diese Basisfunktion jeden Datenpunkt auf die Werte (1,0) abbildet, je nachdem ob er innerhalb des gewählten Radius liegt – und damit zu den nächsten Nachbarn gehört – oder nicht.

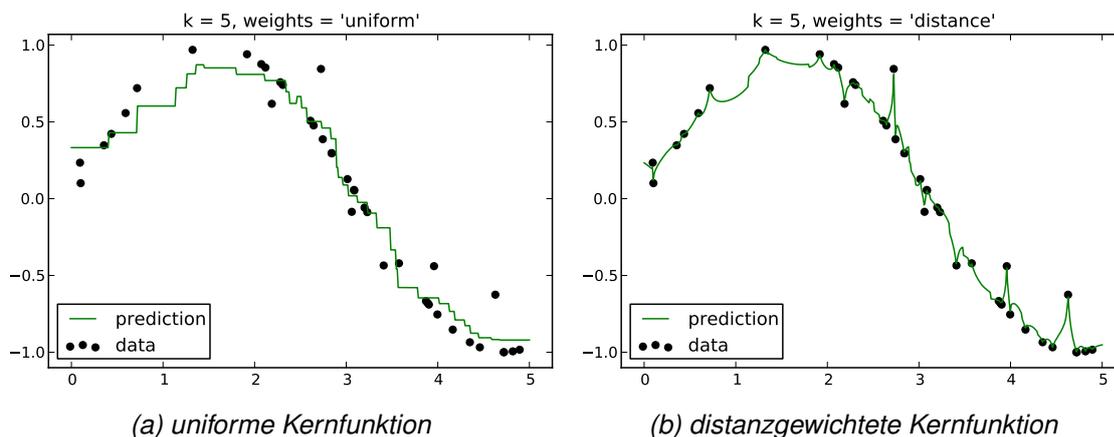


Abbildung 3.3: KNN mit unterschiedlichen Kernfunktionen

Die Wahl der radialen Basisfunktion hat dabei den Vorteil, dass man sich nicht explizit für eine optimale Anzahl von k entscheiden muss, sondern diese Anzahl sich adaptiv aus der Dichte der Samplemenge an der gesuchten Stelle im Datenraum ergibt. Insbesondere wenn die Samples nicht gleich verteilt sind, besteht bei der Wahl eines konstanten k ansonsten die Gefahr, dass auch entlegene Nachbarn ein zu großes Gewicht beigemessen würde [Alp08]. Allgemein ist bei der Wahl einer geeigneten Nachbarschaftsgröße immer das Bias-Varianz-Dilemma zu beachten. So führen große Nachbarschaften zu glatteren Werten; im Extremfall $k \rightarrow N$ entspricht der Vorhersagewert dem Mittelwert. Dieses ist jedoch mit einem erhöhtem Bias verbunden. Kleinere Nachbarschaften führen zwar zu einer geringeren Verzerrung – im Idealfall ist der Bias für ein k von eins gleich null – sie führen jedoch zu einer hohen Volatilität und sind daher weniger stabil. Die Performanz von KNN reagiert in der Folge sehr sensitiv auf die Änderung der Modellparameter, wie der Anzahl von Nachbarn k , der Gewichtsfunktion, des Prognosehorizontes bzw. der Dimension des Merkmalsvektors [YDK06].

¹¹ Beispiel aus sk-learn [<http://www.scikit-learn.org>]

Die vielleicht größte Schwäche von KNN liegt in der Tatsache, dass das Modell keine Möglichkeit bietet, einen Ursache-Wirkungs-Zusammenhang zwischen den Einflussgrößen und der Zielvariablen abzuleiten, was dazu führt, dass bei mehr als zwei Merkmalen praktisch auch keine grafische Darstellung der Abhängigkeiten mehr möglich ist [Ber08]. Dieser Nachteil wird in dieser Arbeit dadurch kompensiert, dass zwei weitere Modelle in Form von Ensembles aus Entscheidungsbäumen, zum einen der Gradient Boosting Tree und zum anderen der Random Forest, als zusätzliche Methoden eingesetzt werden.

3.1.3 Gradient Boosting Trees (GBT)

Während die Methode der KNN zu den sogenannten „faulen“ Lernern gehört (engl. lazy learners), weil die Berechnung des Modells erst mit der Eingabe des gesuchten Merkmalsvektors erfolgt, gehören Entscheidungsbäume zu den „fleißigen“ Lernern (engl. eager learner), bei denen das Modell bereits im Vorfeld auf der Trainingsmenge gelernt wird [HTF11]. Eine Vorhersage erfolgt anschließend auf Basis abgeleiteter Entscheidungsregeln, die in hierarchischer Struktur auf den Merkmalsvektor angewendet werden. Daher gehören Entscheidungsbäume zu den hierarchischen Modellen des überwachten Lernens. Jeder Entscheidungsbaum besteht aus internen Entscheidungsknoten und terminalen Blättern wobei Testfunktionen $f_m(x)$ mit diskreten Ergebnissen als Label für die Verzweigung genutzt werden. Die binäre Aufteilung erfolgt mit Hilfe von Schwellwerten. Jede $f_m(x)$ definiert somit eine Diskriminante im d -dimensionalen Eingaberaum, wodurch dieser in kleinere Regionen zerlegt wird. Beim multivariaten Baume ist jeder Knoten definiert ist als [Alp08]:

$$f_m(x) : w_m^T x + w_{m0} > 0 \quad (3.4)$$

Im multivariaten Fall gibt es damit d mögliche Ausrichtungen (w_m) und $N_m - 1$ mögliche Schwellwerte ($-w_{m0}$), wodurch es $2^d \binom{N_m}{d}$ mögliche Hyperebenen gibt [MKS94]. Der Schwellwert definiert die zulässige Varianz, d.h. idealerweise ist der Schwellwert Null und damit die Response Variable im Blatt – der Vorhersagewert – eine Konstante. Für Bäume wird somit nicht das Nachbarschaftsmaß angepasst, sondern der einzustellende Parameter ist das Maß der erlaubten „Unreinheit“ innerhalb des Unterraums, bzw. finalen Blattes.

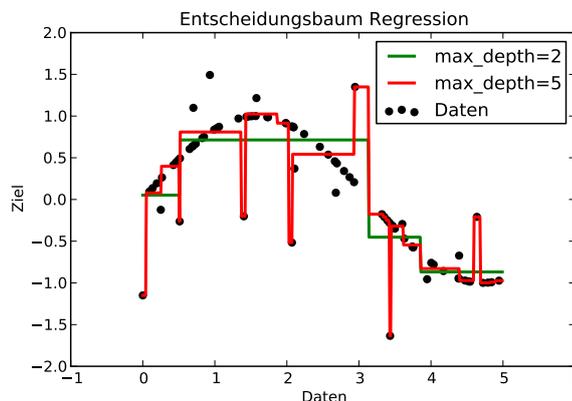


Abbildung 3.4: Regression mit Entscheidungsbaum¹²

So besteht das Interesse nicht an den genauen Instanzen in einem Blatt sondern vielmehr an der Verteilung im Blatt, d.h. die a-posteriori-Wahrscheinlichkeit im Blatt. Dabei besteht die Herausforderung, die Komplexität, d.h. der Stufen des Baumes – sogenannte Tiefe – möglichst gering zu halten, bei gleichzeitiger Optimierung der „Reinheit“. Die Eingrenzung der Tiefe ist erforderlich, um die Generalisierungsfähigkeit des Baumes zu gewährleisten. Abbildung 3.4 zeigt einen Entscheidungsbaum für die Regression mit einer Tiefe von 2 bzw. 5 Stufen. In diesem Beispielfall verleiht die größere Tiefe den Ausreißern ein zu großes Gewicht; die verrauschte Sinus Kurve wird besser durch den zweistufigen Baum repräsentiert.

Der entsprechende Algorithmus wurde als CART-Modell (Classification And Regression Tree) von Breiman und Friedman im Jahr 1983 eingeführt [Bre93]:

GBT

Gegeben seien N Beobachtungen und jeweils p Features, (x_i, y_i) für $i = 1, 2, \dots, N$ mit $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})$. Der Entscheidungsbaum teilt diese N Werte in M Regionen ein, wobei an jedem terminalen Blatt der Mittelwert berechnet wird. Anschließend wird der Fehler für jeden Datenpunkt wie folgt berechnet:

$$f(x) = \sum_{m=1}^M c_m I(x \in \mathbb{R}_m) \quad (3.5)$$

Dabei ist I die Indikatorfunktion, die angibt, ob sich ein Datenpunkt im Blatt befindet oder nicht. Der Wert c_m ist die Verlustfunktion im Blatt. Ziel ist die Unterteilung des Datenraumes in Unterbereiche mit möglichst geringer Varianz. Dementsprechend wird die Güte einer Aufteilung durch den mittleren quadratischen Fehler zwischen den Werten im Blatt vom geschätzten Wert gemessen und die Verlustfunktion C entspricht der quadratischen Norm.

$$C = \sum_m \sum_{i \in R_m} (y_i - \hat{y}_m)^2 \quad (3.6)$$

Ein Entscheidungsbaum nimmt dabei seine eigene Merkmalsselektion vor, d.h. der multivariate Baum nutzt lediglich die benötigten Variablen, wobei er die global wichtigsten Variablen weit oben im Baum benutzt. Dabei haben Entscheidungsbäume – gegenüber Distanz basierten Modellen – den Vorteil, dass sie invariant auf die Merkmalsdimensionierung reagieren, so dass eine Vorverarbeitung wie das Skalieren oder Normalisieren entfallen kann. Ferner ist es mit Bäumen möglich, auch mehrfache Wechselwirkungen zwischen den einzelnen Merkmalen zu lernen. Die Induktion der Entscheidungsbäume erfolgt rekursiv im Top-down-Prinzip; „top down induction of decision trees (TDIDT)“ [BK96]. Diese Suche ist *NP-vollständig*¹³, daher werden Heuristiken angewendet [Cor10]. Normaler-

¹²Beispiel aus sklearn, www.scikit-learn.com

¹³ In der Informatik bezeichnet man ein Problem als NP-vollständig (vollständig für die Klasse der Probleme, die sich nichtdeterministisch in Polynomialzeit lösen lassen), wenn es sich vermutlich nicht effizient lösen lässt [Coo71].

weise folgt der Ansatz einem *Greedy Ansatz* („gierig“), das heißt Entscheidungen früherer Stufen werden nicht revidiert und folgende Funktion wird optimiert [Alp08]:

$$(j^*, t^*) = \operatorname{argmin}_{j,t} C(\{\mathbf{x}_i, y_i : x_{ij} \leq t\}) + C(\{\mathbf{x}_i, y_i : x_{ij} > t\}) \quad (3.7)$$

Dies hat zur Folge, dass bei Verwendung eines einzelnen Baumes eventuell große Verzerrungen entstehen, in der Folge, dass die Varianz zwischen verschiedenen Bäumen groß ist. Entscheidungsbäume zählen daher zu den sogenannten schwachen (engl. weak) Lernen¹⁴. Kombiniert man jedoch mehrere schwache Lerner, so lässt sich die induktive Verzerrung reduzieren und Ensemble von Entscheidungsbäumen erreichen beachtliche Ergebnisse. So werden inzwischen (2014) fast die Hälfte aller Prognosewettbewerbe mit Ensemble Tree Modellen gewonnen [Che14], [Alp08]. Dabei unterscheidet man bei der Ensemble Bildung zwischen sogenannten „*Bagging*“ und „*Boosting*“ Ansätzen.

Beim *Bagging* – eingeführt von Breiman 1994 [Bre93] erfolgt eine zufällige Erzeugung mehrerer Bäume (eng. randomized trees - random forest). Eine Reduzierung der Verzerrung ist durch die einfache Mittelwertbildung über die Prognosen mehrerer unabhängiger zufällig erzeugter Bäume möglich. Dabei erfolgt sowohl die Auswahl der Merkmale wie auch die Wahl der Schwellwerte randomisiert. Diese sogenannten „Extra (randomized) Trees“ haben dadurch jedoch eine erhöhte Varianz, die im besonderen Maße von der Zusammensetzung der Trainingsmenge abhängt [GEW06]. Lin und Jeon [LY13] haben 2002 herausgefunden, dass bei konstanter Menge k in den Endblättern und $N \rightarrow \infty$, der Einfluss einzelner Datenpunkte auf den Vorhersagewert ca. $k(\log N)^{p-1}$ beträgt. Das heißt der Glättungseffekt hängt exponentiell von der Merkmalsdimension ab [Geu06].

Eine gute Alternative bieten *Boosting* Ansätze. Der Hauptunterschied zwischen den beiden Ansätzen ist, dass beim *Bagging* eine große Anzahl paralleler von einander unabhängiger Bäume geschaffen wird, während beim *Boosting* ein Baum iterativ verbessert wird und damit jeder Baum von dem Vorherigen abhängt. So ist der Gradient Boosting Tree (GBT) eine additive Kombination mehrerer Entscheidungsbäume. Gegeben K Entscheidungsbäume f_k ergibt sich für die Prognose zum Zeitpunkt i nach [Geu06]:

$$\hat{y}_i := \sum_{k=1}^K f_k(x_i) \quad (3.8)$$

Dabei startet der GBT mit einer konstanten Vorhersage und fügt in jeder Iteration – Zeitstufe t – eine additive Komponente hinzu. Es ist nach [Che14]:

$$\begin{aligned} \hat{y}_i^{(0)} &= 0 \\ \hat{y}_i^{(1)} &= f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_1) \\ \hat{y}_i^{(2)} &= f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_1) \\ &\dots \\ \hat{y}_i^{(t)} &= \sum_{k=1}^K f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_1) \end{aligned} \quad (3.9)$$

¹⁴ Zur Bias Varianz Problematik bei Entscheidungsbäumen siehe unter anderem [GEW06].

Das Ziel ist die Minimierung der Verlustfunktion über den Trainingsdaten bei gleichzeitiger Minimierung der Komplexität Ω der einzelnen Bäume [Che14]:

$$Obj^{(t)} = \sum_{i=1}^n L\left(y_i, \hat{y}_i^{(t-1)} + f_z(x_i)\right) + \Omega(f_t) \quad (3.10)$$

Dabei wird auf jeder Stufe eine Funktion (eine Baum) gesucht, der die Summe der Abweichungen der Residuen der Vorstufe kompensiert¹⁵. So entspricht der Ausdruck $L\left(y_i, \hat{y}_i^{(t-1)}\right)$ genau den Residuen. Der Algorithmus trainiert dementsprechend auf jeder Stufe einen Entscheidungsbaum auf den Residuen der vorherigen Stufe und addiert diesen. Das heißt es werden nicht die einzelnen Merkmalsgewichte optimiert/gelernt, sondern es werden verschiedene Funktionen (Trees) gelernt. Dabei kann man die Residuen als negative Gradienten auffassen, d.h. der Algorithmus des GBT entspricht dem Gradientenabstiegsverfahren, bei der eine Funktion durch die Addition des negativen Gradienten der Verlustfunktion optimiert „geboostet“ wird [GL14]. Daher die Bezeichnung Gradient Boosting. Ähnlich den Neuronalen Netzen oder Support Vector Machines¹⁶ wird durch den Gradientenabstieg die Trennlinie entgegengesetzt dem Gradienten, verschoben. Zur Vermeidung des Overfitting wird auch bei den GBT eine Lernrate η gesetzt, die den additiven Komponenten mit zunehmender Iterationsstufe weniger Gewicht beimisst. Für genauere Informationen zu den GBT siehe unter anderem [GL14], [ELH08], [GL15]. Abbildung 3.5 zeigt beispielhaft die Modellierung eines GBT auf einer Sinuskurve. Die linke Abbildung zeigt die vorgegebene Kurve (engl. ground truth) und die folgenden Abbildungen zeigen die Bäume auf den drei Stufen. Die Punkte in den rechten Abbildungen entsprechen jeweils den Residuen der vorherigen Stufen. Man erkennt, dass die Abweichungen der Residuen mit zunehmender Zeitstufe geringer werden.

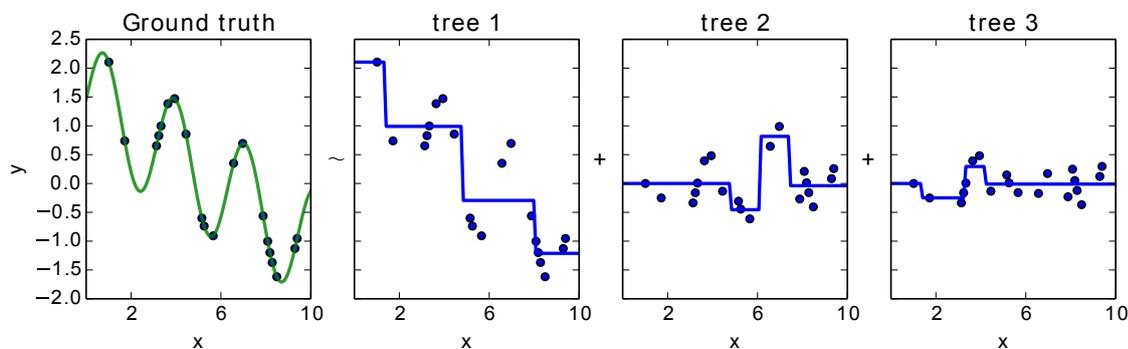


Abbildung 3.5: Beispiel Gradient Boosting Tree¹⁷

¹⁵ Zur Herleitung der Gradient Boosting Trees siehe zum Beispiel [Che14].

¹⁶ Für Support Vector Machines siehe z.B. Vapnik und Lerner [Vap08].

¹⁷ Abbildung aus [GL14].

Beide Ensemble Methoden (RFT, GBT) erlauben eine implizite Berechnung der Merkmalsgewichte (engl. relative Feature Importance FI) und damit ihrer erklärenden Anteile an der Response Variablen. Dabei berechnet sich die relative Relevanz der einzelnen Merkmale nach Breiman (2001,2002) wie folgt [GL15]:

Relative Merkmalsrelevanz (Feature Importance FI)

$$Imp(X_p) = \frac{1}{N_T} \sum_T \sum_{t \in T: v(s_t)=X_p} p(t) \Delta i(s_t, t) \quad (3.11)$$

mit $\Delta i(t)$ als Reduzierung der Varianz mit

$$\Delta i(s, t) = i(t) - p_L i(t_L) - p_R i(t_R) \quad (3.12)$$

Dies entspricht dem gewichteten Mittelwert aller Reduzierungen der Varianz $p(t) \Delta i(s_t, t)$ über alle Bäume N_T . Dabei ist die Funktion $i(t)$ ein Maß der Verbesserung an der Verzweigung t , bei der die Variable $v(s_t)$ mit dem Split s_t dem Merkmal X_p entspricht. Gewichtet werden die Verbesserungen mit der Wahrscheinlichkeit $p(t)$ ¹⁸, dass ein Datenpunkt diese Verzweigung erreicht. An diesem Knoten teilen sich diese Datenpunkte in die Untermengen t_L und t_R mit den entsprechenden Wahrscheinlichkeiten p_L und p_R .

Eine Möglichkeit der Auswertung des Einflusses einzelner Merkmale ist die Darstellung in Form sogenannter „Partial Dependence Plots“ anhand derer sich lineare Zusammenhänge zwischen einem Merkmal und der Response Variablen abgelesen und damit quantifizieren lassen. Dies geschieht durch sogenannte Out-of-Bag-Analysen, wobei das jeweils untersuchte Merkmal konstant gehalten wird, und alle anderen Merkmale in einem Versuchsplan gestuft werden. Anschließend kann der Effekt des Zielmerkmals berechnet werden. Das Verfahren der Variationsrechnung innerhalb der Entscheidungsbäume ist damit vergleichbar dem Vorgehen der statistischen Versuchsplanung [Kle13]¹⁹.

Die Feature Importance Berechnung von Breimann ähnelt der Granger Kausalität [Sch04]. Die Granger Kausalität lässt sich wie folgt charakterisieren. Gegeben zwei Zeitreihen X und Y, besteht keine Granger Kausalität von X zu Y wenn die Verteilung von Y in der Zukunft unabhängig ist von der Zeitreihe X. Breimann stellt eine Verallgemeinerung von Granger dar, weil er sich nicht auf Zeitreihen beschränkt und nicht auf die binäre Gewichtung, sondern auch alle Arten der Teilung des Baumes beinhaltet. Ein weiterer Unterschied ist die Tatsache, dass bei Breiman zur Bewertung der Feature Importance kein neues Modell trainiert wird, sondern die Berechnung der FI unabhängig vom Trainingsprozess geschieht [Ber08, Seite 200].

¹⁸ Die Wahrscheinlichkeit ist der Quotient der Anzahl Datenpunkte, die die Verzweigung erreichen, zur Menge aller Datenpunkte N_t/N .

¹⁹ Zur Effektanalyse der Einflussgrößen auf den Regelsaldo mit Methoden der statistischen Versuchsplanung siehe [OKL15].

3.1.4 Vorgehensmodell Maschinelles Lernen

Das Vorgehen beim maschinellen Lernen ist in Abbildung 3.6 noch einmal zusammenfassend dargestellt. Zunächst wird demnach die vorhandene Datenmenge in Test- und Trainingsdaten aufgeteilt. Die Trainingsdatenmenge kann anschließend für die Parameteroptimierung weiter in eine Trainings- und eine Validierungsmenge unterteilt werden, wobei diese Teilung im Zuge der Kreuzvalidierung auch dynamisch geschehen kann. Die Datenmenge beinhaltet dabei sowohl Realisationen d.h. Zeitreihen der Einflussfaktoren (Merkmale/Prädiktoren) wie auch der Zielvariablen (Label). Im anschließenden Schritt der Merkmals- Labelgenerierung werden aus diesen Daten jeweils die Merkmal/Label-Paare gebildet. Dabei sind sowohl eine geeignete Merkmalsauswahl wie auch -gewichtung zu treffen. Mit diesen Wertepaaren kann anschließend das Modell trainiert werden, das zuvor im Rahmen einer Modellauswahl anhand der Kriterien Komplexität, Generalisierungsfähigkeit und Größe der Trainingsdatenmenge ausgewählt wurde. Nach einer Anfangsinitialisierung der Modellparameter wird anschließend die Prognose auf den Testdaten erzeugt. In der folgenden Evaluation werden diese Prognosewerte mit Hilfe einer Verlustfunktion mit den tatsächlich realisierten Werten verglichen. In einer iterativen Optimierung können abschließend die einzustellenden Modellparameter angepasst werden.

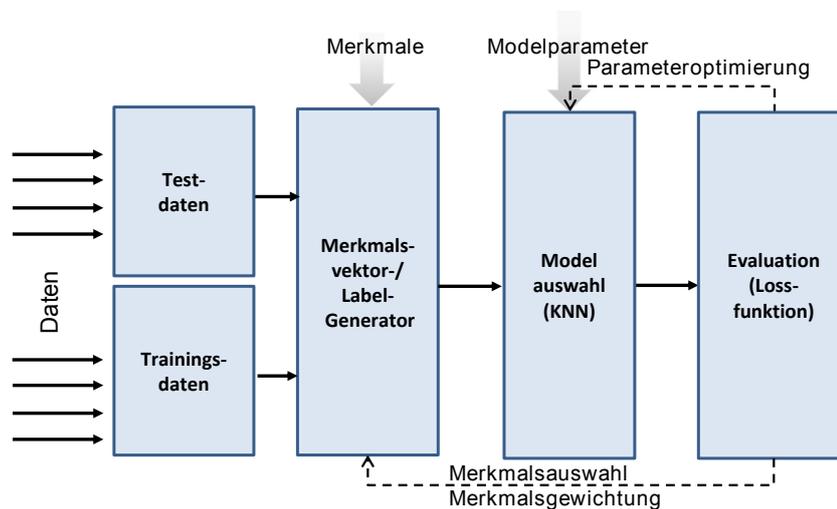


Abbildung 3.6: Vorgehensmodell für das Maschinelle Lernen

3.2 Merkmalsgenerierung

In Kapitel 2.1.3 wurden bereits die Einflussfaktoren auf das Systemungleichgewicht und damit den Regelsaldo vorgestellt. Dies sind neben dem Wind- und PV-Fehler, Lastschwankungen, Fahrplansprünge sowie Kraftwerksausfälle. Darüber hinaus konnte gezeigt werden, dass auch zeitliche Merkmale wie Monat, Wochentag, Uhrzeit oder „Begin of Hour“ einen Einfluss auf den Regelsaldo haben. Die Aufgabe der Merkmalsgenerierung ist nun, diese Merkmale geeignet abzubilden, so dass anhand eines Distanzmaßes ähnliche Nachbarn in der Datenmenge gefunden werden können. Dazu unterteilt sich der Vorgang der Merkmalsgenerierung in die folgenden Unterpunkte:

- Merkmalsvektorisierung
 - Merkmalstransformation
- Merkmalsvorverarbeitung
 - Merkmalsskalierung
 - Distanzmaß
 - Merkmalsauswahl
 - Merkmalsgewichtung

3.2.1 Merkmalstransformation

Zunächst müssen die einzelnen Merkmale auf skalare Werte abgebildet werden, so dass eine Berechnung des Abstandes zweier Systemzustände im Datenraum möglich wird. Dazu werden die Merkmale zunächst in drei Kategorien unterteilt:

- **Features-Lag:**
Realisierte Zeitreihen, für die Daten bis zum Zeitpunkt $\{x_t | t \leq t_0\}$ vorliegen.
Dies sind Regelzonensaldo, Preisinformationen (PHB), Windeinspeisung, PV-Einspeisung und vertikale Netzlast
- **Features-Future:**
Prognosezeitreihen, für die Daten zum Prognosezeitpunkt vorliegen $\{x_t | t \leq t_0 + pred_hor\}$.
Dies sind Windprognose und PV-Prognose
- **Features-Time:**
Reale Werte über den Prognosehorizont.
Dies sind Monat, Wochentag, Uhrzeit oder „Begin of Hour“

Während die Zeitreihenmerkmale bereits als skalare Werte vorliegen, müssen die Zeitmerkmale noch in skalare Werte transformiert werden. Die Monate werden entsprechend in ganzzahlige Werte zwischen eins und zwölf gewandelt, und für die Wochentage wird die vor implementierte Konvention der verwendeten Programmiersprache (*python*) übernommen, so dass Wochentage in Integer-Werte zwischen null (Montag) und sechs (Sonntag)²⁰ abgebildet werden. In unserem Fall ist dies vorteilhaft, da hohe Werte für Wochenenden stehen und niedrige Werte für Wochentage. Nichts desto trotz

²⁰ Dies ist zum Beispiel ein entscheidender Unterschied zu Java, hier ist die Null der Sonntag.

ist diese Abbildung kein geeignetes Maß um den Abstand zwischen Tagen – ebenso wenig wie zwischen Monaten oder Tageszeiten – festzustellen. So würde beispielsweise ein Sonntag und ein Montag maximal entfernt liegen, ebenso wie ein 31. eines Monats und der 1. eines Folgemonats. Um dem entgegenzuwirken könnte ein zyklisches Distanzmaß verwendet werden; dies impliziert jedoch, dass für jedes Zeitmerkmal ein eigenes Distanzmaß verwendet werden müsste und die Merkmale nicht in einem Vektor zusammengeführt werden könnten. Eine Alternative wäre es, die Datumsinformationen nicht in das Distanzmaß aufzunehmen, sondern den Suchraum entsprechend den Datumsmerkmalen einzuschränken. Diese Überlegungen werden im Modelldesign bzw. in der Evaluation berücksichtigt.

Abbildung 3.7 zeigt das Vorgehen. Gegeben die Zielzeitreihe des Regelsaldos sowie weitere Merkmalszeitreihen und Merkmalswerte zum Zeitpunkt t , sollen mit Hilfe des Modells Aussagen über die Realisation der Zielzeitreihe zum Zeitpunkt $t + pred$ ($t + \tau$) getroffen werden. Dazu werden in den Trainingsdaten mit Hilfe der Distanzfunktion ähnliche Kurvenabschnitte gesucht. Anschließend wird das zugehörige Label als erwartete Realisation vorhergesagt. Die Differenz zwischen dem vorhergesagten und dem realisierten Wert ergibt den Prognosefehler.

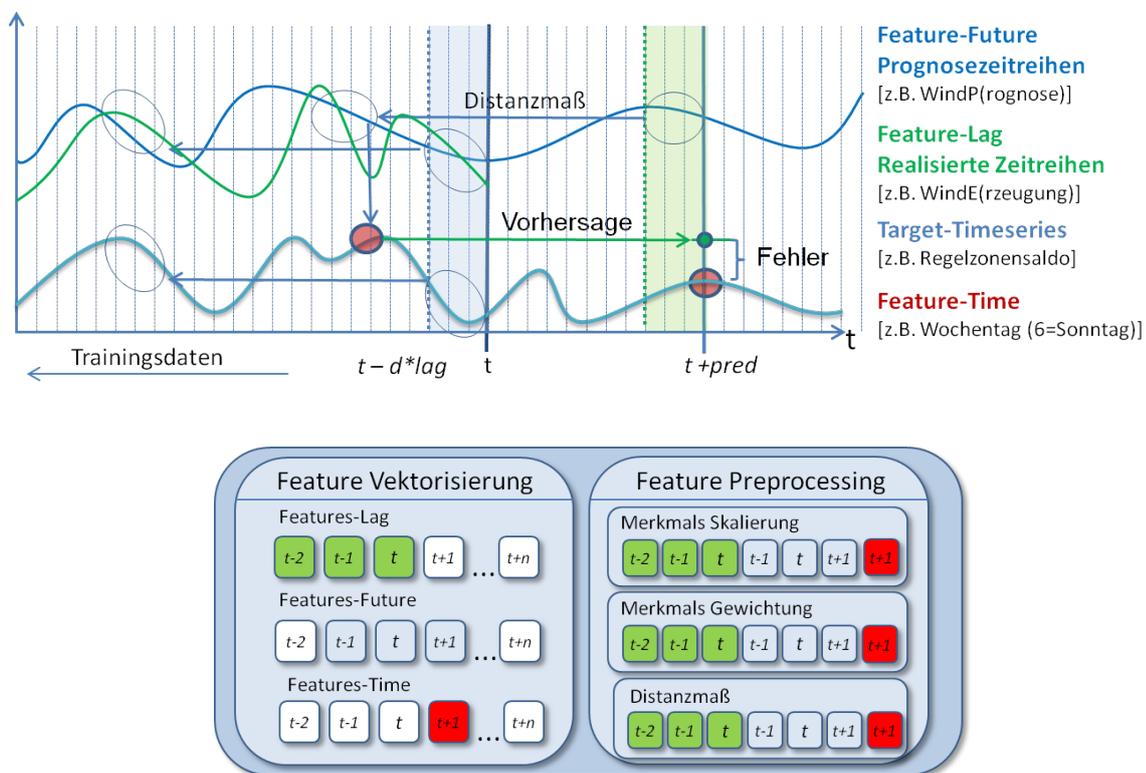


Abbildung 3.7: Vorgehen bei der Suche nach ähnlichen Systemzuständen

Je nachdem ob sich die abhängige Variable, der Regelsaldo y_t und die unabhängigen Variablen, $x_{i,t}$ des Systemzustands (Merkmale) auf dieselbe Zeitperiode t beziehen, unterscheidet man zwischen statischen und dynamischen Modellen [Cro10]. So werden beim dynamischen Modell auch zeitlich verzögerte Realisationen mit in das Modell aufgenommen. Dabei können sowohl verzögerte Realisationen der Zielvariablen als auch der erklärenden Variablen $x_{i,t-l}$ in das Modell einbezogen werden. Die zeitliche Verzögerung (engl. lag) wird mit l angegeben, daher werden diese Variablen auch

„Lag-Variablen“ genannt [Bro77]. Die Prognose des Regelzonensaldos ist dementsprechend ein dynamisches Modell, weil anhand eines Systemzustandes x_t zum Zeitpunkt t eine Aussage über die Zielvariable $y_{t+\tau}$ zum Zeitpunkt $t+\tau$ getroffen werden soll. Der Prognosehorizont τ stellt damit eine Verzögerung für alle realisierten Zeitreihen in Bezug auf die Zielvariable dar, da für diese Zeitreihen nur Werte bis zum Zeitpunkt t vorliegen. In Bezug auf den Prognosezeitpunkt $t+\tau$ sind diese Werte dementsprechend mit einem lag von τ verzögert bzw. verschoben; daher die Bezeichnung „Feature-Lag“. Je nachdem wie viele Werte pro Zeitreihe ausgewählt werden ergeben sich pro Merkmal d Werte. Dabei kann man entweder d zusammenhängende Werte, d.h. einen Kurvenabschnitt auswählen (in diesem Fall ist $l = 1$) oder man wählt das l entsprechend einer sog. Abtastrate. Dies ist zum Beispiel bei frequentierten Zeitreihen hilfreich. In unserem Fall wurden die zusammenhängenden letzten Werte jeder Zeitreihe ausgewählt. Es ergeben sich demnach die eingefärbten Bereiche. Anschließend werden diese d Werte der Einzelmerkmale in einem gemeinsamen Vektor zusammengeführt und weiter vorverarbeitet.

3.2.2 Merkmalsskalierung

Da die einzelnen Prädiktor Variablen zum Teil erhebliche Dimensionsunterschiede haben, zum Beispiel haben die Lastwerte die Dimension 1000 während die Wochentage nur Werte zwischen null und sechs annehmen können, würde dies die Aussagen des Distanzmaßes verzerren. So würden z.B. bei der euklidischen Distanz immer die werthöchsten Variablen die Distanz dominieren und damit die Nachbarn bestimmen. Um dies zu verhindern müssen die Werte vorbehandelt (engl. preprocessing) werden. Dazu kann man die Werte der Variablen entweder **normieren** oder **standardisieren**. Im ersten Fall werden die Werte in den Wertebereich zwischen $[0, 1]$ transformiert, indem von jedem Wert der Minimalwerte abgezogen wird und dann durch die Wertespanne geteilt wird.

Normierung

$$x_{norm} = \hat{x}_{ij} = \frac{x_{ij} - \min_j}{\max_j - \min_j} \quad (3.13)$$

mit

$$\min_j = \min\{x_{ij} | i = 1, \dots, M\}, \quad \max_j = \max\{x_{ij} | i = 1, \dots, M\}$$

Das Problem bei der Normierung liegt darin, dass für neue unbekannte Muster keine Garantie vorliegt, dass \hat{x}_{ij} innerhalb des Wertebereiches von $[0, 1]$ liegt. Im Gegensatz dazu werden bei der Standardisierung – oder auch z-Transformation – die Werte der Merkmale so transformiert, dass der Erwartungswert null wird und die Standardabweichung eins wird.

Ist x_j das j -te Merkmal mit den Erwartungswert $E(x_j) = \mu_j$ und die Varianz $\text{var}(x_j) = \sigma_j^2$ erhält man die transformierten Werte \hat{x}_{ij} mit:

Standardisierung

$$x_{stan}\hat{x}_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (3.14)$$

mit

$$\mu_j = \frac{1}{N} \sum_{i=1}^N (x_{ij}) \quad \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{ij} - \mu_j)^2}$$

Die einzelnen Arten der Datenvorverarbeitung werden im Programm in einem *Dictionary* festgelegt. Ähnlich einem Wörterbuch werden darin jedem Schlüsseleintrag bestimmte Werte zugeordnet. Die Art des Merkmals legt dabei fest, zu welchem Zeitpunkt t der Vektor für das entsprechende Merkmal generiert wird und wie dieser vorverarbeitet wird. So werden zum Beispiel Zeitmerkmale nicht z-transformiert/standardisiert, sondern lediglich normalisiert, da es keine negativen Zeitmerkmale gibt. Dies ist erforderlich damit sie in der Größenordnung mit den standardisierten Größen harmonisieren und diese nicht dominieren.

3.2.3 Distanzfunktion

Nach erfolgreicher Vektorisierung lassen sich mit Hilfe von Distanzfunktionen – Unähnlichkeitsmaßen – Abstände von Merkmalsvektoren im d -dimensionalen Raum berechnen, indem jedes Vektorenpaar auf einen skalaren Wert abgebildet wird. Dabei heißt eine Abbildung *dist* genau dann Unähnlichkeitsmaß für alle x und y wenn gilt[Run10]:

$$\begin{aligned} dist(x, y) &= dist(y, x) \\ dist(x, y) &\geq 0 \\ dist(x, x) &= 0 \end{aligned} \quad (3.15)$$

Dabei lassen sich Distanzmaße auch durch Normen der Differenz zwischen zwei Vektoren darstellen. Allgemein erhält man für die Matrixnorm [Run10] zur Matrix A :

$$\|x - y\|_A = \sqrt{(x - y)A(x - y)^T} \quad (3.16)$$

Setzt man für die Matrix die Identitätsmatrix ein, so erhält man die *Euklidische Norm*:

$$\|x - y\|_2 = \sqrt{\sum_{j=1}^d (x^{(j)} - y^{(j)})^2} \quad (3.17)$$

Die Diagonalen der Matrix A können als Gewichte interpretiert werden, die den Merkmalen eins bis d zugeordnet sind. Im Falle des euklidischen Abstandes werden alle Merkmale mit dem Faktor eins

belegt und damit gleich gewichtet. Wird jedes Merkmal unterschiedlich entsprechend seines Beitrags g_d gewichtet, erhält man die folgende Matrix A [Run10]:

$$A = \begin{pmatrix} g_1 & 0 & \dots & 0 \\ 0 & g_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & g_d \end{pmatrix} \quad (3.18)$$

In diesem Fall entstehen keine Kreise, sondern Ellipsen. Voraussetzung für die Anwendung dieser Distanzmasse ist, dass die einzelnen Merkmale unkorreliert sind, d.h. $E(X \cdot Y) = E(X) \cdot E(Y)$ [Koc12]. Insbesondere bei steigender Anzahl Merkmale kann es jedoch verstärkt zu Wechselwirkungen – sogenannter Multikollinearität (engl. multicollinearity) – kommen. In diesem Fall sind die einzelnen unabhängigen Variablen untereinander nicht länger unkorreliert, d.h. zum Beispiel, dass die erwarteten Werte der einzelnen Dimensionen der Zufallsvariablen (Systemzustand) sich einander bedingen. Im Merkmalsraum stehen die Hauptachsen der jeweiligen Merkmale (jeweiliger Einheitsvektor) nicht mehr senkrecht aufeinander, sondern in einem Winkel, dessen Kosinus der Korrelation der beiden Merkmale untereinander entspricht. Im Falle der Abhängigkeit ergibt sich eine gedrehte Ellipse und in der Matrix sind auch die Werte außerhalb der Diagonalen belegt. Ein Beispiel ist die *Mahalanobis Norm*, die als Matrix A die Inverse der Kovarianzmatrix benutzt [Mah], [Koc12]:

$$A = cov^{-1}X = \left(\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^T (x_k - \bar{x}) \right)^{-1} \quad (3.19)$$

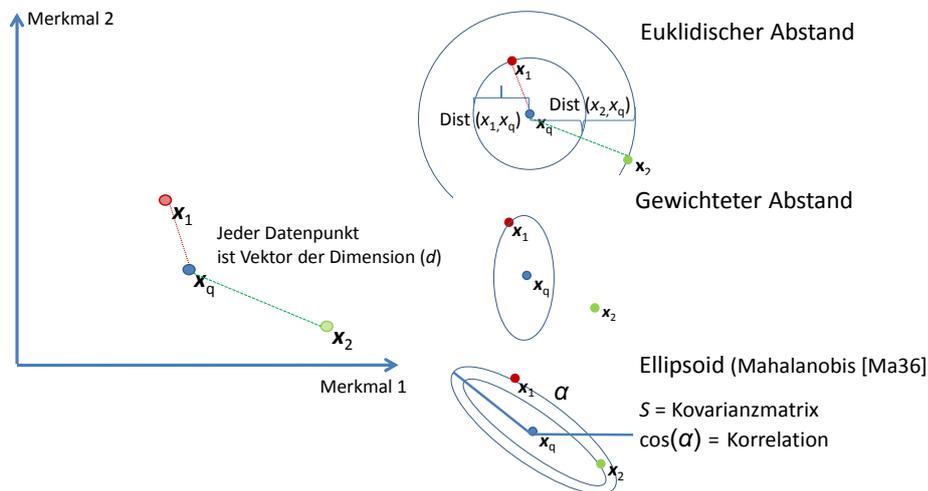


Abbildung 3.8: Euklidisches Distanzmass und Mahalanobis Distanz

Abbildung 3.8 zeigt den Unterschied zwischen dem euklidischen Abstand und dem Mahalanobis Abstand für den zweidimensionalen Merkmalsraum. Dem entgegengesetzt gibt es auch die Mög-

lichkeit der Ähnlichkeitsmaße. Ein Ähnlichkeitsmaß (engl. similarity) ist eine Abbildung für die gilt [Run10]:

$$\begin{aligned} sim(x, y) &= sim(y, x) \\ sim(x, y) &\geq 0 \\ sim(x, x) &\geq sim(x, y) \end{aligned} \quad (3.20)$$

Sind die beiden Vektoren normalisiert, so gilt zudem:

$$sim(x, x) = 1 \quad (3.21)$$

Ein bekanntes normalisiertes Ähnlichkeitsmaß zwischen zwei Vektoren ist ihre Korrelation; diese ist gleichbedeutend mit dem Cosinus des Winkels zwischen diesen beiden Vektoren. Daher ist der Cosinus eine bekannte Ähnlichkeitsfunktion sim_{cos} [Run10]:

$$sim_{cos}(x, y) = \frac{\sum_{i=1}^d x^{(i)} y^{(i)}}{\sqrt{\sum_{i=1}^d (x^{(i)})^2 \sum_{i=1}^d (y^{(i)})^2}} \quad (3.22)$$

Das Problem bei Ähnlichkeitsmaßen – im Unterschied zu Unähnlichkeitsmaßen – besteht darin, dass eine vermeintliche Verschiebung der beiden Vektoren nicht ins Gewicht fällt. So haben auch zwei um das Maß x verschobene Vektoren das Ähnlichkeitsmaß eins, jedoch auch einen Bias von x . Daher muss bei der Verwendung des Ähnlichkeitsmaßes die Verschiebung bei der Vorhersage der Zielvariablen berücksichtigt werden.

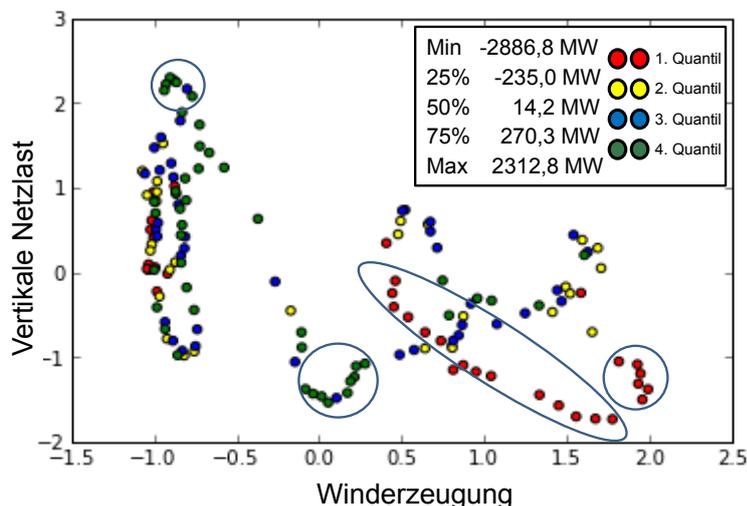


Abbildung 3.9: Distanzmaß und Merkmalsgewichtung

Um eine Vorstellung eines geeigneten Distanzmaßes im vorhandenen Merkmalsdatenraum zu erhalten, sind in Abbildung 3.9 250 zufällig ausgewählte Datenpunkte zwischen Januar und März 2011 für die Regelzone von Tennet dargestellt. Dabei sind die Werte der Zielvariablen entsprechend ihrer Quantilszugehörigkeit farblich eingefärbt. Die Legende zeigt jeweils die obere Grenze eines jeden

Quantiles. Als Merkmale werden für die zweidimensionale Darstellung die Winderzeugung auf der x-Achse und die vertikale Netzlast auf der y-Achse gewählt. Die Merkmale sind jeweils standardisiert, so dass die Standardverteilungen abgetragen sind. Man erkennt, dass sowohl die Höhe der einzelnen Merkmale als auch deren Wechselwirkung einen Einfluss auf die Quantilszugehörigkeit haben. So führt die Kombination aus einer besonders niedrigen Winderzeugung bei gleichzeitig hoher vertikaler Netzlast zu extrem hohen Regelsalden, während umgekehrt besonders niedrige Werte der vertikalen Netzlast in Kombination mit einer extrem hohen Winderzeugung zu extrem niedrigen Regelzonensalden führen. Des Weiteren ist in der Mitte ein Bereich der Korrelation zwischen den beiden Merkmalen erkennbar, bzw. eine Wechselwirkung, die in der Kombination zu ähnlichen ebenfalls extrem niedrigen Regelzonensalden führt.

Das Ziel der Distanzfunktion muss es daher sein, die Merkmale nicht statisch einheitlich zu gewichten, sondern eine dynamische Merkmalsgewichtung zu ermöglichen, die sich sowohl an der relativen Höhe der einzelnen Merkmale wie auch an der Wechselwirkung zwischen den Merkmalen orientiert. Eine Möglichkeit wäre die Nutzung der Mahalanobis Distanz. Die Nutzung der Umkehrung der Kovarianzmatrix hat jedoch den Effekt, dass alle Variablen auf die Einheitsmatrix standardisiert werden und Korrelationen eliminiert werden [Alp08, Seite 94]. So erhält eine Variable weniger Gewicht, wenn sie eine größere Varianz als eine andere hat, und haben zwei Variablen eine hohe Korrelation miteinander, so gehen sie ebenfalls weniger stark in die Bemessung ein. In unserem Fall ist dies allerdings nicht gewünscht. Ferner sind die Kovarianzen zwischen den einzelnen Merkmalen sowie die Korrelation zwischen den Merkmalen und der Zielvariablen zeitlich differenziert. Man müsste daher zur Verwendung der Mahalanobis Distanz, die Kovarianz für jeden Datenpunkt neu berechnen. Da dies ein zu hoher Rechenaufwand wäre, wird stattdessen das relative Merkmalsgewicht und die Korrelation der einzelnen Merkmale mit der Zielvariablen zur Gewichtung verwendet. Des Weiteren werden durch eine Quadrierung der Merkmale (engl. double weight DW), Extremwerte stärker gewichtet.

Bevor nun ein geeignetes Distanzmass angewendet werden kann, müssen noch zwei weitere Aspekte analysiert werden, die zuvor bereits kurz in Form des Triple-Trade-Offs (siehe 3.1.1, Seite 65) angesprochen wurden; der *Umgang mit unausgewogenen Daten* und die *Wahl der geeigneten Dimension*.

Umgang mit unausgewogenen Daten

Dieses Problem entsteht wenn die Samplemenge eine unausgewogene Verteilung der unterschiedlichen Klassen bzw. Realisationen enthält, die nicht der Verteilung in der Gesamtmenge entspricht. In diesem Fall wird das trainierte Modell eine Verschiebung (engl. Bias) haben. Sollte die Samplemenge z.B. nur „Extensituationen“ enthalten, so wird das Prognosemodell ebenso eine gewisse Verschiebung produzieren, bzw. "Normalzustände" nur schwer prognostizieren können. In unserem Fall stellt sich diese Frage insbesondere bei der Wahl des Suchraums, d.h. der Länge des Zeitabschnitts der für das Training des Modells verwendet wird. Ist es zum Beispiel ausreichend einen rollenden Horizont, beispielsweise jeweils die letzten drei Monate, als Suchraum zu nehmen, oder wäre es besser vergleichbare Monate des Vorjahres als Suchraum zu nehmen? Entsprechende Fragestellungen werden in der Evaluation adressiert.

Wahl der geeigneten Merkmalsdimension

Der Erfolg der Suche nach den ähnlichsten Nachbarn im Datenraum, insbesondere von KNN, hängt entscheidend von der Größe des Datenraums, bzw. dessen Dimension ab. So ist die Gefahr groß, dass der Datenraum bei einer zu hohen Dimension zu „spärlich“ besetzt ist²¹. Dies ist eine Konsequenz des sogenannten „Fluchs der Dimensionen“ (siehe 2.3.3, Seite 57). Dabei lassen sich die negativen Wechselwirkungen einer zu großen Dimension wie folgt zusammenfassen:

- Der mögliche Funktionsraum steigt schneller als exponential an
- In hohen Dimensionen sind nahezu alle Samplemengen spärlich besetzt
- In höheren Dimensionen sind die einzelnen Variablen nicht mehr unabhängig voneinander
- Der Unterschied zwischen der kleinsten und der größten Distanz zwischen zwei Datenpunkten im Vergleich zur kleinsten Distanz wird mit zunehmender Dimension beliebig klein

Insbesondere die letzte Tatsache hat Auswirkungen auf die Wahl der nächsten Nachbarn, bzw. der Aussagekraft, die dem Distanzmaß beigemessen werden kann [BGr99]. Es ist daher notwendig, eine geeignete Merkmalsauswahl bzw. Merkmalsgewichtung vorzunehmen, da nicht parametrische Verfahren auf Basis von Distanzmassen wie KNN sensitiv auf irrelevante Merkmale reagieren.

3.2.4 Merkmalsauswahl

Der Prozess der Merkmalsauswahl lässt sich in drei Unterschritte aufteilen, *Screening*, *Ranking*, *Selecting* [EG04]. Nach einem anfänglichen Screening, d.h. einer Suche aller in Frage kommenden Einflussgrößen, erfolgt in einem zweiten Schritt ein Ranking der Merkmale in Bezug auf ihren Einfluss auf die Zielvariable. Im letzten Schritt erfolgt schließlich die endgültige Merkmalsauswahl. Dabei wird bei der Merkmalsauswahl zwischen der Merkmalsselektion und der Merkmalsextraktion unterschieden²². Bei der Merkmalsselektion (engl. Feature Subset Selection FSS) werden drei wesentliche Typen unterschieden [EG04]:

- Filter Ansatz
- Wrapper Ansatz
- Embedded/Hybrider Ansatz

Während der *Wrapper* Ansatz den Algorithmus des Prognosemodells nutzt, um das beste Subset zu finden, sucht der *Filter* Ansatz das beste Subset anhand von Informationen, die bereits vor Anwendung des Algorithmus bekannt sind. Dies sind zum Beispiel die Korrelation zwischen einzelnen Merkmalen oder Informationen, die mit Hilfe eines weiteren Algorithmus zuvor berechnet wurden. So werden unter anderem auch evolutionäre Algorithmen in der Merkmalsselektion eingesetzt. Siedlecki und Sklansky waren dabei die ersten, die Evolutionäre Algorithmen (EA) in Verbindung mit FSS eingesetzt haben, um gezielt eine Merkmalsauswahl vorzunehmen [SS89]. In ihrem Ansatz wurden

²¹ So benötigt man, um einen 10-dimensionalen Datenraum zu 10 % zu füllen, bereits 80 % der Daten einer jeden Dimension [HTF11].

²² Grundlagen zur Merkmalsauswahl finden sich zum Beispiel in [EG04].

die Merkmale allerdings nur binär codiert, d.h. eine eins bedeutet, dass das Merkmal zur Nachbarnsuche herangezogen wurde und eine null bedeutet, dass das Merkmal nicht herangezogen wurde. Dem Gegenüber wird bei der Merkmalsgewichtung – eine Unterkategorie der Merkmalsselektion – jedem Merkmal ein spezifisches Gewicht zugeordnet. Diesen Ansatz haben Cost, Salzberg [CS93] für die Methode der k-Nächsten-Nachbarn eingeführt, indem sie die optimierte Gewichtung der Merkmale mit Hilfe von Evolutionären Algorithmen weiterentwickelt haben. So kann die binäre Codierung von Siedlecki und Sklansky bereits als spezielle Form der Merkmalsgewichtung angesehen werden [Alp08]. Weitere Beispiele der Optimierung der KNN haben [GP10] (Boosting k Nearest Neighbors by Means of Input Space Projection), [Sha11] (ACO Boosting), [BBLB11] (Kernel Optimierung) gezeigt.

In diesem Fall werden die lokalen Korrelationen zwischen den Merkmalen und dem Regelsaldo als eine Form der Merkmalsgewichtung genutzt, wobei durch eine Multiplikation mit dem Korrelationskoeffizienten stark korrelierte Merkmale entsprechend stärker gewichtet werden²³. So hat die Abbildung 3.9 gezeigt, dass eine optimale Merkmalsgewichtung immer auch abhängig vom gesuchten Merkmalsvektor, d.h. vom Ort im Merkmalsraum ist. Außerdem konnte in [EG04] gezeigt werden, dass selbst wenn ein Merkmal nicht relevant erscheint, die Mitnahme dieses Merkmals dazu führen kann, dass der Merkmalsraum gewinnbringend eingeschränkt wird.

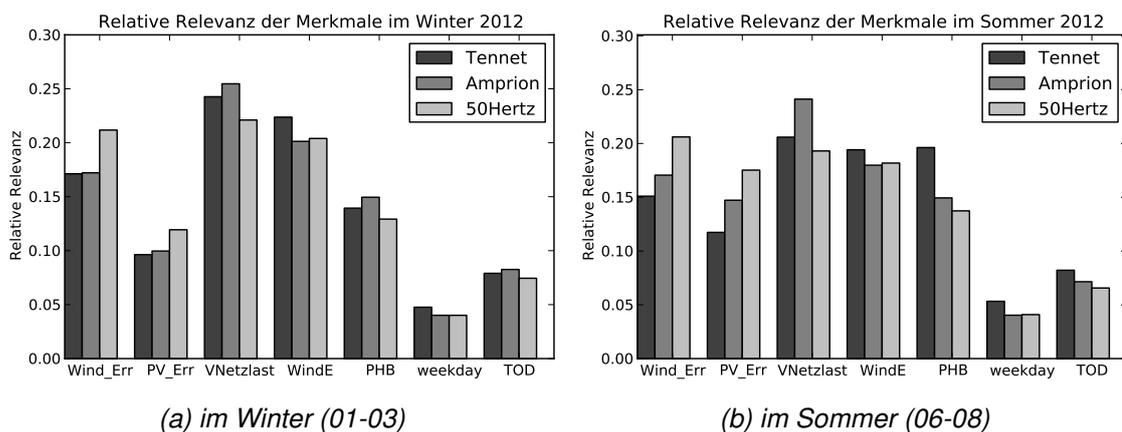


Abbildung 3.10: Saisonale und regionale Relevanz der Merkmale

So kann es vorteilhaft sein, den Merkmalsraum nicht bereits vor dem Aufruf des eigentlichen Prognosealgorithmus einzuschränken, sondern die Merkmalsauswahl innerhalb desselben (daher der Name *Wrapper*) vorzunehmen. Dabei wird bei den *Wrappern* zwischen parametrischen und nicht parametrischen Verfahren unterschieden, je nachdem ob die Merkmalsauswahl bzw. Merkmalsgewichtung direkt vorgenommen wird, d.h. die Merkmalsparametrisierung Teil des Algorithmus ist. So werden bei den künstlichen Neuronalen Netzen (kNN) die Merkmale direkt innerhalb des Modells parametrisiert²⁴, während z.B. in Entscheidungsbäumen, die Gewichtung der Merkmale indirekt über eine Varianzanalyse erfolgt, die Auskunft über den Informationsgehalt der einzelnen Merkmale liefert. Die relativen Merkmalsgewichte werden anschließend aus der Struktur der Bäume abgeleitet, je nachdem wie oft ein Merkmal für einen Baum benutzt wurde bzw. an welcher Hierarchieordnung es im Baum steht. Abbildung 3.10 zeigt die relativen Merkmalsgewichte, die mit einem Gradient Boos-

²³ Zur korrelationsbasierten Gewichtung von Merkmalen siehe z.B. [Hal99].

²⁴ Dies geschieht, indem der Gewichtsvektor in einem mehrdimensionalen Gradientenabstiegsverfahren optimiert wird.

ting Tree erzeugt wurden. Um regionale sowie saisonale Unterschiede aufzeigen zu können, wurden sowohl die drei markantesten Regelzonen Amprion, 50 Hertz und Tennet als auch die Winter- und Sommermonate einzeln trainiert. Es lässt sich erkennen, dass insbesondere der Einfluss des Wind- und PV-Fehlers sowohl regional als auch saisonal differiert.

Um auch quantitative Aussagen über den Einfluss einzelner Merkmale auf die Regelzonensalden treffen zu können, bietet die Methode des GBT eine integrierte „Out of Bag“- Analyse, die sowohl die Wirkung einzelner Faktoren wie auch ihre Wechselwirkung auf den Saldo berechnet. Abbildung 3.11 zeigt das Ergebnis des GBT in Form des wechselseitigen Einflusses des Windfehlers sowie der vertikalen Netzlast auf den Regelzonensaldo in den Regelzonen von Amprion und 50 Hertz. Man erkennt, dass in der Amprion Regelzone der Einfluss des Windfehlers eindeutig vom Einfluss der vertikalen Netzlast dominiert wird, während dies in der 50 Hertz Regelzone genau umgekehrt der Fall ist.

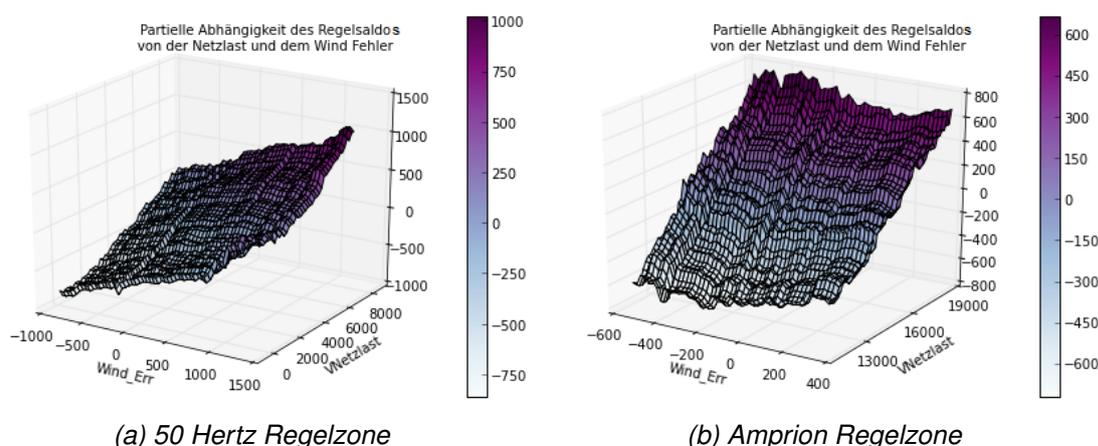


Abbildung 3.11: Wechselwirkung zwischen der Netzlast und dem Windfehler auf den Saldo

Analysiert man diese beiden Einflussfaktoren getrennt von einander, d.h. bereinigt man den Einfluss um die Wechselwirkung, erkennt man in Abbildung 3.12 jeweils klare lineare Zusammenhänge zwischen den Merkmalen und den Regelzonensalden. Die senkrechten Linien auf der x-Achse markieren dabei jeweils die Perzentile der Verteilungen für die entsprechende Datenmenge. So lässt sich erkennen, dass in den betrachteten Wintermonaten in der 50 Hertz Regelzone der Windfehler in 10 % der Fälle einen Wert kleiner als -600 MW angenommen hat, während er in der Amprion Regelzone nur Werte kleiner als -220 MW angenommen hat. Der maximale Fehler lag in der 50 Hertz Zone mit ca. +1200 MW ebenfalls dreimal so hoch wie in der Amprion Regelzone (+ 400 MW). In der 50 Hertz Regelzone hat der Windfehler dementsprechend einen wesentlich größeren Einfluss auf die Höhe des Saldos; dieser steigt mit anwachsendem Windfehler in etwa im Verhältnis 1:2,5. In der Amprion Regelzone ist der Einfluss des Windfehlers dagegen nicht linear ansteigend sondern sowohl ein negativer als auch ein positiver Windfehler führen zu einem leichten Anstieg des Saldos. Bei der vertikalen Netzlast in dagegen in beiden Regelzonen eine lineare Abhängigkeit feststellbar, hier ist das Verhältnis 1,3:1.

Während die *Merkmalsselektion* damit nur eine Auswahl von k aus n möglichen Merkmalen darstellt, erfolgt bei der *Merkmalsextraktion* eine Reduktion der Merkmalsanzahl durch eine Abbildung der Muster in \mathbb{R}^n mittels einer linearen Transformation in einen d -dimensionalen Unterraum \mathbb{R}^d . Diese kann entweder unüberwacht sein (z.B. Hauptkomponentenanalysen – Principal Component Analysis, (PCA)) oder überwacht (z.B. die Diskriminanzanalyse) [KD09].

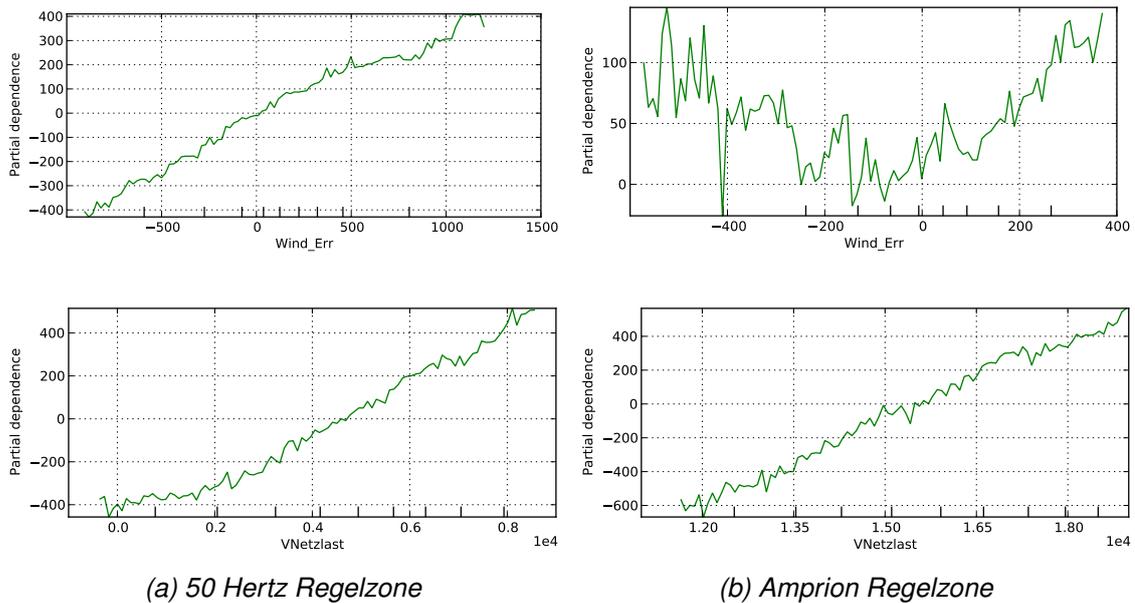


Abbildung 3.12: Partielle Abhängigkeit des Regelzonensaldos

Bei d Dimensionen existieren 2^d mögliche Kombinationen. Sowohl die PCA als auch die Lineare Diskriminanzanalyse (LDA) sind somit Methoden mit dem Ziel, die Dimension im Merkmalsraum zu reduzieren. Allerdings ignoriert die PCA die Label, und konzentriert sich ausschließlich auf die Varianz, während die LDA versucht einen Merkmalsunterraum zu finden, der die vorhandenen Klassen bestmöglich separiert. Das Ziel besteht bei beiden Verfahren darin, die Dimension zu finden, die die Daten optimal repräsentiert. Die PCA kann man dabei auch als „Erweiterung der Regression“ auffassen. So wird eine „hypothetische Variable“ konstruiert, die die gesamte Summe der quadratischen Abweichungen einer Ausgleichsgerade durch die Datenpunkte minimiert [KD09, Seite 175]. Im Gegensatz zur (multiplen) Regression werden die unabhängigen Variablen jedoch nicht vorgegeben, sondern sind hypothetische Konstrukte, die aus den Daten abgeleitet werden [KD09, Seite 175].

Dazu versucht die PCA die Originalvariablen durch eine kleinere Anzahl „dahinterliegender Variablen“ zu ersetzen. Das Ziel ist, die Korrelation zwischen den einzelnen Merkmalen „herauszufiltern“. So werden die Hauptachsen jeweils in Richtung der stärksten Varianz gesucht und die jeweiligen Achsen stehen senkrecht aufeinander, so dass die neu erzeugten Variablen unkorreliert unabhängig voneinander sind [Noa07]. Dabei geht der Ansatz davon aus, dass wenn zwei Variablen stark miteinander korreliert sind, gibt es eine Komponente (latenter Faktor), zu dem diese Variablen in Beziehung stehen bzw. eine ebenso starke Korrelation besitzen. Die Korrelation der Variablen zu diesen Komponenten bezeichnet man als auch als „Faktorladungen“ [Gru05]. Die neu zu bildenden hypothetischen Variablen sind Linearkombinationen der Ausgangsvariablen [Bac11]. Entscheidend für den Erfolg der Hauptkomponentenanalyse ist das Vorliegen stark korrelierter Ursprungsdaten, daher wird in einer ersten Analyse auch die Korrelation der Ursprungsdaten analysiert. Genauer gesagt, sollen die Komponenten der Variabilität der Ausgangsdaten, gemessen als Summe der Varianzen der Ausgangsvariablen (totale Varianz), möglichst vollständig erklären können [Bac11].

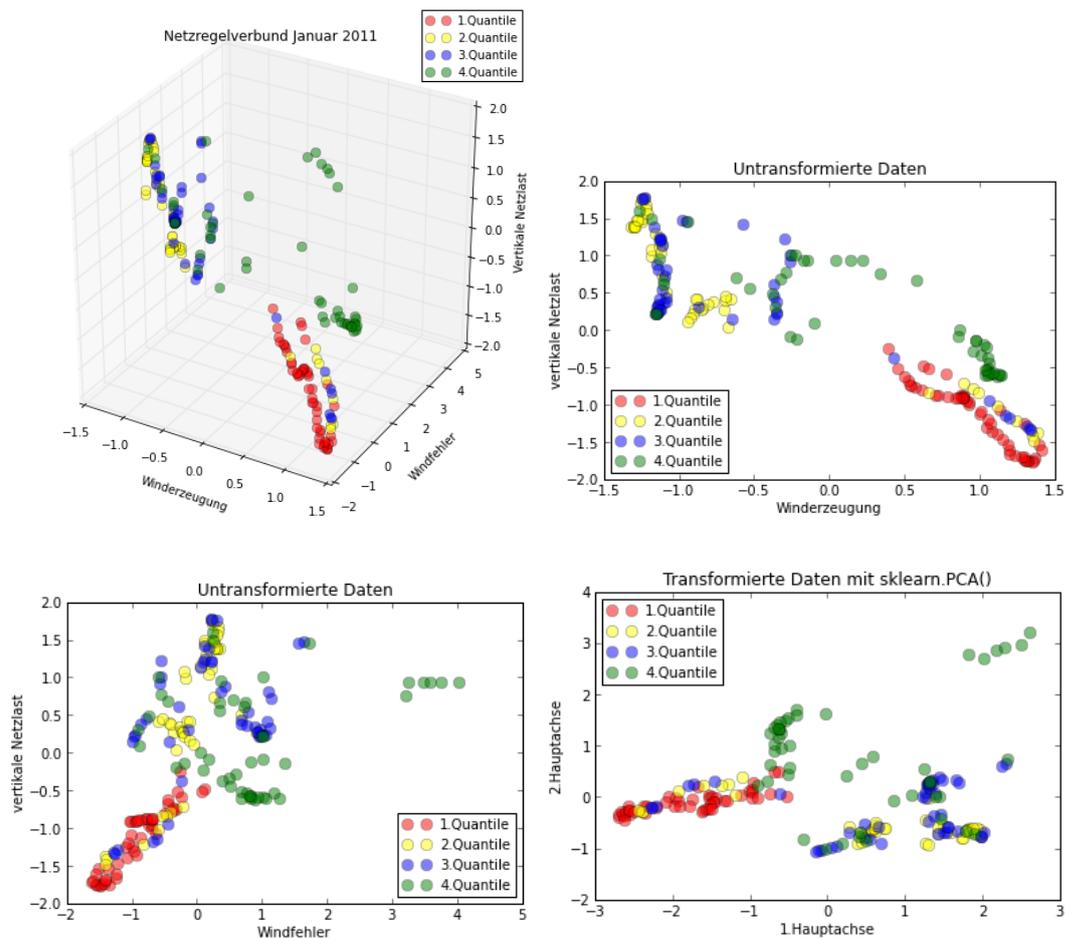


Abbildung 3.13: Transformation auf die zwei Hauptachsen mit PCA aus SKLearn

Die PCA unterteilt sich in die folgenden Unterbereiche:

- Standardisieren der Daten
- Berechnung der Korrelations bzw. Kovarianzmatrix
- Bestimmung der Eigenvektoren und Eigenwerte
- Auswahl der Eigenvektoren mit den höchsten Eigenwerten
- Transformation des Merkmalsraumes mit Hilfe der Projektionsmatrix

In Abbildung 3.13 wird die PCA beispielhaft auf 200 Datenpunkten des Jahres 2011 für den Netzregelverbund vorgeführt²⁵. Dabei wird die vorimplementierte PCA von SKlearn auf den skalierten Daten angewendet. Die obere Abbildung zeigt eine dreidimensionale Darstellung der drei betrachteten

²⁵ Die 200 Datenpunkte setzen sich jeweils aus dem ersten 50 Datenpunkten jedes Quantiles zusammen.

Merkmale (Winderzeugung, Windfehler und vertikale Netzlast). Die ersten beiden unteren Abbildungen zeigen jeweils die zweidimensionalen Ansichten. In der rechten Abbildung sind die transformierten Daten dargestellt. Die erklärten Varianzen der ersten beiden Hauptachsen sind 0,75 und 0,21, d.h. die Hauptvarianz wird bereits durch die erste Hauptachse erklärt.

Auch die PCA wurde in der Vergangenheit bereits erfolgreich in Kombination mit KNN eingesetzt [HT04]. Einen weiteren Überblick über verschiedene dynamische und adaptive Verfahren zur Gewichtung der Merkmale in Kombination mit KNN werden in [AGN] vorgestellt. In der vorliegenden Arbeit werden daher verschiedene Arten der Merkmalsgewichtung sowie die Möglichkeit der Dimensionsreduktion mit einer PCA untersucht. In Bezug auf die Merkmalsgewichtung wird sowohl die statische uniforme Gewichtung (einfacher euklidischer Abstand) untersucht, als auch die Weiterentwicklung einer dynamischen sowie adaptiven Merkmalsgewichtung.

- statische Merkmalsgewichtung:
Alle Merkmale erhalten ein uniformes Gewicht.
- dynamische Merkmalsgewichtung:
Alle Merkmale werden entsprechend ihrer relativen Merkmalsgewichte aus den entsprechenden GBT bzw. RFT gewichtet. Diese Gewichte werden dynamisch für den jeweiligen Prognosezeitpunkt angepasst.
- adaptive Gewichtung:
Die Gewichtung der Merkmale erfolgt in Abhängigkeit der stündlichen Korrelation mit der Zielvariablen, bzw. in Abhängigkeit der relativen Höhe des jeweiligen Merkmals. Dieses wird erreicht, indem die Merkmalswerte quadriert und anschließend mit ihrem stündlichen Korrelationskoeffizienten multipliziert werden.

In Abbildung 3.14 ist der Ablauf der Merkmalsauswahl noch einmal zusammenfassend dargestellt.

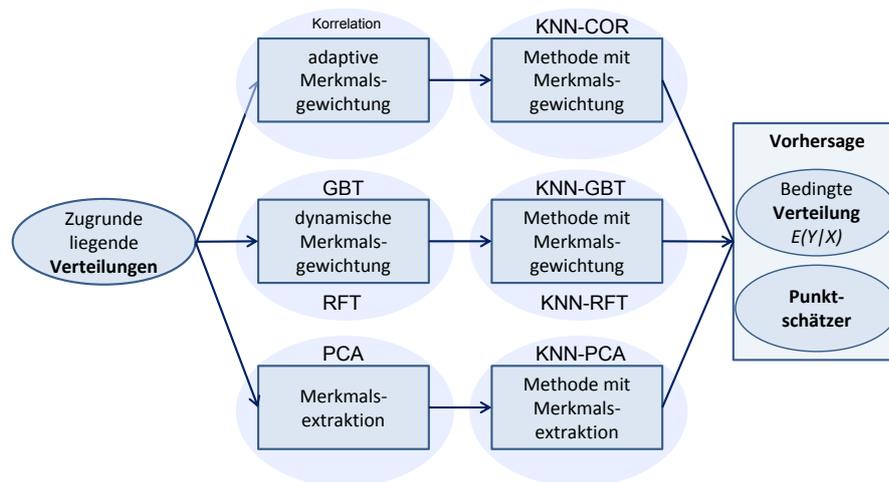


Abbildung 3.14: Merkmalsauswahl

3.3 Modellbewertung – Zielfunktion

Ziel des maschinellen Lernens ist die Optimierung der einzustellenden Parameter; dies sind sowohl die modellspezifischen Parameter als auch die Parameter des Problemdesigns wie die zuvor erläuterte Merkmalsauswahl oder das Festlegen eines geeigneten Prognosehorizontes. Um diese Parameter geeignet optimieren zu können, bedarf es einer Zielfunktion, die die Güte des Prognosemodells bewertet. Im folgenden werden daher zunächst Gütemaße für die Bewertung von Prognosen vorgestellt, bevor anschließend näher auf die Besonderheiten des hier eingeführten Toleranzbandfehlers eingegangen wird.

3.3.1 Gütemaße für die Prognose

Die Güte einer Prognose wird anhand ihrer Zuverlässigkeit (Reliabilität) und ihrer Genauigkeit (Validität) gemessen [Cro10, Seite 69]. Die Vorhersage, die mit Hilfe eines Prognosemodells getroffen wird, kann jedoch nie „genau“ sein. Es wird immer einen empirischen Prognosefehler (r) geben²⁶, den es zu minimieren gilt (siehe Kapitel 2.3.3).

$$E_{emp}(r) = r(h) = E\{||\hat{Y} - Y||\} \rightarrow \min_{h(*)} \quad (3.23)$$

Dies hängt damit zusammen, dass es sich bei der zu prognostizierenden Zielgröße um eine Zufallsvariable handelt. Diese wird neben den Einflussgrößen immer auch von unbeobachtbaren Störgrößen beeinflusst, die durch einen Störterm ϵ ausgedrückt werden. Dieser verbleibende Fehler oder auch Residuum der Regressionsfunktion entspricht im Idealfall einer Normalverteilung $\epsilon_t \sim N(0, \sigma_\epsilon^2)$ ²⁷. Er ist die erwartete Varianz der Regressionsfunktion bzw. die erwartete Quadratsumme der Residuen. Die (erwarteten) Realisationen der Zielzeitreihe (Regelsaldo) unter Annahme des Systemzustandes x_t lassen sich daher durch eine Struktur- und eine Zufälligkeitskomponente wie folgt beschreiben [Cro10]:

$$E(y_t | \mathbf{x}_t) = h(\mathbf{x}_t) + \epsilon_t \quad (3.24)$$

mit $h(\cdot)$ = Strukturkomponente und ϵ (Fehlerkomponente) im Idealfall normalverteilt.

Es verbleibt somit immer eine gewisse Unsicherheit des realen Wertes der Zielvariablen y . Diese systeminhärente Variabilität von Raum und Zeit wird auch *aleatorische Unsicherheit* genannt [Kne04]. Sie ist – im Gegensatz zur sogenannten *epistemischen Unsicherheit* – unabhängig von den Einflussgrößen bzw. dem gewählten Prognosemodell, sondern ergibt sich aus den Unsicherheiten in den Daten bzw. der Unsicherheit bezüglich des zukünftigen Zustandes des Systems [Kne04]. Abbildung 3.15 zeigt den Unterschied zwischen den beiden Unsicherheiten im Bezug auf die Prognose.

²⁶ Eine gute Schätzung des empirischen Fehlers ist der Mittelwert auf den Trainingsdaten, je nachdem wie repräsentativ diese für die Gesamtverteilung sind. Daher gilt für den ermittelten Fehler auf den Trainingsdaten $R_n(\hat{h}) = R(h) + \gamma_n(h)$. Dabei ist γ der Zero-Mean-Noise Komponent, der eine Aussage darüber liefert wie weit die Sample-Menge davon entfernt ist, die wahre Verteilung zu repräsentieren. Nach den Gesetz der großen Zahlen tendiert dieser Wert allerdings gegen Null.

²⁷ Mit Hilfe von sogenannten Residuentests auf Normalverteilung können ferner Aussagen über die Prognosegüte des Modells bzw. die Einhaltung der Annahmen getroffen werden.

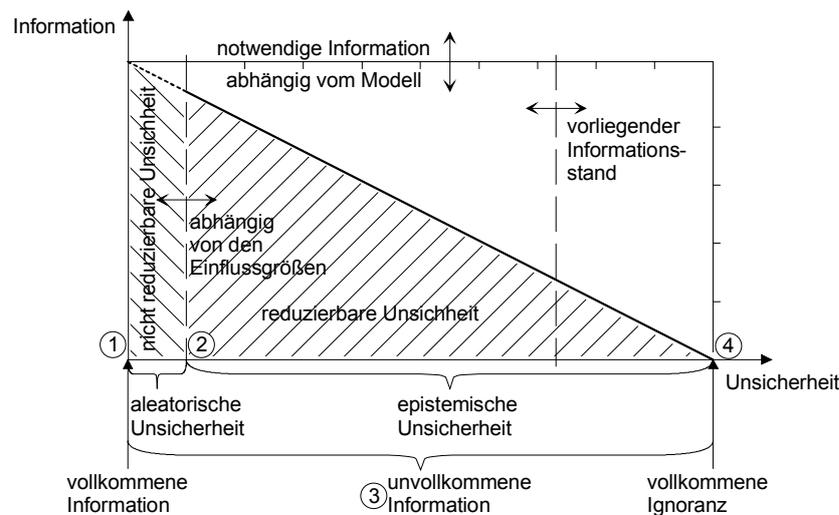


Abbildung 3.15: Zusammenhang zwischen Unsicherheit und Information [Kne04]

Das Ziel der Prognose ist daher – neben der Verbesserung der Genauigkeit – auch immer eine möglichst genaue Eingrenzung der erwarteten Werte auf ein sogenanntes Konfidenzintervall. So ist neben der Vorhersage eines einzelnen Wertes (Punktprognose) auch ein Wertebereich anzugeben (Intervallprognose) mit einer minimalen Unsicherheit bzw. einer entsprechend (maximalen) bedingten Wahrscheinlichkeit. Neben dieser *Konfidenz*, zur Bewertung der Stärke der abgeleiteten Assoziationsregeln, hat jedes Prognosemodell einen sogenannten *Support*, der Auskunft über die statistische Signifikanz der Regeln gibt [Höf04]. Dies ist von Bedeutung, da auch die Einflussgrößen Zufallsvariablen sind und damit einer Volatilität unterliegen. Die Wahrscheinlichkeit des Auftretens der einzelnen Systemvariablen unabhängig vom Wert der Zielvariablen wird auch als Randwahrscheinlichkeit oder *Evidenz* bezeichnet. Die Güte einer Prognose bzw. der Erwartungswert des Prognosefehlers hängen somit auch immer vom Zeitpunkt der Prognose, bzw. den Wahrscheinlichkeiten der einzelnen Einflussgrößen zu diesem Zeitpunkt ab. So ergibt sich der Erwartungswert des strukturellen Fehler wie folgt [Vap08] (siehe auch Integration der Erwartungswerte Formel 2.9, Seite 60):

$$E_{struc}(r) = E(E_{emp}(r)) = \int \int L(y, f(x))p(x, y)dx dy \quad (3.25)$$

Dementsprechend ist es nicht auf einfachem Wege möglich, ein allgemeines Gesetz zu modellieren, das den Zusammenhang zwischen der Wahrscheinlichkeitsverteilung der gesuchten Zielvariablen y und dem Merkmalsvektor x beschreibt. Gäbe es eine Menge von Beobachtungen zu demselben Merkmalsvektor mit unterschiedlichen Realisationen von y , so wäre es möglich, die Parameter der Verteilung über klassische Schätzmethoden direkt zu bestimmen. In den meisten Fällen liegen jedoch paarweise Datensätze $(y_t; \mathbf{x}_t)$ vor, die annähernd in einem kontinuierlichen Raum bezüglich beider Dimensionen auftreten, so dass kaum ein Merkmalsvektor x doppelt oder sogar mehrfach auftaucht [Stü03]. Dies ist – wie bereits erwähnt – eine Folge des sogenannten „Fluch der Dimensionen“ [Bel61].

Alternativ kann man jedoch mit Hilfe des KNN-Modells die k nächsten Nachbarn bestimmen und eine Wahrscheinlichkeitsverteilung über diesen Nachbarn schätzen; so erhält man für jeden System-

zustand eine Wahrscheinlichkeitsverteilung für das Eintreten bestimmter Werte der Zielvariablen. Auf diese Weise lässt sich ebenfalls eine Wahrscheinlichkeit für das Auftreten einzelner Systemzustände berechnen, indem die Dichte der Nachbarn um den gesuchten Datenpunkt berechnet wird. Ist $R_k^d(x)$ der Abstand zwischen dem gesuchten Datenpunkt und dem k -ten nächsten Nachbarn und c_D das Volumen im d -dimensionalen Merkmalsraum ergibt sich nach Bishop [Bis06] die Wahrscheinlichkeit wie folgt:

$$p(\mathbf{x}) \approx \frac{k}{NV} = \frac{k}{N c_D R_k^d(\mathbf{x})} \quad (3.26)$$

Nun kann man entweder das Volumen fixieren und die Anzahl von Punkten innerhalb bewerten, wie dies bei den sogenannten *Kernichtefunktionen* der Fall ist [GO11], oder man fixiert die Anzahl an Nachbarn und berechnet das Volumen. Dies entspricht dem Vorgehen bei KNN. Da für seltene Systemzustände die Dichte wesentlich geringer ist als für häufige Systemzustände, muss die Anzahl Nachbarn für häufige Systemzustände entsprechend größer gewählt werden. Dieses Problem steht in Zusammenhang mit der *Heteroskedetizität*²⁸, d.h. die Residuen sind in diesem Fall – ohne eine Anpassung der Modellparameter – für bestimmte Wertebereiche nicht normalverteilt²⁹. In unserem Fall hätte das zur Folge, dass nicht alle Salden gleich gut vorausgesagt werden können, bzw. die Fehler, die bei der Vorhersage gemacht werden sind nicht gleichverteilt, sondern hängen in besonderer Weise vom Zeitpunkt der Prognose ab. So ist beim Regelsaldo davon auszugehen, dass es bestimmte „Ausreißer“ bzw. Extremsituationen gibt, die schwerer zu prognostizieren sind. Normalerweise geht man in Modellen davon aus, dass die Varianz des Fehlers unabhängig vom Wert bzw. Zeitpunkt der Simulation ist.

Abbildung 3.16 zeigt beispielhaft die Verteilung der Residuen (RMSE) für KNN mit 500 Nachbarn und gleich-gewichteten Merkmalen für den NRV im Februar und April 2012³⁰. Man erkennt, dass die Residuen lediglich im Bereich großer Prognosefehler von der Normalverteilung abweichen. Dabei sind die Abweichungen im Februar und April genau entgegengesetzt. Während im Februar insbesondere große unerwartete positive Regelleistungsabrufe (hohe Prognosefehler) schlechter vorhergesagt werden, sind es im April die hohen negativen Abrufe. Auf die unerwartet hohen Abrufe im Februar war bereits in Kapitel 2.2.2 eingegangen worden. Die Verteilung der Residuen bestätigt damit die Annahme menschlich strategisch induzierten Verhaltens bei der Inanspruchnahme positiver Regelleistung, bzw. weiterer nicht direkt messbarer Einflussgrößen, die Auswirkungen auf den Abruf großer Mengen positiver Regelleistung haben. Im April wurden dagegen die Abrufe negativer Regelleistung unterschätzt, d.h. auch hier gab es Extremsituationen, die nicht prognostiziert werden konnten, bzw. deren Fehlerverteilung von der Normalverteilung abweicht. Ein weitere Analyse der Fehlerverteilung der einzelnen Modelle findet im Rahmen der Evaluation statt.

²⁸ Ein anderer oft verwendeter Begriff ist (Residuen-)Varianzheterogenität.

²⁹ Zum Erkennen derartiger Heterogenitäten verwendet man sogenannte Quantile-Plots (Q-Q-Plots) bei denen die Quantile der Verteilung gegen die einer Normalverteilung aufgetragen werden. Idealerweise ergibt sich eine Gerade.

³⁰ Die Prognosefehler sind jeweils ((IST-Wert) - Prognosewert).

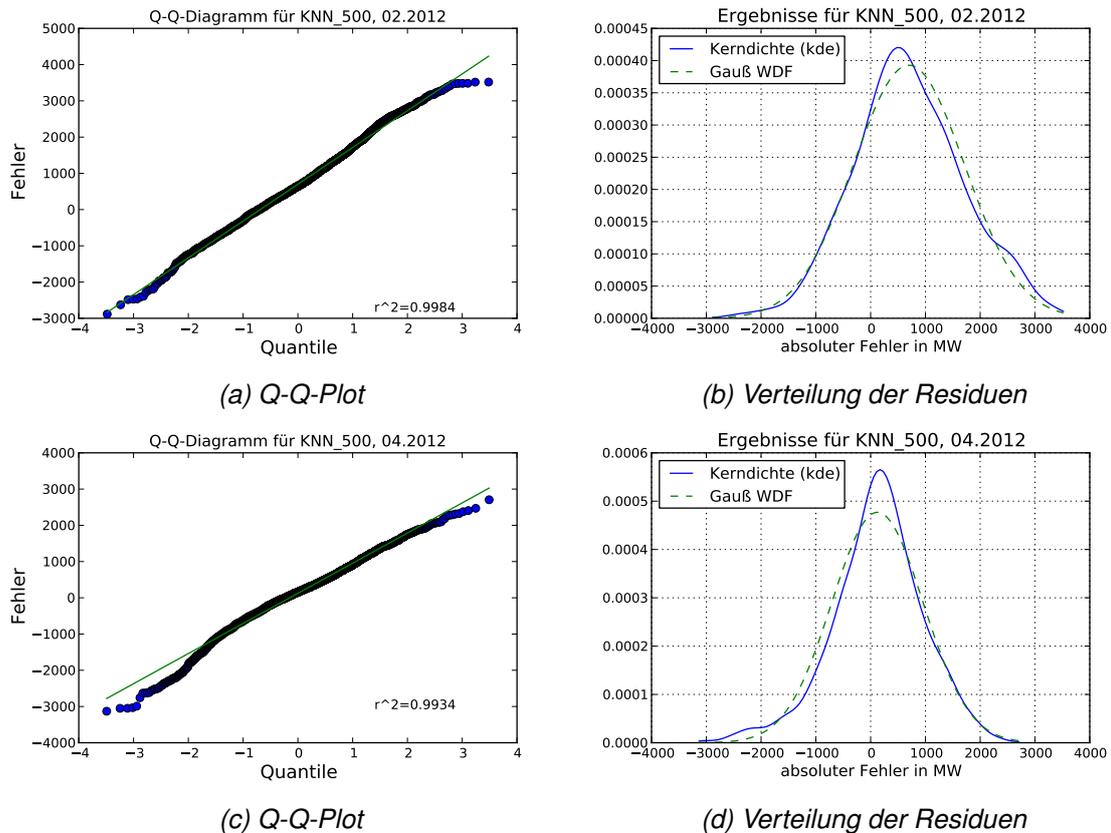


Abbildung 3.16: Verteilung der Residuen für KNN-500 im NRV 02/2012 und 04/2012

Die Punktprognose ergibt sich im Falle der KNN als gewichteter Mittelwert der k nächsten Nachbarn, wobei die jeweiligen Abstände mit ihrem Kehrwert in die Gewichtung eingehen (siehe Formel 3.3, Seite 69). Dabei sind Prognosen bzw. ihre Punktschätzer nicht kumulativ, d.h. Vorhersagen dürfen nicht addiert werden, sondern die entsprechenden Wahrscheinlichkeitsverteilungen müssen miteinander gefaltet und ein neuer Punktschätzer bestimmt werden [FK08]. In diesem Fall bedeutet dies, dass die Prognose des Regelsaldos nicht aus der Summe der Einzelprognosen der vier Regelzonen gebildet werden kann, sondern jede Regelzone – auch der Netzregelverbund (NRV) – getrennt prognostiziert werden muss. Dabei lässt sich die Abweichung der Punktprognose in Bias und Varianz aufteilen; für KNN ergibt sich die folgende Gleichung [HTF11, Seite 37, Formel 2.47]:

Bias-Varianz Aufteilung bei KNN

$$Err_{KNN}(x) = \left(f(x) - \frac{1}{k} \sum_{i=1}^k f(x_i) \right)^2 + \frac{\sigma_\epsilon^2}{k} + \sigma_\epsilon^2 \quad (3.27)$$

$$Err(x) = \text{Bias}^2 + \text{Varianz} + \text{Störterm}$$

Bei $k = 1$ wird der Bias bei einer idealen unendlichen Trainingsmenge null. Mit Zunahme der Anzahl Nachbarn steigt der Bias, während die Varianz mit Zunahme der Nachbarn abnimmt [HTF11,

Seite 37 ff.]. Dabei steigt der Bias bei Zunahme der Nachbarn abhängig von der Struktur und Verteilung des Merkmalsraumes, d.h. je – rauer der Merkmalsraum – d.h. je schneller die Werte der einzelnen Merkmale ihren Wert verändern – desto größer der Einfluss des k auf die Verzerrung der Prognose.

Während bei den KNN die Dichte der bedingten Verteilung im Anschluss an das Prognosemodell anhand der jeweiligen Nachbarn gebildet werden kann, erfolgt die Berechnung des Konfidenzintervalls bei den Gradient Boosting Trees innerhalb des Modells. So kann mit Hilfe der integrierten Zielfunktion, die über die „Reinheit“ der finalen Blätter entscheidet, die maximal zulässige prozentuale Überschreitung des Konfidenzintervalls mit Hilfe des Parameters $alpha$ eingestellt werden. Die Teilung des Baumes wird auf die Einhaltung der Konfidenzintervalle hin trainiert, die mit Hilfe der entsprechenden Quantile-Berechnung in den Blättern gebildet werden.

3.3.2 Zielfunktion des Prognosemodells

Das Ziel des zu entwickelnden Prognosemodells für den Regelsaldo bzw. der daraus abzuleitenden RL-Bemessung ist die Einhaltung des vorgegebenen Gesamtdefizitniveaus bzw. des Sicherheitsniveaus, bei gleichzeitiger Reduzierung der Vorhaltemengen. Dazu wird die potentiell monatlich durchschnittlich eingesparte Leistungsmenge in Megawatt sowie der potentiell eingesparte Leistungspreis in Euro für jeden Monat berechnet. Die einzusparende Vorhaltemenge ergibt sich, indem man die Grenzen des Konfidenzintervalls als Bemessungswerte annimmt und anschließend die Differenz zur vorgehaltenen Menge berechnet. Die Grenzen des Intervalls lassen sich aus den k nächsten Nachbarn ableiten bzw. sie werden direkt innerhalb des Modells gebildet (GBT mit Quantile-Zielfunktion). Dabei wird in diesem Modell nicht eine Verteilung über den k nächsten Nachbarn gebildet und anschließend die Quantile bestimmt, sondern als obere und untere Grenze werden jeweils der kleinste und größte Vorhersagewert innerhalb der Nachbarn gewählt. Abbildung 3.17 zeigt systematisch die Ermittlung der oberen und unteren Grenzwerte des Intervalls sowie die Berechnung des *Toleranzbandfehlers* (engl. tolerance band error TBE).

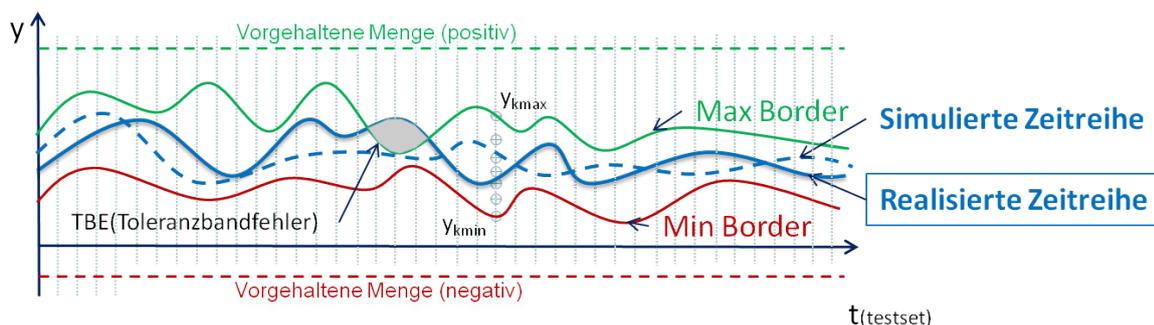


Abbildung 3.17: Toleranzbandfehler

Diese neu eingeführte Größe des Toleranzbandfehlers ist vom Keogh-Band [Keo05], [KR05] aus der Spracherkennung abgeleitet, die sich wiederum aus der dynamischen Abstandsbemessung von Zeitreihen herleitet. So handelt es sich beim sogenannten „Dynamic Time Warping“ (DTW) um ein Verfahren zur Distanzmessung zwischen zwei Zeitreihen. Im Gegensatz zur euklidischen Distanz, bei

der die Abstandsberechnung vektorisiert d.h. sequenziell erfolgt (indem jeweils der Abstand der i -ten Vektoreinträge berechnet wird), wird beim DTW dynamisch der geringste Abstand zwischen zwei Zeitreihenabschnitten ermittelt. Dies geschieht indem der kürzeste Pfad innerhalb einer Distanzmatrix mit Hilfe einer dynamischen Programmierung gesucht wird. Dabei sind die Einträge der Abstandsmatrix jeweils die Abstände zwischen zwei Datenpunkten der Zeitreihen, die maximal um die zeitliche Verzögerung k gegeneinander verschoben sind. Dabei entspricht k der Länge des Kurvenabschnitts. Auf diese Weise ist es möglich auch zeitlich gestreckte oder gedehnte Zeitabschnitte als ähnlich zu erkennen, wie dies in der Spracherkennung notwendig ist.

$$dist_{DTW}(X, Y) = \operatorname{argmin}_w \left(\sqrt{\sum_{k=1}^k w_k} \right) \quad (3.28)$$

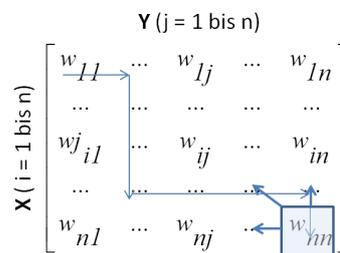


Abbildung 3.18: Berechnung der minimalen DTW-Distanz

Keogh hat nun im Jahr 2005 heraus gefunden, dass dieser Abstand immer größer sein muss, als das von ihm eingeführte Keogh Distanzmaß. Gegeben zwei Zeitreihen Q und C , ergibt sich das Keogh-Maß mit einer dynamischen Verschiebung von r wie folgt [KR05]:

$$dist_{Keogh}(Q, C) = \sqrt{\sum_{i=1}^n \begin{cases} (c_i - U_i)^2 & \text{wenn } c_i > U_i \\ (c_i - L_i)^2 & \text{wenn } c_i < L_i \\ 0, & \text{sonst} \end{cases}} \quad (3.29)$$

$$U_i = \max(q_{i-r} : q_{i+r}) = \text{Upper band} \quad \text{und} \quad L_i = \min(q_{i-r} : q_{i+r}) = \text{Lower band}$$

Dabei definiert die dynamische Verschiebung quasi einen Bereich um die gesuchte Kurve Q , indem die maximalen Werte im Bereich $(i - r : i + r)$ jeweils die obere Grenze U und die minimalen Werte jeweils die Grenze L bilden. Das Keogh-Maß zu einer beliebigen Zeitreihe C entspricht dann den schraffierten Flächen. Im vorliegenden Fall entsprechen diese schraffierte Flächen jeweils den Defizitenergiemengen zur Deckung der positiven bzw. negativen Leistungsdifferenzen über die Zeit t . Die Verschiebung r entspricht in diesem Fall dem gewählten Bemessungsintervall. Werden die RL-Mengen beispielsweise vierstündlich ausgeschrieben so ergäbe sich eine Verschiebung von +/- zwei Stunden.

³¹Abbildung aus [KR05]

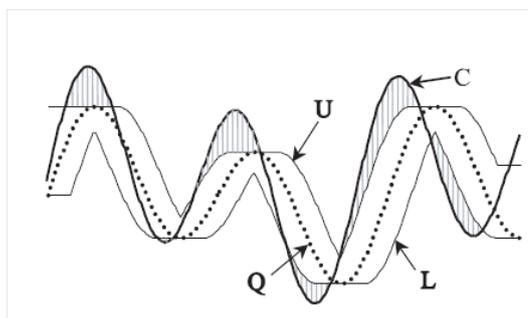


Abbildung 3.19: Berechnung des Keogh-Bandes³¹

Toleranzbandfehler - TBE:

$$TBE(y) = \sqrt{\sum_{t=1}^T \begin{cases} (y_t - U_t)^2 & \text{wenn } y_t > U_t \\ (y_t - L_t)^2 & \text{wenn } y_t < L_t \\ 0, & \text{sonst} \end{cases}} \quad (3.30)$$

$$U_t = \max(y(t-2)_{kmax} : y(t+2)_{kmax}) = \text{Upper band}$$

$$L_t = \min(y(t-2)_{kmin} : y(t+2)_{kmin}) = \text{Lower band}$$

Ziel der Modellparametrierung ist dementsprechend die Wahl eines minimalen Konfidenzintervalls, d.h. maximal eingesparten Mengen bei maximal erreichbarem Sicherheitsniveau bzw. minimalem Toleranzbandfehler.

3.3.3 Modellparametrierung

Bei der Modellparametrierung ist zwischen den modellinhärenten Parametern und den Simulationsparametern zu unterscheiden. Während erstere für die gewählten Modelle unterschiedlich sind, sind die Simulationsparameter für alle Modelle gleich. So ist neben der bereits vorgestellten Merkmalsauswahl und -gewichtung ein geeigneter Prognosehorizont sowie die Größe des Daten- bzw. Suchraums festzulegen.

Als geeignete Prognosehorizonte werden zum einen eine Stunde und zum anderen ein Tag gewählt. Der Prognosehorizont von einer Stunde orientiert sich am Gate-Closure des Intraday Marktes. Dies ist gleichzeitig der Zeitpunkt, an dem der ÜNB die Verantwortung für die Systemstabilität übernimmt. Insbesondere zur Prognose des regelzoneninternen Systemungleichgewichts ist dies somit ein geeigneter Zeitpunkt. Für die Prognose des Gesamtregelsaldos ist dagegen ein Zeitvorlauf von einem Tag zu wählen, damit eine Beschaffung der entsprechenden Mengen auf dem RL-Markt geschehen kann.

Bezüglich der Größe des Suchraums werden sowohl drei Monate als auch ein Jahr untersucht. Der „kleinere Suchraum“ ist damit saisonal eingeschränkt, während der große Suchraum den jeweiligen

Vergleichstag des Vorjahres enthält. Des Weiteren ist es durch die Wahl dieser beiden Suchraumgrößen möglich, den Einfluss der Anzahl Nachbarn in Relation zur Gesamtdatenmenge zu untersuchen. Als Anzahl Nachbarn werden dabei 100, 200 und 500 gewählt.

Diese Auswahl begründet sich auf drei Überlegungen:

- Reduzierung der Varianz:
Durch den Effekt der Aggregation lässt sich die Varianz und damit der Vorhersagefehler der Punktprognose bei der Auswahl mehrerer Nachbarn reduzieren.
- Berechnung des Konfidenzintervalls:
Zur Berechnung des Konfidenzintervalls bzw. der Annahme einer annähernden Normalverteilung muss die Anzahl Datenpunkte genügend groß gewählt werden.
- Einhaltung des Sicherheitsniveaus:
Durch eine große Anzahl Nachbarn erhöht sich die Wertespanne der Zielvariablen und damit die Breite des Konfidenzintervalls. Das Sicherheitsniveau steigt somit mit der Anzahl Nachbarn.
- Hohe Dichte für häufige Systemzustände
Aufgrund der Tatsache, dass für häufige Systemzustände eine hohe Dichte im Merkmalsraum vorliegt, muss die Anzahl Nachbarn in diesen Fällen genügend groß gewählt werden. So bringt die Wahl eines großen k bessere Vorhersagen, wenn sich die Zeitreihen der nächsten Nachbarn sehr stark ähneln.
- Orientierung am Vergleichstag:
Die gewählten Werte orientieren sich an den Zeitmerkmalen. Geht man zum Beispiel von einer maximalen Tageszeitabhängigkeit und einer Trainingsmenge von einem Jahr aus, so wäre die vermeintlich optimale Anzahl Nachbarn 365.

Bei den GBT ist die Bildung des Konfidenzintervalls im Programm integriert, dementsprechend lässt sich das angestrebte Sicherheitsniveau anhand des Modellparameters α einstellen. Im vorliegenden Fall wird dementsprechend zum einen die aktuelle Defizitwahrscheinlichkeit angesetzt und zum anderen jeweils ein größerer und ein kleinerer Vergleichswert. Als Parameter für den GBT ergeben sich damit die folgenden Werte (0,99; 0,9975; 0,9999). Darüber hinaus sind beim GBT die *Lernrate* des additiven Modells sowie die minimale Anzahl Datenpunkte an einer Abzweigung (*min sample split*) und die maximale Tiefe (*max-dep*) der einzelnen Bäume festzulegen. Eine *Grid Search* Optimierung³² hat als optimale Kombination eine Lernrate von 0,01, eine minimale Samplemenge von neun sowie eine maximale Tiefe von vier ergeben. Alle gewählten Modell- und Simulationsparameter sind noch einmal in Tabelle 3.1 zusammengefasst.

3.3.4 Modelloptimierung

Die modellinhärenten Parameter werden innerhalb der Evaluation nicht weiter optimiert, sondern es werden jeweils drei Parametereinstellungen für jedes Modell evaluiert. Für die modellunabhängigen Parameter erfolgt eine „One Factor at Time“-Analyse, d.h. eine Sensitivitätsanalyse bei der jeweils die

³² Darunter versteht man eine Methode, bei der die Kombinationen der einzelnen Parametereinstellungen stufenweise auf einem Raster (Grid) durchprobiert werden.

	KNN	GBT
Prognosehorizont	1 Stunde; 1 Tag	1 Stunde; 1 Tag
Trainingsmenge	3 Monate; 12 Monate	3 Monate; 12 Monate
Anzahl Nachbarn	100; 200; 500	/
Sicherheitsniveau	/	0,99; 0,9975; 0,9999
Lernrate	/	0,01
min. Anzahl Samples/Knoten	/	9
max. Baumtiefe	/	4

Tabelle 3.1: Modellparametrierung

Einstellungen eines einzelnen Parameters geändert werden. Dabei ist davon auszugehen, dass beide Modelle unterschiedlich auf die Parametereinstellungen reagieren werden. So gibt es nach dem "No Free Lunch Theorem" [WM97] nicht den einen überlegenen Algorithmus, sondern insbesondere bei heuristischen Algorithmen konnte gezeigt werden, dass gemittelt über alle möglichen Probleme alle Algorithmen gleich gut bzw. gleich schlecht sind [Wei99]. So ist davon auszugehen, dass nicht ein Algorithmus mit einer bestimmten Parametereinstellung für alle Regelzonen und Prognosezeitpunkte überlegen sein wird. Insbesondere bei großen Suchraumdimensionen besteht die Gefahr, dass es viele lokale Maxima gibt.

Während die Optimierung zur Erreichung der Zielfunktionen bei den GBT durch Gradientenabstiegsverfahren innerhalb des Modells geschieht, muss die Optimierung der KNN außerhalb des eigentlichen Modells geschehen. Dabei gibt es bereits zahlreiche Ansätze, die sich mit einer Verbesserung des KNN Ansatzes beschäftigen, wobei es vielfach um die Adaptivität des Ansatzes geht. Insbesondere wenn die Verteilung der Samples nicht bekannt ist, ist eine einheitliche Parametrierung häufig nicht sinnvoll. So kann es z.B. sinnvoll sein, die Distanzmetrik adaptiv zu gestalten, indem sich der unterschiedlichen Verteilung der Zielvariablen im Merkmalsraum bedient wird. So kann es sein, dass in einigen Bereichen, bei denen die Zielvariable sehr gleichverteilt ist, ein euklidischer Abstand mit gleichgewichteten Merkmalen bessere Ergebnisse erzielt, während insbesondere an den Grenzen des Datenraums eine gewichtete Distanz zu wählen ist. Für die Regression hat unter anderem Guerre mit seinem „Design Adaptive Nearest Neighbor Regression Estimation“ [Gue00] einen Ansatz für ein derart adaptives KNN vorgestellt. Weitere ähnliche Ansätze, die sich mit der optimalen Parametrierung insbesondere am Datenraumrand befassen lieferten Hastie und Tibshirani mit ihrer „Discriminant Adaptive Nearest Neighbor Classification“, [HT04] sowie Domeniconi „Locally adaptive metric nearest-neighbor classification“, [DPG01]. Eine Optimierung des KNN-Ansatzes lässt sich in dreierlei Hinsicht erreichen:

- Optimierung der Modellparameter
- Optimierung der Merkmale
- Optimierung der Metrik

Dabei kann lassen sich die einzelnen Optimierungen meist nicht strikt voneinander trennen, sondern sie bedingen sich gegenseitig. So ist die Merkmalsgewichtung eine Anpassung der euklidischen

Distanzmetrik und auch eine Anpassung der Anzahl der Nachbarn ist im Grunde eine Anpassung des Radius der euklidischen Distanz. In dieser Arbeit erfolgt insbesondere die Merkmalsgewichtung adaptiv, indem sowohl die Merkmalsgewichte aus dem GBT, die Korrelationen mit der Zielvariablen als auch die relative Höhe der Merkmalsausprägungen mit in die Gewichtung einfließen.

3.4 Implementierung

Die Implementierung des Prognosemodells erfolgt in der objektorientierten Programmiersprache *python*. Diese Wahl ist damit begründet, dass sie zum einen mit dem Paket *pandas* (**Panel Daten Analyse**) die automatisierte Datenanalyse und -aufbereitung unterstützt (siehe Kapitel 2.2.1) und zum anderen gibt es mit der Bibliothek *scikit-learn* [www.scikit-learn.org] bereits eine Vielzahl vorimplementierter Programmpakete für das maschinelle Lernen. Der implementierte allgemeine Programmablauf ist in Abbildung 3.20 dargestellt.

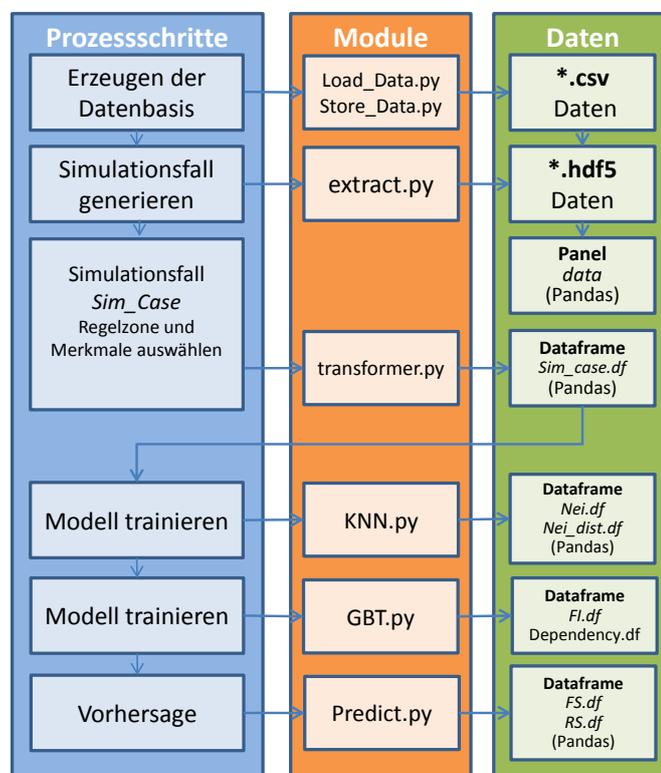


Abbildung 3.20: Programmablauf

Zunächst erfolgt in einem gesonderten Programm die Bildung der Datenbasis, indem mit dem Programm *Load_Data.py* die benötigten *.csv-Dateien aus dem Internet³³ heruntergeladen und anschließend nach der Aufbereitung mit Hilfe des Programms *Store_Data.py* als *.hdf5-Dateien gespeichert werden. Mit dem eigentlichen Programmaufruf werden diese *.hdf5-Daten dann mit Hilfe des Programms *extract.py* in ein Panel geladen. Mit dem Programm *transformer.py* wird anschließend die

³³ www.regelleistung.net

Prognoseumgebung bzw. der Simulationsfall – „Sim_Case“ – festgelegt. Darin werden neben der Regelzone, dem zeitlichen Startpunkt und dem Ende der Simulation auch die zu prognostizierende Zielvariable festgelegt. So ist theoretisch neben dem Regelsaldo auch die Prognose des Abrufs von Sekundärregelleistung oder Minutenreserve möglich. Anschließend wird der Datentyp, der vorhergesagt werden soll definiert. Dabei stehen außer dem Typ *value*; also der Vorhersage einer reellen Zahl, noch zwei weitere Typen (*class* oder *sign*) zur Verfügung. Beim Typ *class* werden vier Klassen (null bis drei) gebildet, die die Zielgröße anhand ihrer Quantile in vier Bereiche aufteilen. Beim Typ *sign* wird die Zielvariable in drei Werte unterteilt, je nachdem ob sie einen positiven, negativen Wert oder Null annimmt. Des Weiteren erfolgt eine Festlegung der zu betrachtenden Merkmale – durch die Initiierung der Variablen *Features_select* – sowie des Prognosehorizontes *pred_hor*. Anschließend werden die Merkmale entsprechend den Simulationseinstellungen vorverarbeitet.

Python bietet für die Datenvorverarbeitung sogenannte *Estimator Klassen*. Diese Klassen haben den Vorteil, dass sie die Methoden *fit()* und *fittransform()* beinhalten, wodurch die Möglichkeit besteht, die Dataframes des Panels sowohl als geschlossenes Objekt als auch getrennt in einzelne Unterbereiche zu transformieren. Diese Transformation geschieht im Programm als Teil einer sogenannten *Pipeline*, d.h. die einzelnen Vorverarbeitungsschritte werden automatisiert sequentiell aufgerufen und ausgeführt. In dem Programm *Transformer.py* sind die einzelnen Transformationsmöglichkeiten für den Dataframe zusammengestellt. So wird der *Dataframe* nach Merkmalstypen sortiert und anhand der angegebenen Parameter für den Vorhersagehorizont *pred_hor*, das Maß der Verzögerung *lag*, sowie des Labeltyps werden zum einen der Merkmalsdataframe *X* sowie die Zielzeitreihe in Form einer Labeltimeseries *Y* erzeugt. Der Merkmalstyp (Future, Lag, Time) legt dabei die Art der Wertegenerierung sowie die Art der Skalierung/Normung fest. Im *Pipeline* Schritt *Weighting* erfolgt anschließend die Gewichtung der einzelnen Merkmale.

Anschließend kann mit dem Methodenaufruf *fit()* der ausgewählte Lernalgorithmus auf den Trainingsdatensatz (*X_train*, *y_train*) trainiert werden, bevor abschließend die Prognose mit der Methode *predict(X_test)* erfolgt. Dabei ist es zum Beispiel entscheidend, dass die Vorverarbeitung des Testdataframes *X_test* auf gleiche Weise erfolgt wie der Trainingsdataframes *X_train*, d.h. zum Beispiel die Skalierung auf dem gleichen Datenraum stattfindet. Die *Pipeline*, bzw. die Methode *predict()* berücksichtigen dies.

Als vorimplementierte Methoden aus der *Sk-Learn* Bibliothek wurden dabei die folgenden Algorithmen benutzt; für den GBT wurde der *GradientBoostingRegressor()* gewählt für RFT der *ExtraTreesRegressor()* und für KNN der *KNeighborsRegressor()*

Als Resultat einer Simulation bzw. eines Programmaufrufs ergeben sich sechs Dataframes:

- Fehlerstatistik (*FS*):
Die Fehlerstatistik enthält die nach Monaten aggregierten Prognosefehler jeweils für einen Modelaufruf. Dabei werden sowohl der Toleranzbandfehler (TBE), der RMSE, sowie die Defizitwahrscheinlichkeiten berechnet. Und zwar jeweils auf den Trainingsmengen (Mittelwert der Kreuzvalidierung) und auf der Testmenge.
- Ergebnisdataframe (*RS*):
Der Ergebnisdataframe entspricht dem Testdataframe (*X_test*) ergänzt um die Ergebnisspalten der einzelnen Modelle.

- Relative Merkmalsrelevanz (*FI*):
Der Dataframe der Feature Importance enthält die monatlichen relativen Merkmalsgewichte, die in den GBT und RFT ermittelt werden.
- Auswertung der Nachbarn (*Nei und Nei_dist*):
Die beiden Dataframes enthalten je getestetem Zeitintervall jeweils die Zielvariablenwerte bzw. den jeweiligen Abstand zum gesuchten Datenvektor aller k nächsten Nachbarn.

Tabelle 3.2 zeigt beispielhaft die Fehlerstatistik für den Januar 2013. Dabei entspricht der Wert (*Test_Score*) dem RMSE auf den Testdaten in [MW], in diesem Fall dem Monat Januar, *Max_Test_Error* ist die maximale absolute Abweichung der Punktprognose in [MW], der *TBE_Max* und *TBE_Min* sind die jeweiligen positiven bzw. negativen Defizitmengen in [MWh], wobei ein Ausschreibungsintervall von einer Stunde zugrunde gelegt wurde. Die *Int_max* und *Int_min* geben jeweils die absolute Anzahl Intervalle an, an denen die Konfidenzintervallgrenzen über- bzw. unterschritten wurden. Und daraus berechnen sich entsprechend die Defizitwahrscheinlichkeiten *PU* (upper) und *PL* (lower). Die Werte *PU4* und *PL4* sind die entsprechenden Defizitwahrscheinlichkeiten für ein Ausschreibungsintervall von vier Stunden.

3.5 Zusammenfassung

Das Ziel dieses Kapitels war die Vorstellung des entwickelten Prognosemodells. Dazu wurden in Kapitel 3.1 zunächst die Grundlagen des Prognoseprozesses auf Basis des maschinellen Lernens vorgestellt. Diese nicht parametrische Art der Modellierung war aufgrund der Komplexität des betrachteten Systems sowie der zeitlichen Variabilität der Einflussfaktoren in Kapitel 2 festgelegt worden. Dazu wurden sowohl das Vorgehensmodell des maschinellen Lernens als auch die ausgewählten Algorithmen, der k -nächsten-Nachbarn (KNN) und der Gradient Boosting Trees (GBT) vorgestellt. Die folgenden Unterkapitel orientierten sich an den einzelnen Prozessschritten des Vorgehensmodells. So wurde in 3.2 die Merkmalsgenerierung vorgestellt und in 3.3 die verwendete Zielfunktion. In diesem Zusammenhang wurde sowohl die verwendete Größe des Toleranzbandfehlers eingeführt als auch die Parametereinstellung der Modelle festgelegt. Diese sind in Tabelle 3.1 (Seite 97) zusammenfassend dargestellt. Abschließend wurde in 3.4 die Implementierung vorgestellt.

Methode	Test_Score	Max_Test_Error	TBE_Max	TBE_Min	Int_max	Int_min	PU	PL	PU4	PL4
GBT_0,99	821.34	4549.06	320.94	-1459.93	1	56	0.000	0.019	0.000	0.014
GBT_0,9975	822.46	4549.06	539.49	-1661.53	5	23	0.002	0.008	0.000	0.005
GBT_0,9999	821.91	4549.06	0.00	-436.48	0	6	0.000	0.002	0.000	0.002
KNN_GBT_100	784.53	4496.23	58.10	-2078.36	1	43	0.000	0.014	0.000	0.003
KNN_GBT_200	784.12	4523.44	0.00	-1092.61	0	29	0.000	0.010	0.000	0.001
KNN_GBT_500	791.28	4532.76	0.00	-1092.61	0	12	0.000	0.004	0.000	0.001
KNN_100	777.37	4477.68	93.12	-2078.36	1	48	0.000	0.016	0.000	0.005
KNN_200	777.79	4451.10	58.10	-2078.36	1	28	0.000	0.009	0.000	0.002
KNN_500	786.98	4480.26	0.00	-1092.61	0	11	0.000	0.004	0.000	0.001
KNN_RFT_100	784.71	4482.44	58.10	-2078.36	1	49	0.000	0.016	0.000	0.005
KNN_RFT_200	785.14	4506.33	0.00	-1848.72	0	25	0.000	0.008	0.000	0.002
KNN_RFT_500	791.66	4530.83	0.00	-1092.61	0	12	0.000	0.004	0.000	0.001
KNN_PCA_100	779.37	4504.65	1176.72	-2330.91	16	51	0.005	0.017	0.003	0.004
KNN_PCA_200	778.44	4472.25	705.95	-1835.99	7	22	0.002	0.007	0.002	0.003
KNN_PCA_500	786.23	4486.33	634.36	-863.95	5	5	0.002	0.002	0.001	0.001
Persistenz	851.19	4158.97	0.00	-338.62	0	4	0.000	0.001	0.000	0.001

Tabelle 3.2: Fehlerstatistik Sim_Start: 2013-01-31 00:00:00+01:00 Sim_Ende: 2013-01-31 23:45:00+01:00

4 Evaluation

4.1 Evaluationsszenarien

Für die Evaluation werden verschiedene Simulationsszenarien gerechnet. Ein Simulationsszenario (SIM-CASE) ist dabei durch die Vorauswahl bezüglich der folgenden verschiedenen Parameter definiert :

- **Regelzone:** Zur Auswahl stehen die vier deutschen Regelzonen Amprion, Tennet, 50 Hertz sowie TransnetBW und der Netzregelverbund (NRV) als gemeinsame Summe.
- **Simulationsjahr:** Insgesamt stehen Daten für die Jahre 2011 bis 2013 zur Verfügung, so dass bei einer Trainingsmenge von bis zu zwölf Monaten die Jahre 2012 und 2013 simuliert werden können.
- **Prognosehorizont:** Untersucht wird die tägliche und die stündliche Prognose. Die One-Day-Ahead Prognose hat damit einen Prognosehorizont von 96 Intervallen und die One-Hour-Ahead Prognose einen Prognosehorizont von vier Intervallen.
- **Trainingsmonate:** Die Trainingsmenge wird jeweils dynamisch vom zu berechnenden Monat ausgewählt, d.h. für den Simulationsmonat Mai 2013 werden als Trainingsmonate die Monate ab dem April 2013 gewählt. Als Alternativgrößen werden jeweils drei Monate und zwölf Monate gewählt¹.
- **Merkmalsauswahl:** Insgesamt stehen elf Merkmale zur Verfügung; sieben vektorielle Zeitreihenmerkmale und vier skalare Zeitmerkmale.
 - Zeitreihenmerkmale: Regelsaldo (RS), Windeinspeisung (WindE), Windfehler (Wind_Err), PV-Einspeisung (PVE), PV-Fehler (PV_Err), Vertikale Netzlast (VNLast), Phelix Base Preis an der EEX (PHB)².
 - Zeitmerkmale: Monat (Mo) [1,..,12], Wochentag (weekday) [0,1,..,6], Tageszeit (TOD) [0,..,23], Anfangsviertelstunde (BOH) [0,1].

Für diese elf Merkmale besteht die Möglichkeit alle Kombinationen unterschiedlicher Anzahl Merkmale zu berechnen, eine zufällige Auswahl zu treffen oder eine feste Kombination vorzugeben. In der Simulation werden jeweils sieben und elf Merkmale gegenüber gestellt und alternativ die Möglichkeit untersucht, wenn man die Wind- und PV-Fehler durch die Prognosewerte ersetzt.

- **Merkmalsvorverarbeitung:** Für jede Zeitreihenvariable stehen drei weitere Merkmale zur Verfügung: die jeweilige stündliche, tägliche, und wöchentliche Korrelation mit der Zielvariablen. Für die Zwecke der Simulation wird nur die stündliche Korrelation betrachtet. Wird die Merkmalsvorverarbeitung (COR) ausgewählt, so wird der Wert jeder Zeitreihenvariablen mit dem Betrag der jeweiligen stündlichen Korrelation mit der Zielvariablen multipliziert. Im Falle einer perfekten Korrelation (sowohl positiv als auch negativ) erhält das Merkmal somit das Maximalgewicht von

¹ Aufgrund der Datenverschiebung zum Beispiel bei der Berechnung der Korrelation wird zur Vermeidung zu vieler ungültiger Werte im Jahr 2012 nur mit einer Trainingsmenge von elf Monaten gerechnet.

² Für das Jahr 2013 stehen die PHB Daten nur bis Mai zur Verfügung, so dass dieses Merkmal für die Simulation des Jahres 2013 nicht verwendet wird und sich dementsprechend nur zehn bzw. sechs Merkmale ergeben.

eins. Des Weiteren wird getestet, wie sich eine Gewichtung extremer Merkmalswerte auswirkt. Dazu werden alle Merkmalswerte mit ihrem Betrag multipliziert, so dass – ähnlich dem quadratischen Fehler – größere Werte ein stärkeres Gewicht erhalten. Diese ist mit DW (engl. double weight) bezeichnet.

- **Verzögerungswerte:** Für die Zeitreihenmerkmale (Features-Future und Features-Lag) besteht die Möglichkeit mehrere Werte der Zeitreihe in den Merkmalsvektor aufzunehmen. Für die Simulation werden nur die Fälle mit einem Wert pro Zeitmerkmal ($\text{lag}[0]$) und jeweils zwei Werten pro Merkmal ($\text{lag}[0,1]$) untersucht.

Die theoretisch möglichen Simulationsszenarien sind in Abbildung 4.1 noch einmal zusammenfassend dargestellt. Es ergeben sich somit je Regelzone und Simulationsjahr 72 verschiedene Szenarien.

Regelzone	Merkmalsvorverarbeitung	Merkmalsgenerierung	Merkmalsauswahl	Jahr	Trainingsmonate	Prognosehorizont
Amprion Tennet 50Hertz TransnetBW Summe(NRV)	Ohne Korrelation	Nur ein Wert	Alle 11 Merkmale	2012	3 Monate	96 (1 Tag)
	Mit Korrelation gewichtet		7 Merkmale (ohne Feat_Time)			
	Mit Korrelation und DW gewichtet	Zwei Werte je Zeitreihe Lag = [0,1]	8 Merkmale (ohne EE-Fehler)	2013	12 Monate	4 (1 Stunde)

Abbildung 4.1: Parameterfestlegung für einen Simulationsfall SIM-CASE für die Evaluation

Innerhalb dieser Simulationszenarien werden die Methoden KNN und GBT jeweils mit unterschiedlichen Parameterbelegungen berechnet, so dass in jedem Simulationsaufruf jeweils 15 Methodenaufrufe durchgeführt und entsprechend für jede Methodenbelegung die Punktprognose, die Intervalle und die Fehlerauswertung berechnet werden. Insgesamt ergeben sich somit für jeden Prognosehorizont 1.080 unterschiedliche Prognosen für jedes Zeitintervall. Aufgrund der hohen Anzahl möglicher Simulationsfälle werden daher nur ausgewählte Fälle simuliert und anhand einer Sensitivitätsanalyse die Parameterbelegung analysiert. In Abbildung 4.2 ist beispielhaft der erste Simulationsaufruf dargestellt. Dabei werden folgende Methodenparameter gewählt:

- **Merkmalsparameter:** Die Merkmalsparametrierung erfolgt gemäß Tabelle 3.1 (siehe Seite 98). Für die KNN folgt entsprechend für die Anzahlen an Nachbarn (100,200,500) und für die GBT wird der Parameter alpha wie folgt belegt (0.99,0.9975,0.9999).
- **Merkmalsgewichtung:** Es besteht für das Verfahren des KNN zudem die Möglichkeit, die Merkmale unterschiedlich zu gewichten bzw. eine Vorauswahl zu treffen (siehe auch Abbildung 3.14):
 - Uniform - Einheitsgewichtung (KNN): Alle Merkmale haben ein Gewicht von eins.
 - Gewichtung mit GBT (KNN-GBT): Gewichtung mit den relativen Merkmalsgewichten (Feature Importance FI) wie sie der jeweilige Gradient Boosting Tree ermittelt hat.
 - Gewichtung mit RFT (KNN-RFT): Gewichtung mit den relativen Merkmalsgewichten (Feature Importance FI) wie sie der jeweilige Random Forest ermittelt hat.

- **Filter (PCA):** Es wird eine Hauptkomponententransformation vorgenommen, indem die Anzahl Merkmale jeweils um zwei reduziert wird, d.h. im Fall von sechs Merkmalen wird auf die vier Hauptkomponenten transformiert.

Verfahren	Merkmals- vorverarbeitung	Merkmals- generierung	Merkmals- auswahl	Filter	Merkmals- gewichtung	Parameter	Name
KNN	Ohne Korrelation	Nur ein Wert	Alle 11 Merkmale [Saldo, WindE, Wind_Err, PVE, PV_Err, Netzlast, PHB, month, weekday, TOD,BOH]	ohne PCA	Uniform	K = 100	KNN_100
						K = 200	KNN_200
						K = 500	KNN_500
					GBT	K = 100	KNN_GBT_100
						K = 200	KNN_GBT_200
						K = 500	KNN_GBT_500
					RFT	K = 100	KNN_RFT_100
						K = 200	KNN_RFT_200
						K = 500	KNN_RFT_500
				mit PCA 6 Merkmale	Uniform	K = 100	KNN_PCA_100
K = 200	KNN_PCA_200						
K = 500	KNN_PCA_500						
GBT	Ohne Korrelation	Nur ein Wert	Alle 11 Merkmale	/	/	Alpha = 0.99	GBT_0.99
						Alpha = 0.9975	GBT_0.9975
						Alpha = 0.9999	GBT_0.9999

Abbildung 4.2: Beispiel Simulationscase

Für die Bewertung der Ergebnisse werden verschiedene Zielfunktionen, die in Kapitel 3.3.2 vorgestellt wurden, verwendet. Für den Punktschätzer wird der RMSE betrachtet. Dieser wird mit den Ergebnissen der Persistenz verglichen. Für die Einhaltung der Grenzen wird die Defizitwahrscheinlichkeit (obere Grenze) bzw. die Überschusswahrscheinlichkeit (untere Grenze) berechnet, welche mit den vorgegebenen Werten von derzeit 0,025 % verglichen werden. Für die dritte Zielfunktion, die Minimierung der vorzuhaltenden Mengen, wird sowohl die einzusparende Regelleistungsmenge in [MW] ermittelt, als auch die einzusparenden Kosten. Dazu werden die mittleren Leistungspreise für die Regelleistungsbereitstellung angesetzt. Diese Ergebnisse werden zum einen mit den theoretisch realisierbaren Mengen (d.h. aus der empirischen Datenanalyse), als auch mit den Ergebnissen der DESIRE-Studie³ [Buc14], die ebenfalls eine tägliche Regelleistungsbemessung untersucht haben, verglichen. Um diesen Vergleich vornehmen zu können, wird daher der Netzregelverbund (NRV) und das Simulationsjahr 2013 gewählt. Für die einzelnen Regelzonen werden exemplarisch Simulationsergebnisse vorgestellt. Hierbei liegt das Hauptaugenmerk nicht auf einer optimalen Parameter-einstellung bzw. der Anwendung der Methode auf die Regelleistungsbemessung, sondern vielmehr in der Ableitung von Ursache-Wirkungs-Zusammenhängen zwischen einzelnen Einflussgrößen und dem Regelzonensaldo bzw. dem Aufzeigen von Unterschieden zwischen den einzelnen Regelzonen.

³ Der Titel der Studie lautet „Marktdesign für zukunftsfähige Elektrizitätsmärkte unter besonderer Berücksichtigung der vermehrten Einspeisung von erneuerbaren Energien“.

4.2 Ergebnisse für den Netzregelverbund

4.2.1 Ergebnisse für KNN

Im Folgenden werden die Ergebnisse für den Netzregelverbund für die Vortagesprognose (One-Day-Ahead) dargestellt und besprochen. Dabei wird zunächst nach den Methoden zwischen den Ergebnissen für die k-Nächsten-Nachbarn (KNN) und die Gradient Boostung Trees (GBT) unterschieden. Die Darstellung und Auswertung der Ergebnisse ist wie folgt strukturiert. Zunächst werden die Ergebnisse für KNN vorgestellt und anschließend die der GBT, dabei wird zunächst keine Merkmalsgewichtung oder -vorverarbeitung vorgenommen und die Anzahl der Nachbarn wird auf $k = 100$ bzw. $alpha = 0.99$ gesetzt. Anschließend werden die einzelnen Parametereinstellungen wie folgt untersucht:

- **Beispielsergebnisse:**
Sieben Zeitreihenmerkmale (RS, WindE, Wind_Err, PVE, PV_Err, VNetzlast und PHB) und drei Trainingsmonaten mit $k = 100$ (Abbildung 4.3) bzw. $alpha = 0.99$ (Abbildung 4.16)
- **Änderung der Merkmalsauswahl:**
Hinzunahme der Zeitmerkmale (month, weekday, TOD und BOH) und Beibehaltung der drei Trainingsmonate, d.h. elf Merkmale anstatt sieben Merkmale (Abbildung 4.6, 4.17)
- **Änderung der Trainingsmonate:**
Erhöhung von drei Trainingsmonaten auf zwölf Trainingsmonate unter Beibehaltung von sieben Merkmalen (Abbildungen 4.7, 4.18)
- **Änderung der Anzahl Nachbarn:**
Erhöhung von 100 auf 500 Nachbarn bzw. von $alpha = 0.99$ auf $alpha = 0.9999$ jeweils für drei bzw. zwölf Trainingsmonate unter Beibehaltung von sieben Merkmalen (Abbildungen 4.8, 4.19)
- **Änderung der Merkmalsgewichtung:**
Merkmalsgewichtung mit den Merkmalsgewichten aus den Trees (KNN_GBT, KNN_RFT) bzw. Hinzunahme der „Principal Component Analysis“ (KNN_PCA) (Abbildung 4.10)
- **Änderung der Merkmalsvorverarbeitung:**
Hinzunahme der Korrelation (COR) und der Doppelgewichtung (DW) (Abbildungen 4.11, 4.20)
- **Änderung der Merkmalszusammensetzung:**
Berücksichtigung der Wind- und PV-Prognose anstatt des Wind- und PV-Fehlers und der Wind- und PV-Einspeisung (Abbildungen 4.13, 4.21)
- **Änderung der Merkmalsgenerierung:**
Erhöhung der Anzahl Werte pro Zeitreihenmerkmal auf zwei, d.h. Änderung des Verzögerungswertes auf $lag[0,1]$ (Abbildung 4.14)
- **Änderung des Prognosehorizonts:**
Änderung des Prognosehorizonts von einem Tag (96) auf eine Stunde (4) (Abbildung 4.15)

Abschließend erfolgt eine tabellarische Auswertung der Ergebnisse der betrachteten Szenarien jeweils für das Jahr 2013⁴. In Abbildung 4.3 sind zwei Beispielmonate aus dem Jahr 2012 dargestellt, links zeigt das Ergebnis für einen Wintertag (1. März) und rechts für einen Sommertag (1. Juli). Die mittlere durchgezogene Linie zeigt jeweils den Punktschätzer des Prognosemodells während der an diesem Tag tatsächlich realisierte Regelsaldo – zum Vergleich – gestrichelt dargestellt ist. Zur Bildung dieses Punktschätzers wurden die Beiträge der Nachbarn entsprechend ihrer Distanz gewichtet. Neben der möglichst guten Übereinstimmung des Punktschätzers mit der realisierten Kurve ist für die Performanz des Prognosemodells die möglichst genaue Bemessung der Vorhaltungsmengen bzw. die Wahrung des geforderten Sicherheitsniveaus entscheidend. Dazu wurde neben dem Punktschätzer für jede Methode auch ein Konfidenzintervall (weiß dargestellt) berechnet, das die Bandbreite der zu erwartenden Regelsalden repräsentiert. Dazu wurde für die KNN jeweils der Nachbar mit dem Minimal- bzw. Maximalwert gesucht. Diese Werte ergeben die obere und untere durchgezogene Linie (min/max border). Die gestrichelten Linien am oberen und unteren Rand entsprechen den aktuell vorgehaltenen Gesamtgelleistungsmengen (positiv 3.821 MW, negativ -4.272 MW)⁵. Eingefärbt sind jeweils die Einsparpotentiale, würde man die obere und untere Grenze als neuen Bemessungsmaßstab für die vorzuhaltenden Mengen verwenden. Voraussetzung dafür wäre, dass der realisierte Saldo innerhalb des von den Grenzen aufgespannten Intervalls verbleibt, bzw. dieses nur in 0,025 % der Fälle⁶ überschreitet.

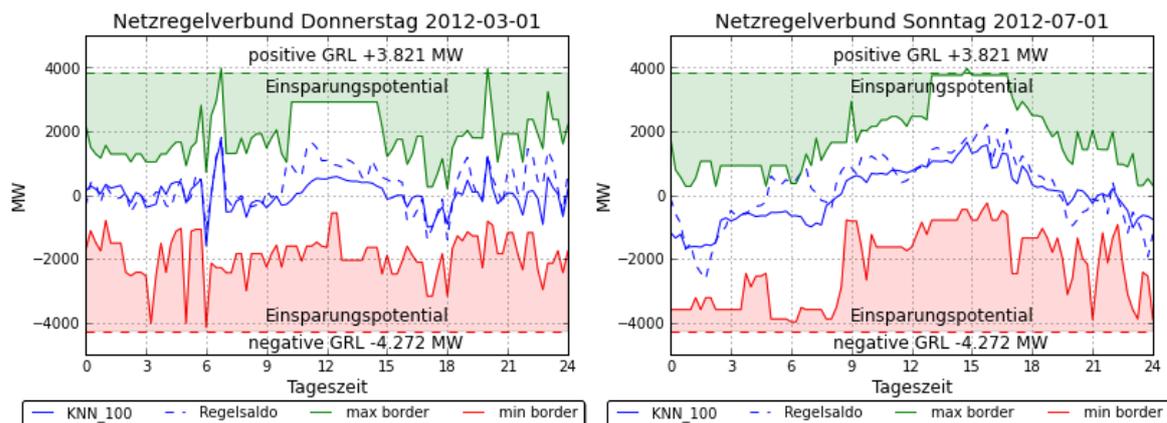


Abbildung 4.3: **Beispielergebnisse** für KNN-100 mit 7 Merkmalen und 3 Trainingsmonaten

Man erkennt, dass an den zwei Beispieltagen der Punktschätzer die realisierte Kurve gut wiedergibt. Insbesondere die Fahrplansprünge in den Morgen- und Abendstunden im März konnten gut nachgebildet werden, wobei die relativ hohe Saldodifferenz um 6:00 Uhr besonders gut prognostiziert werden konnte. Diese Auffälligkeit der großen Saldodifferenz um diese Uhrzeit wurde bereits in Kapitel 2 bei der Auswertung des Regelsaldos beobachtet und geht auf die starken Abweichungen in der vertikalen Netzlast zurück. Im Sommer fallen diese Fahrplansprünge nicht derart ins Gewicht, hier überwiegen die Prognosefehler, insbesondere aus der PV-Einspeisung. Der Saldo steigt daher in den Mittagsstunden, in denen die Einspeisung aus PV und damit das Risiko einer hohen Abweichung

⁴ Zur Demonstration zeigen die folgenden Abbildungen teilweise auch Ergebnisse für das Jahr 2012.

⁵ Dies entspricht jeweils der Summe aus SRL und MRL, im Jahr 2013 wurden entsprechend 4.583 MW und -4.641 MW angesetzt.

⁶ Dies entspricht dem aktuellen Defizitniveau.

am höchsten ist. Abbildung 4.4 zeigt die mittlere absolute Abweichung (MAD) des Regelsaldos vom Mittelwert jeweils überlagert mit dem MAD des PV-Fehlers bzw. der vertikalen Netzlast⁷.

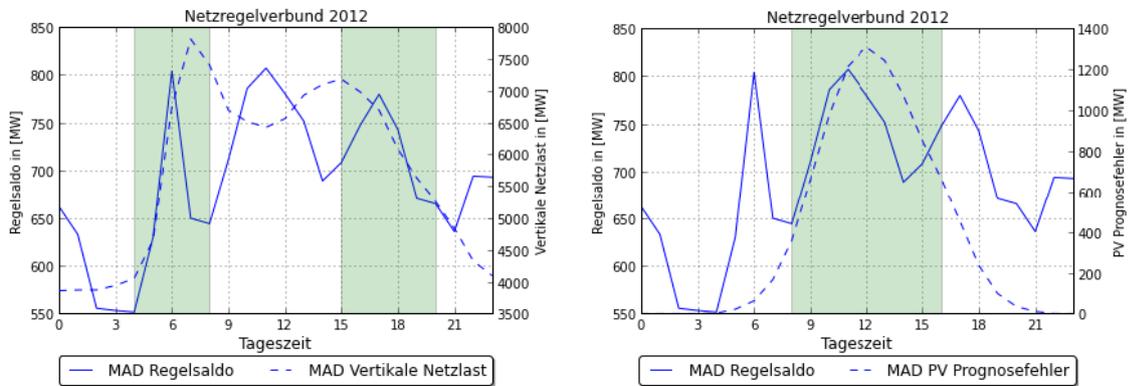


Abbildung 4.4: MAD des Saldos und der Vertikalen Netzlast bzw. des PV-Fehlers

Deutlich zu erkennen ist der morgendliche Peak um 06:00 Uhr sowohl im MAD des Regelsaldos wie auch im MAD der vertikalen Netzlast; d.h. die Varianz ist in beiden Kurven um diese Uhrzeit relativ hoch, während sie zuvor zwischen 02:00 Uhr und 04:00 Uhr ihren Minimalwert hatte. Diese extremen Schwankungen im Regelsaldo lassen sich auch am Beispieltag im März wiederfinden. Des Weiteren ist ein deutlicher Anstieg der mittleren Abweichungen zwischen 09:00 Uhr und 12:00 Uhr zu erkennen, sowie deren deutlicher Zusammenhang mit dem MAD des PV-Fehlers. Es ist daher davon auszugehen, dass der Anstieg des Saldo am 01.07. zwischen diesen Stunden auch eine Kombination aus dem erhöhten PV-Fehler sowie der ansteigenden Netzlast sein wird. Der Abfall des Saldo zwischen 16:00 Uhr und 18:00 Uhr ist ebenso auf die abfallende Netzlast zurückzuführen, da die MAD-Kurven in Abbildung 4.4 in diesen Stunden ebenfalls überein stimmen. Auffällig ist, dass der PV-Fehler scheinbar hauptsächlich einen Anstieg des Saldos zur Folge hat, d.h. sich positive PV-Fehler stärker auswirken zu scheinen als Negative. Dieses wird anhand einer partiellen Abhängigkeitsanalyse zwischen den Merkmalen mit Hilfe der GBT bestätigt. Die Ergebnisse sind in Abbildung 4.5 dargestellt.

Links ist die partielle Abhängigkeit des Regelsaldos vom Windfehler dargestellt und rechts die des Regelsaldos vom PV-Fehler. Die vertikalen Linien auf der x-Achse markieren jeweils die Perzentile der Verteilung der EE-Fehler. So lässt sich zum Beispiel ablesen, dass in ca. 15 % der Zeit ein negativer Windfehler kleiner als - 800 MW aufgetreten ist. Beim PV-Fehler entsteht eine Häufung der Perzentile um den Nullpunkt, da die Nachtstunden in der Auswertung mit berücksichtigt wurden. Vergleicht man nun die beiden Abbildungen, so ist auffällig, dass es zwar in beiden Fällen eine nahezu lineare Abhängigkeit zwischen den EE-Fehlern und dem Regelsaldo gibt, diese sich jedoch im Fall des PV-Fehlers auf den positiven Fehler beschränkt, bzw. dort wesentlich ausgeprägter ist. So ist die Steigung beim Windfehler im gesamten Bereich nahezu konstant, während die Steigung beim PV-Fehler im negativen Bereich wesentlich flacher ausfällt. Dafür ist die Kurve im positiven Bereich in etwa doppelt so steil wie beim Windfehler. So hat eine Veränderung im Windfehler um + 800 MW einen Anstieg des Saldos um ca. 300 MW zur Folge, während die gleiche Veränderung

⁷ Der MAD (engl. mean absolute deviation) wurde dabei gemittelt über die Uhrzeiten des Jahres 2012.

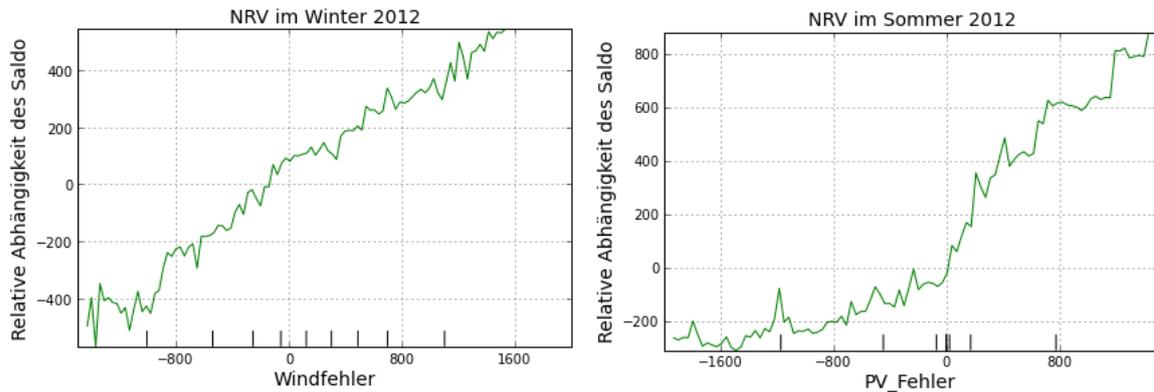


Abbildung 4.5: Partielle Abhängigkeit des Regelsaldos von den Prognosefehlern (NRV)

beim PV-Fehler einen Anstieg des Saldos um ca. 600 MW zur Folge hat. Dies spricht dafür, dass plötzliche Einspeisungsdefizite bei der PV-Einspeisung zum Beispiel durch Wolkenfelder oder Hochnebel schwerer kurzfristig zu prognostizieren und damit am Intradaymarkt abzufedern sind, als positive Windfehler, und sich damit stärker im Regelsaldo widerspiegeln. Bei den Windfehlern sind im Gegenteil hohe negative Abweichungen in Zeiten schwacher Netzlast problematisch. So ist der starke Abfall des Saldos am 01.07.2012 nachts zwischen 00:00 Uhr und 03:00 Uhr auf einen plötzlichen Anstieg der Windeinspeisung d.h. eines plötzlich hohen negativen Windfehlers in der Regelzone von 50 Hertz zurückzuführen. Dieses ist in Abbildung 4.40 erkennbar (siehe Kapitel 4.3.). Dennoch blieb der realisierte Wert – durch die ausgleichende Wirkung des NRV – innerhalb des prognostizierten Konfidenzintervalls.

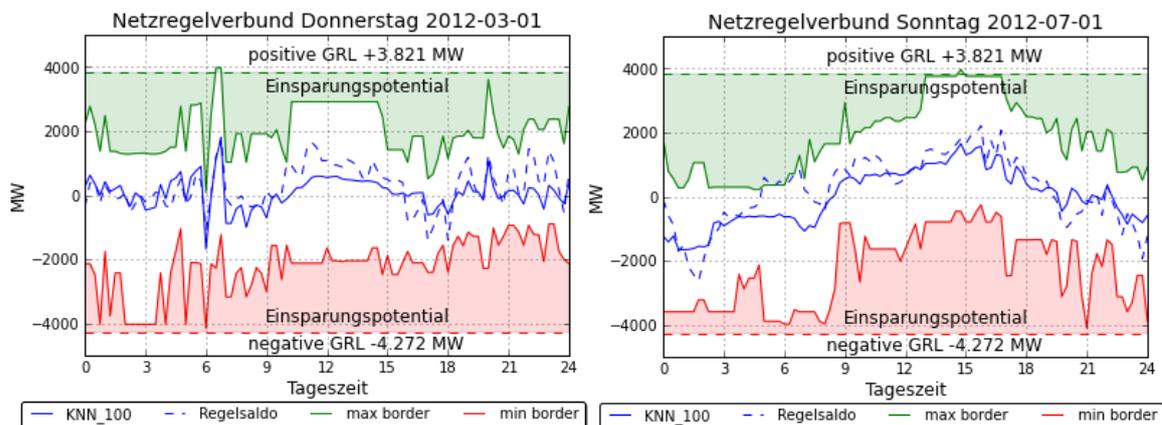


Abbildung 4.6: **Änderung der Merkmalsauswahl:** Ergebnisse für KNN-100 mit 11 Merkmalen und 3 Trainingsmonaten

So lässt sich für die Beispieltage feststellen, dass keine Grenzverletzungen eingetreten wären. Im Juli hätte der realisierte Saldo um 6:00 Uhr allerdings die obere Grenze tangiert. Inwieweit die Zeitmerkmale hilfreich bei der Prognose bzw. Einhaltung der Grenzen sind, zeigt die Abbildung 4.6; hier

wurden Zeitmerkmale wie Monat, Wochentag, Tageszeit und „Begin of Hour“ hinzu genommen. Es ist zu erkennen, dass sich die Punktschätzer nur marginal unterscheiden und auch die Grenzverläufe sich nur in Feinheiten unterscheiden. So liegt die untere Grenze im März in den Nachtstunden zwischen 0:00 Uhr und 6:00 Uhr bei Berücksichtigung der Zeitmerkmale tiefer, wodurch sich das Konfidenzintervall verbreitert, während dies zwischen 18:00 Uhr und 24:00 Uhr genau umgekehrt der Fall ist. Im Bezug auf die obere Grenze ist auffällig, dass in Abbildung 4.6 um 7:00 Uhr die obere Grenze die vorgehaltenen Menge übersteigt, d.h. hier hätte theoretisch mehr Regelleistung vorgehalten werden müssen. Im Juli sind die beiden Abbildungen nahezu identisch, hier lässt sich nur zwischen 0:00 Uhr und 6:00 Uhr ein Unterschied in der oberen Grenze erkennen, was dazu geführt hätte, dass im Falle von elf Merkmalen die obere Grenze verletzt worden wäre; um 6:00 Uhr war der realisierte Saldo höher als die ausgewiesene obere Grenze. Im Bezug auf die Grenzverletzungen hat somit die Zunahme der Zeitmerkmale alleine keine Verbesserung gebracht. Dieses lässt sich jedoch verbessern, wenn die Menge der Trainingsmonate und damit der Samples vergrößert wird. So wurde in Kapitel 3 bereits ausführlich dargestellt, dass eine Zunahme der Merkmalsdimension eine größere Samplemenge erfordert. Zur Beurteilung der einzelnen Parameter wird die Anzahl Merkmale jedoch zunächst wieder auf sieben reduziert. Abbildung 4.7 zeigt die Ergebnisse wenn statt der bisherigen drei Trainingsmonate zwölf Trainingsmonate verwendet werden.

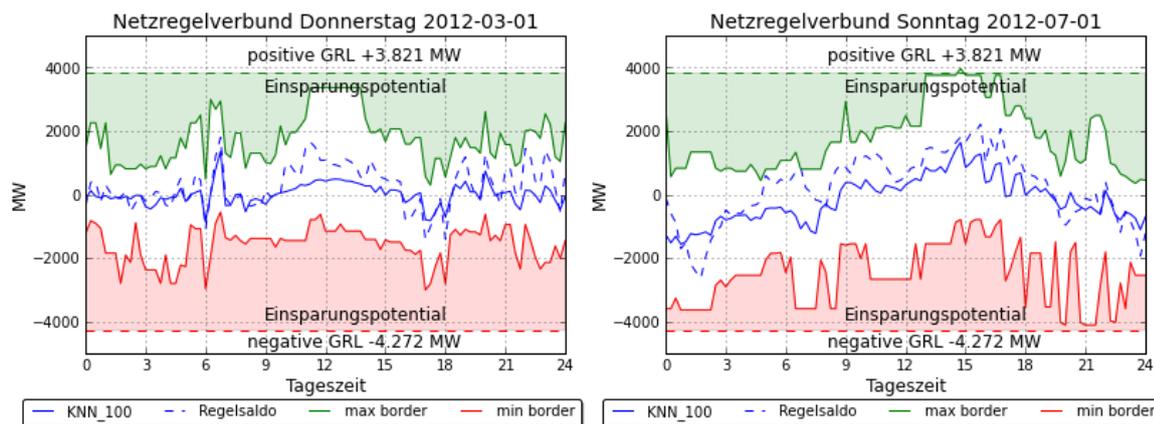


Abbildung 4.7: **Änderung der Trainingsmonate: Ergebnisse für KNN-100 mit 7 Merkmalen und 12 Trainingsmonaten**

Man erkennt, dass die Konfidenzintervalle in beiden Fällen schmaler werden. Dies liegt insbesondere an der unteren Grenze; so sind beispielsweise im März keine wesentlichen Ausbrüche mehr über die Marke von -2000 MW zu erkennen, abgesehen von den negativen Peaks des realisierten Saldos um 06:00 Uhr und um 18:00 Uhr, die weiterhin erkannt werden. Ansonsten zeichnet die untere Grenze ein wesentlich „ruhigeres“ Bild. Die Unterschiede in der Anzahl der Trainingsmonate wird noch deutlicher, wenn man die Anzahl an Nachbarn erhöht, dazu sind in Abbildung 4.8 die Ergebnisse für drei Trainingsmonate auf der linken Seite und für zwölf Trainingsmonate auf der rechten Seite gegenübergestellt.

In Bezug auf die Erhöhung der Anzahl an Nachbarn (in Abbildung 4.8 jeweils von oben nach unten) erkennt man zwei wesentliche Dinge. Zum einen vergrößert sich das Konfidenzintervall und zum anderen verliert der Punktschätzer an Varianz, was sich zum einen an den Spitzen um 06:00 Uhr und

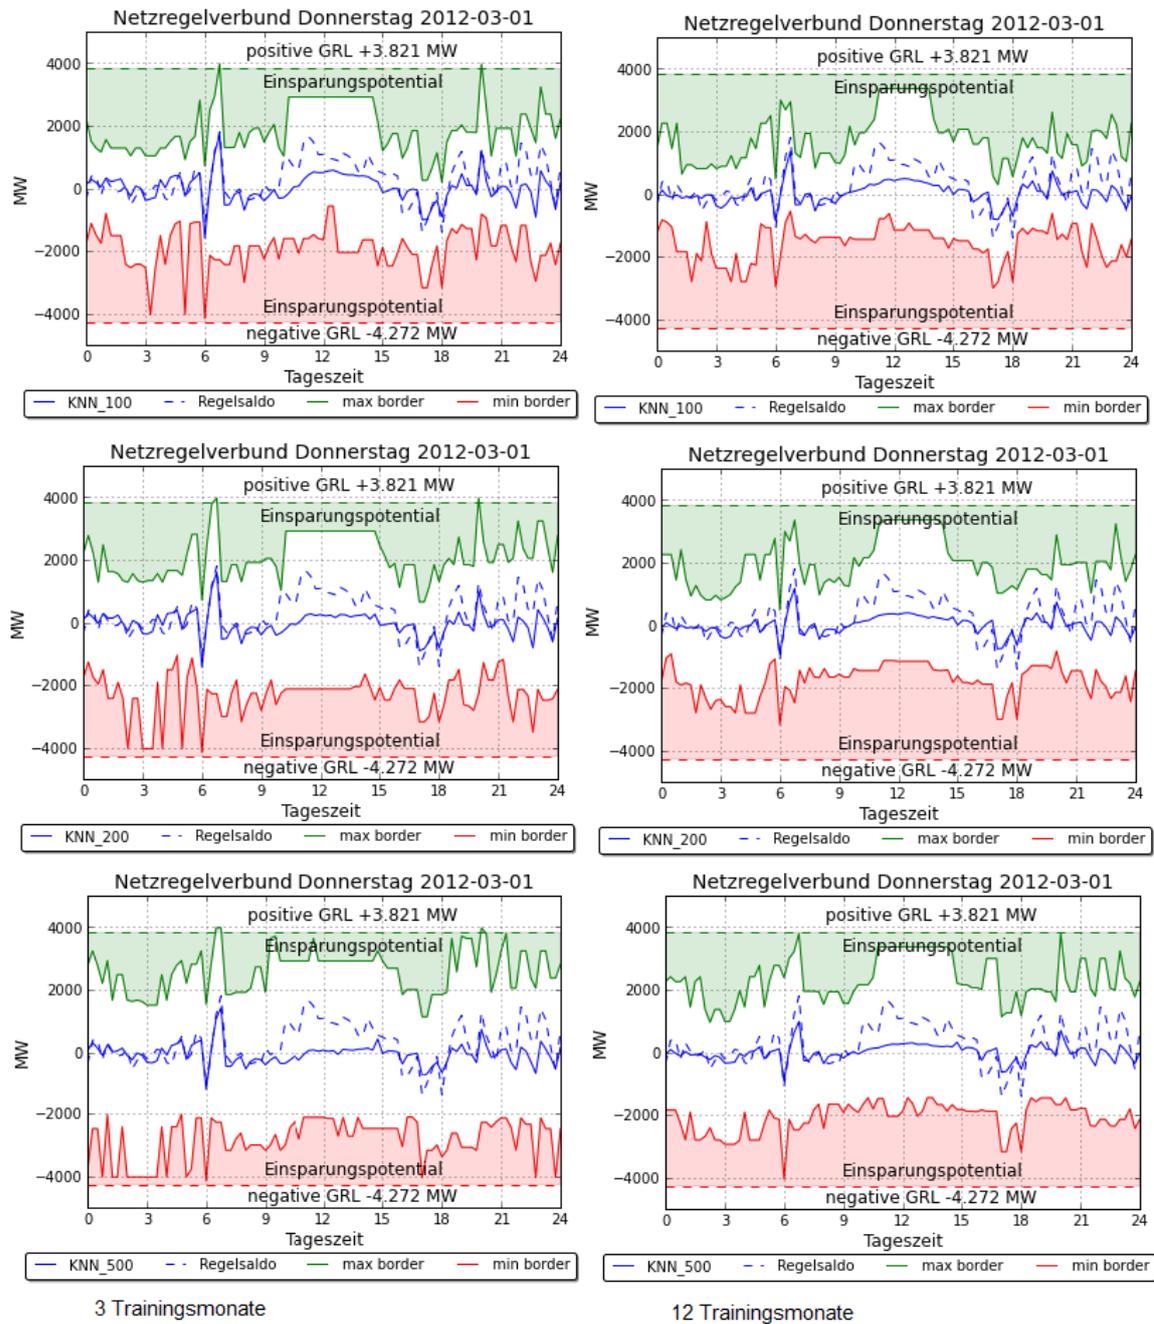


Abbildung 4.8: **Änderung der Anzahl Nachbarn:** Ergebnisse für den 01.03.2012 für KNN mit 7 Merkmalen und unterschiedlicher Anzahl Nachbarn (100,200,500)

20:00 Uhr und zum anderen an der Kurve in der Mittagszeit feststellen lässt. Diese ist bei 100 Nachbarn wesentlich ausgeprägter und erreicht Werte bis + 800 MW, während sie sich bei 500 Nachbarn im Bereich des Nullpunktes bewegt. Dies liegt daran, dass der Punktschätzer nun das gewichtete Mittel einer größeren Anzahl an Samples darstellt. Dieses Verhalten entspricht damit den Erwartungen, d.h.

es ist für das gewählte Modell der KNN sowohl davon auszugehen, dass sich die Varianz der Einzelwerte mit zunehmendem Radius (d.h. Erhöhung der Anzahl Nachbarn) vergrößert, als auch, dass der gewichtete Mittelwert eine geringere Varianz erhält. Somit steigt der Bias, d.h. die Verschiebung des Punktschätzers vom realisierten Wert mit Zunahme des k , während die Varianz des erwarteten Fehlers mit zunehmendem k sinkt. Dies ist der Fall, weil die Varianz der Labelwerte mit zunehmendem k steigt. Die Kurve des Punktschätzers nähert sich mit zunehmendem k dem Mittelwert an⁸. Diese Tatsache spricht dafür, dass KNN mit dem gewählten Distanzmaß auf das vorliegende Problem angewendet werden kann. So lässt sich daraus schließen, dass Nachbarn mit geringerem Abstand auch ähnlichere Realisationen des Regelsaldo haben, als Nachbarn mit größerem Abstand. Dies ist eine Annahme, die alle nicht parametrischen Methoden zwingend voraus setzen.

In Bezug auf die Vergrößerung der Trainingsmenge wäre dementsprechend davon auszugehen, dass sich die Varianz der Labelwerte mit steigender Anzahl an Samplen reduziert, während sich die Varianz zwischen den Abstandswerten der Nachbarn erhöht. Und genau dieses Verhalten lässt sich ebenfalls in Abbildung 4.8 beobachten. So zeigt ein Vergleich der linken mit der rechten Bildhälfte deutlich, dass das Konfidenzintervall bei zwölf Trainingsmonaten nicht in dem Maße an Breite zunimmt, wie es noch bei drei Trainingsmonaten der Fall war. Dies liegt an der Tatsache, dass die Wahrscheinlichkeit ähnlichere Nachbarn (d.h. mit geringeren Abständen) zu finden mit der Anzahl an Samples steigt. Diese Tatsache führt jedoch nicht zwangsläufig dazu, dass auch die zugehörigen Label näher an der gesuchten Zielgröße liegen, auch wenn das Postulat vom maschinellen Lernen dieses Verhalten unterstellt (siehe Seite 65). In unserem Fall wird diese These jedoch bestätigt; die Methode ist in der Lage, die ähnlichsten Nachbarn zu finden, wobei diese ähnlichen Systemzustände (Feature-Vektoren) in der Folge auch zu ähnlichen Labeln (Regelsalden) führen.

Abbildung 4.9 zeigt die Auswirkungen der Größe der Trainingsmenge auf die Abstände der Nachbarn und die Verteilung des Regelsaldos. Links dargestellt ist der Fall mit drei Trainingsmonaten und rechts mit zwölf Trainingsmonaten. In der mittleren Ebene dargestellt sind die 100 nächsten Nachbarn eines beispielhaften Datenpunktes (09.01.2013 19:15 Uhr). Auf der x-Achse ist der jeweilige Wert ihres Labels (Regelsaldo in [MW]) abgetragen und auf der y-Achse ihr absoluter Abstandswert zum gesuchten Merkmalsvektor. Man erkennt, dass sich die Unterschiede, d.h. die Varianz zwischen den Abstandswerten mit Zunahme der Trainingsmenge erhöht, während gleichzeitig ihr absoluter Wert um mehr als ein Drittel sinkt. Entscheidend für die Bemessung ist jedoch die Tatsache, dass im gleichen Maß auch die Varianz zwischen ihren Labelwerten (Regelsalden) abnimmt. Idealerweise ergibt sich die Form eines nach unten verjüngenden Trichters, d.h. die Nachbarn mit geringerem Abstand sollten auch eine geringere Differenz ihres Labels zum gesuchten Label haben. Um dies beurteilen zu können ist der vorhergesagte Punktschätzer als dunkel (grün) eingefärbter Punkt eingetragen und der realisierte Wert in diesem Zeitintervall in hell (gelb). Auch hier ist zu erkennen, dass im rechten Fall mit zwölf Trainingsmonaten eine bessere Übereinstimmung erreicht werden konnte. Dies ist auch in der unteren Zeichnungsebene erkennbar. Hier sind die Vorhersagewerte des KNN_100 Modells als senkrechte gepunktete magentafarbene Linien dargestellt, während die realisierten Werte als senkrechte durchgezogene magentafarbene Linien dargestellt sind. In der rechten Abbildung liegen diese Linien nahezu übereinander. Die einzelnen Realisationen der 100 Nachbarn sind als graue Kreuze auf der x-Achse dargestellt, im Hintergrund ist das sich ergebene Histogramm eingezeichnet und als durchgezogene blaue Linie ist die Kerndichtevertelung (engl. kernel density estimation (kde)) eingetragen. Um diese Verteilung mit einer Normalverteilung vergleichen zu können, wurde

⁸ Für die Zerlegung des Erwartungswertes des Prognosefehlers in Bias und Varianz für KNN siehe Kapitel 3.5. Fehlermaße für die Prognose.

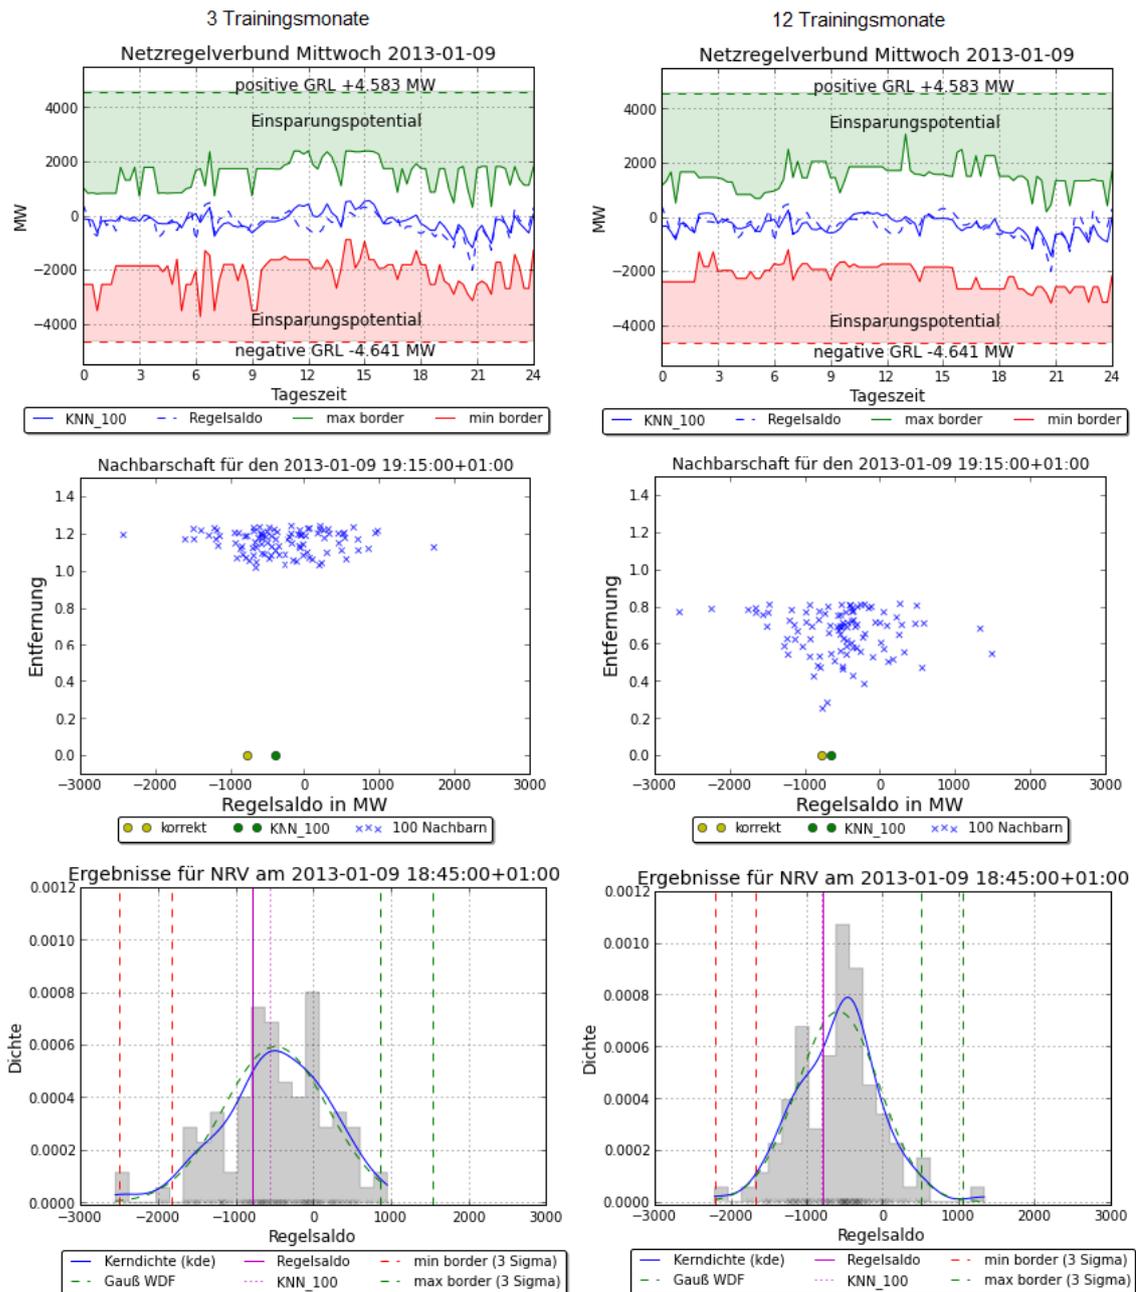


Abbildung 4.9: Nachbarn bei KNN-100 mit 10 Merkmalen ohne Korrelation

eine Gaußverteilung zwischen den Extremwerten der 100 Nachbarn gefittet (gestrichelte Linie). Es ist zu erkennen, dass sich die Verteilung in beiden Fällen der Gaußverteilung annähert und dass die Verteilung im rechten Fall wesentlich steiler verläuft, d.h. die Varianz deutlich geringer ist. Zur Verdeutlichung sind vertikal jeweils die zwei bzw. drei σ Werte als gestrichelte Linien eingetragen. Die Varianz des Regelsaldos lässt sich mit Kenntnis des Systemzustandes somit einschränken und damit

die Menge an Regelleistung verringern; eine Erweiterung des Trainingshorizontes hat dabei einen positiven Einfluss.

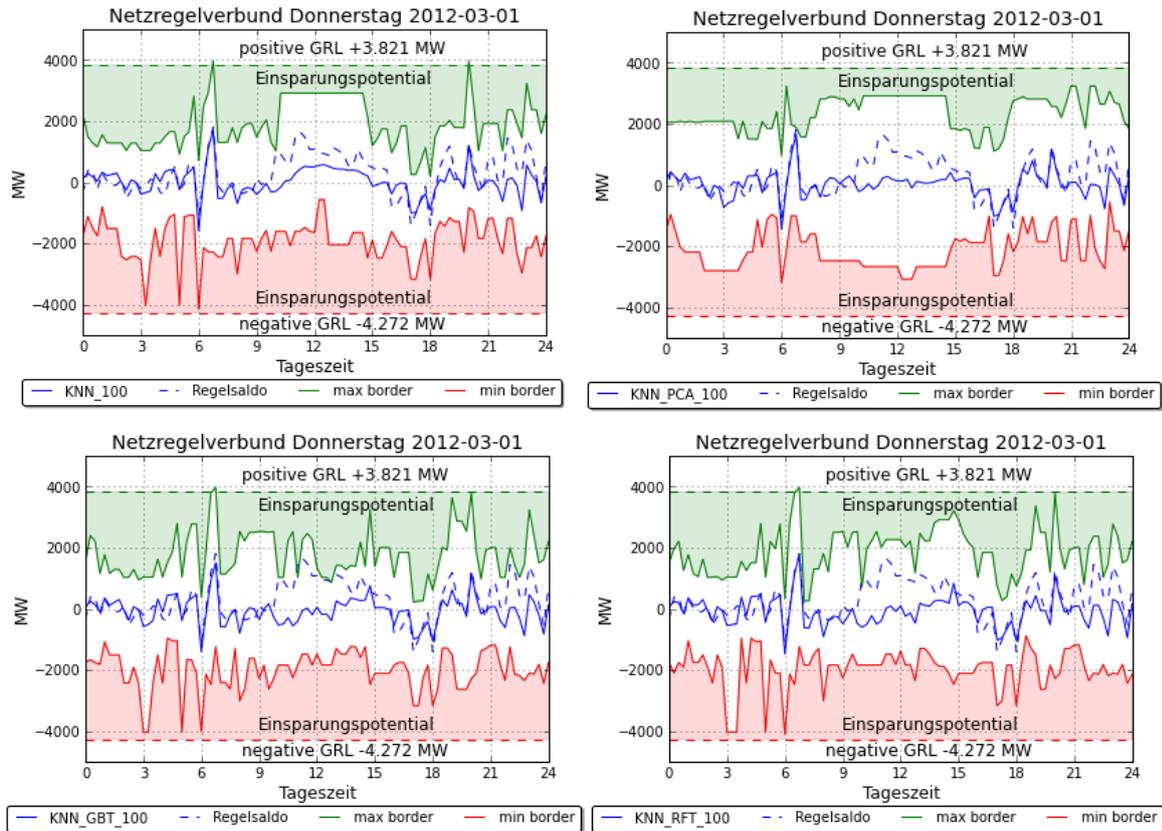


Abbildung 4.10: Änderung der Merkmalsgewichtung: Ergebnisse für KNN-100 mit 7 Merkmalen und 3 Trainingsmonaten sowie unterschiedlichen Merkmalsgewichtungen

In der Abbildung 4.10 wird untersucht, wie sich die Ergebnisse ändern, wenn die Merkmale unterschiedlich gewichtet werden, bzw. mit einer PCA auf vier Hauptachsen reduziert werden. Die Anzahl Nachbarn bleibt mit $k = 100$ konstant und es wurde zu Vergleichszwecken erneut der März betrachtet. Man erkennt, dass sich die gewichteten Punktschätzer (unten) untereinander nur marginal unterscheiden, im Vergleich zu der gleichgewichteten KNN-Methode (oben links) sind allerdings Unterschiede zu erkennen. So kann der Anstieg des Regelsaldos um 12:00 Uhr von den gewichteten Schätzern nicht abgebildet werden. Die Fahrplansprünge, insbesondere der Sprung um 6:00 Uhr, können jedoch von allen Methoden wiedergegeben werden. Die Sprünge abends werden von den gewichteten Methoden ebenso wiedergegeben, hier zeigt auch die PCA eine gute Performanz. In Bezug auf die Grenzen sind die Unterschiede zwischen den Methoden gravierender. So sind die oberen Grenzen bei einer Gewichtung der Merkmale aus den Entscheidungsbäumen (unten) wesentlich unruhiger als bei gleichmäßiger Gewichtung (oben). Bei einer Reduzierung der Merkmale auf die Hauptachsen werden die Grenzverläufe zwar „ruhiger“, folgen jedoch nicht mehr in dem Maße dem Punktschätzer bzw. der realisierten Kurve, wie sie es bei der Merkmalsgewichtung oder der einheitlichen Gewichtung tun. Die Merkmalsgewichtung ist daher der Merkmalsreduktion bzw. Hauptachsentransformati-

on vorzuziehen. Im Falle einer einheitlichen und dynamischen Gewichtung der Merkmale lässt sich somit zusammenfassend feststellen, dass sowohl eine Zunahme der Trainingsmenge als auch der Anzahl an Nachbarn einen positiven Einfluss haben. Insbesondere bei Zunahme der Merkmalsdimension auf zehn Merkmale, ist die Erweiterung der Trainingsmenge erforderlich, um das Sicherheitsniveau halten zu können. Eine Gewichtung der Merkmale erlaubt eine dynamischere Anpassung der Grenzen.

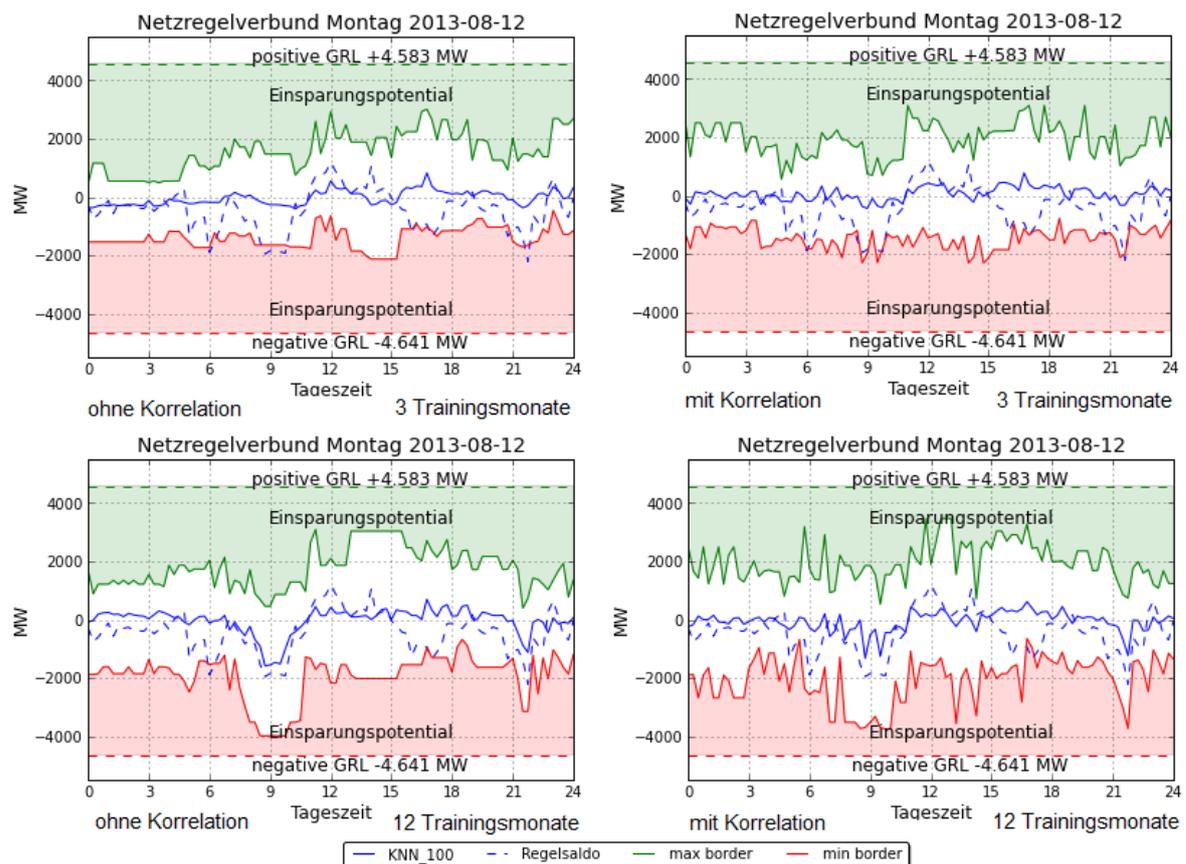


Abbildung 4.11: **Änderung der Merkmalsvorverarbeitung: Ergebnisse für KNN-100 mit 10 Merkmalen mit/ohne Korrelation und 3/12 Trainingsmonaten**

Im Folgenden wird untersucht, wie sich die Ergebnisse verändern, wenn man die stündliche Korrelation der Einflussgrößen mit der Zielvariablen bei der Merkmalsgewichtung berücksichtigt und die Merkmale somit adaptiv gewichtet. Dazu werden die beiden Simulationsfälle mit drei und zwölf Trainingsmonaten in Abbildung 4.11 gegenüber gestellt. Links ist jeweils der Fall ohne Berücksichtigung der Korrelation dargestellt und rechts mit Berücksichtigung der stündlichen Korrelation. Oben werden drei Monate trainiert und unten jeweils zwölf Monate. In Bezug auf die Trainingsmonate bestätigen die Ergebnisse die vorher bereits aufgezeigte Tatsache, dass sich die Grenzen besser dem Verlauf der realisierten Kurve anpassen, wenn sich die Anzahl an Samples erhöht. Das Hinzufügen der Korrelation als Merkmalsgewicht bewirkt eine stärkere „Rauheit“; dies gilt sowohl für die Prognosezeitreihe als auch für die obere und untere Grenze. Dies kann jedoch auch eine Folge der stärkeren Gewichtung

der Zeitmerkmale sein, die sich als Folge ergibt, wenn man die Zeitreihenmerkmale entsprechend ihrer Korrelation abschwächt.

Um dies zu evaluieren wird daher in Abbildung 4.12 ein Referenztag untersucht, bei dem die Zeitmerkmale weggelassen werden. Man erkennt, dass die stärkere Rauheit nicht an den verhältnismäßig stärker gewichteten Zeitmerkmalen liegt, sondern auch auftritt, wenn man diese weglässt. In Bezug auf die Enge des Konvidenzintervalls ist daher die Methode ohne Korrelation zu bevorzugen. In Bezug auf die Performanz des Punktschätzers lässt sich feststellen, dass auch hier die Zuhilfenahme der Korrelation eine stärkere Varianz des Schätzers zur Folge hat. Insbesondere zwischen 09:00 Uhr und 18:00 Uhr weist der Schätzer rechts eine deutlich erhöhte Bewegung auf, während der Schätzer links nur den Trend der Kurve nachzeichnet. Den starken Abfall des Saldos um 18:00 Uhr können beide Methoden nicht exakt abbilden, jedoch schaffen es beide Methoden dies in ihrer unteren Grenze zu berücksichtigen, so dass es in beiden Fällen nicht zu Grenzverletzungen kommt; der Abstand zur Grenze ist jedoch unter Berücksichtigung der Korrelation größer.

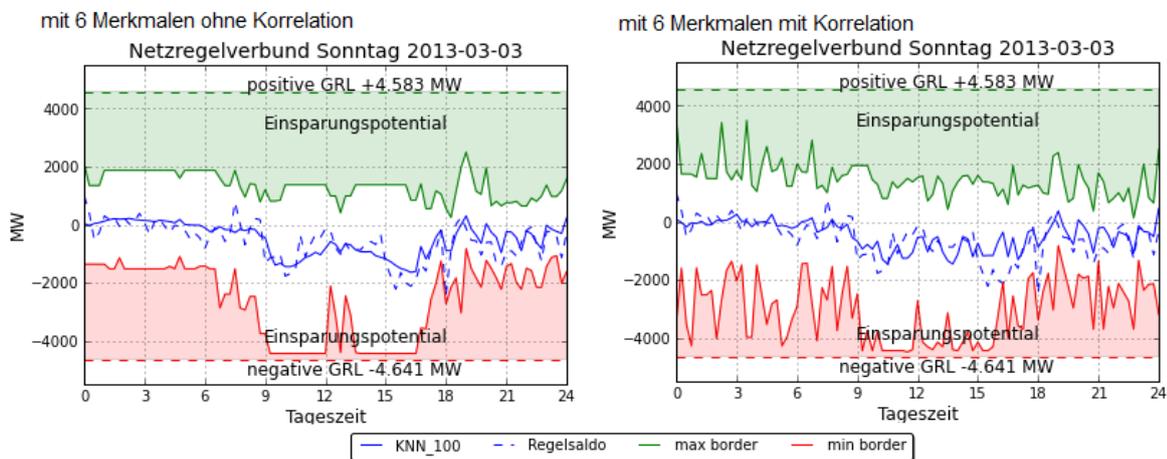


Abbildung 4.12: Ergebnisse für KNN-100 mit 6 Merkmalen mit/ohne Korrelation und 12 Trainingsmonaten

In Abbildung 4.13 wird die Auswirkung analysiert, wenn man den Prognosefehler aus Wind und PV nicht als gegeben voraus setzt, d.h. als Merkmal berücksichtigt, sondern stattdessen lediglich die Prognosewerte für Wind und und PV einsetzt. Dementsprechend werden nicht mehr die Werte der Einspeisung und der Fehler berücksichtigt, sondern lediglich die Werte der Vortagsprognose aus Wind und PV. Es ergeben sich somit unter Einbeziehung der Zeitmerkmale nicht länger zehn sondern acht Merkmale.

Dabei ist links das Ergebnis bei einem Training von drei Monaten gezeigt und rechts das Ergebnis mit zwölf Monaten. Es ist zu erkennen, dass die Performanz des Punktschätzers nicht wesentlich schlechter ist, als wenn man die Prognosefehler vorgibt (siehe zum Vergleich Abbildung 4.11 linke Seite). In Bezug auf das Konfidenzintervall ist dieser im Fall der Unkenntnis des EE-Fehlers wesentlich differenzierter. Während das Intervall zwischen 04:00 Uhr und 18:00 Uhr erwartungsgemäß breiter ist, ist es in den Nachtstunden, insbesondere zwischen 0:00 Uhr und 04:00 Uhr sogar schmaler als wenn man die EE-Fehler als gegeben voraussetzt. Dies ist damit zu begründen, dass nachts nicht zwingend jeder EE-Fehler Auswirkungen auf den Regelsaldo hat. Das Modell dies jedoch nicht

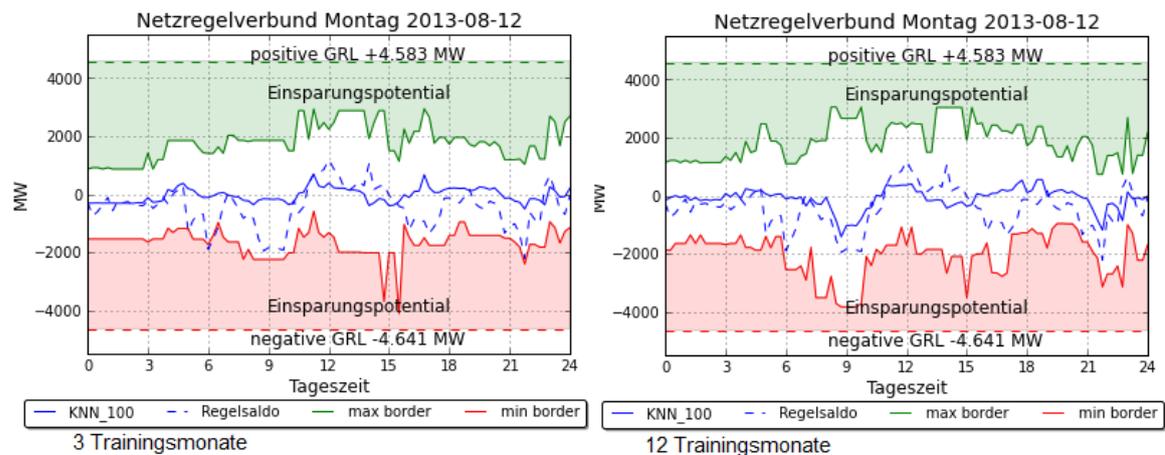


Abbildung 4.13: **Änderung der Merkmalsauswahl:** Ergebnisse für KNN-100 mit 8 Merkmalen ohne Berücksichtigung des EE-Fehlers und 3/12 Trainingsmonaten

unterscheiden kann, bzw. die Gewichtung auf dem EE-Fehler und der EE-Einspeisung höher ist, als auf dem Zeitmerkmal „TOD“. Wählt man dagegen nur den Prognosewert für die EE-Einspeisung, d.h. reduziert man die Anzahl Merkmale, erhält das Zeitmerkmal automatisch ein höheres Gewicht. Diese Tatsache des schmaleren nächtlichen Konfidenzintervalls fällt insbesondere bei den einzusparenden Kosten ins Gewicht, da der Leistungspreis für die negative Regelleistungsvorhaltung zwischen 0:00 Uhr und 04:00 Uhr am höchsten ist. Tagsüber verbreitert sich das Konfidenzintervall, da mit zunehmender Netzlast auch der Einfluss der EE-Fehler auf den Regelsaldo zunimmt. So steigt die Bandbreite zwischen den Extremwerten der k Nachbarn an, da ähnliche Prognosewerte sowohl positive als auch negative Prognosefehler zur Folge haben können und damit der Regelsaldo entsprechend sowohl positiv als auch negativ beeinflusst sein kann. Dies zeigt sich insbesondere um 09:00 Uhr wo der Korridor in Unkenntnis des realisierten Prognosefehlers sowohl positiv als auch negativ breiter wird, während in Kenntnis des – in diesem Fall – negativen Prognosefehlers (siehe Abbildung 4.11) nur der negative Bereich vergrößert wird.

Die Zunahme des tatsächlich realisierten Prognosefehlers aus EE-Einspeisung als zusätzliches Merkmal, hat damit in erster Linie Einfluss auf das Konfidenzintervall. Dieses wird in Zeiten großer Netzlast (tagsüber) breiter, in den Nachtstunden hingegen wird das Intervall nur zum Teil verbreitert.

Eine weitere Möglichkeit der Erhöhung der Merkmalsdimension bietet, neben der Zunahme neuer Merkmale, die Auswahl mehrere Zeitwerte pro Zeitreihenmerkmal. Abbildung 4.14 zeigt die Ergebnisse mit zwei Werten pro Zeitreihenmerkmal für drei Trainingsmonate auf der linken Seite und zwölf Trainingsmonaten auf der rechten Seite⁹. Man erkennt, dass bei zwölf Trainingsmonaten die Erweiterung auf zwei Werte pro Merkmal eine Verbesserung der Vorhersage bewirkt. Insbesondere das Konfidenzintervall wird schmaler unter gleichzeitiger Einhaltung der Grenzen.

Abschließend erfolgt die Betrachtung der Einstundenprognose (One-Hour-Ahead) ebenfalls für den 01.03.2012 und den 01.07.2012. Die Ergebnisse sind in Abbildung 4.15 dargestellt. Man erkennt, dass das Konfidenzintervall deutlich an Breite abnimmt, bzw. noch besser der Vorhersagekurve folgt. Auf-

⁹ Zum Vergleich siehe ebenfalls Abbildung 4.11 auf der linken Seite.

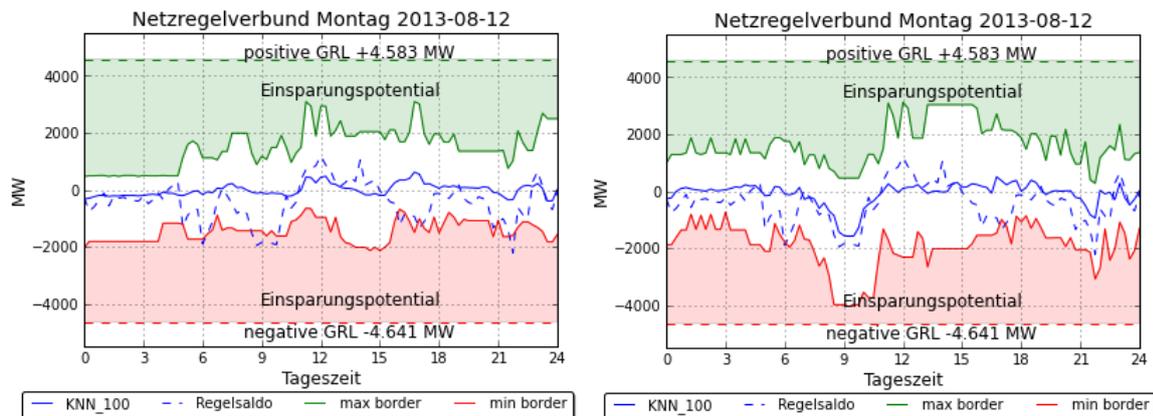


Abbildung 4.14: **Änderung der Merkmalsgenerierung:** Ergebnisse für KNN-100 mit 6 Merkmalen und Lag[0,1] und 3/12 Trainingsmonaten

fällig ist die Überschreitung der vorhandenen negativen Regelleistungsmenge um 03:00 Uhr, d.h. zu diesem Zeitpunkt hätte das Prognosemodell einen erhöhten Bedarf an Regelleistung prognostiziert. Dies hängt mit dem extrem hohen Windfehler in der 50 Hertz Regelzone zu diesem Zeitpunkt zusammen; die zulässige Grenze der Überschusswahrscheinlichkeit konnte jedoch auch bereits bei der Eintagesprognose gehalten werden (siehe Abbildung 4.7). Im Vergleich mit der Eintagesprognose hat die stündliche Prognose starke Ähnlichkeit mit der Persistenz, bei der lediglich der Vorstundenwert als Prognosewert genommen wird. Dieser Wert ist in der Abbildung gepunktet dargestellt. Somit ist der Gewinn, den man gegenüber der Persistenz erzielen kann, wesentlich geringer als bei der Eintagesprognose. Dies könnte an der relativ hohen täglichen Autokorrelation des Regelsaldos liegen, was zu der guten Performance der täglichen Prognose geführt hat. Die Ergebnisse für den RMSE im Vergleich zur Persistenz folgen nachdem auch der Gradient Boosting Tree ausgewertet wurde.

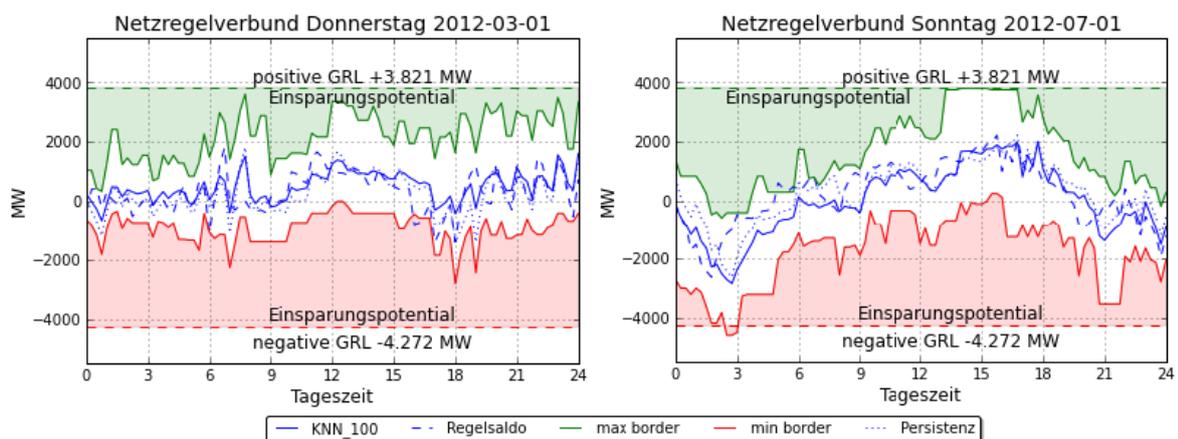


Abbildung 4.15: **Änderung des Prognosehorizonts:** Ergebnisse für KNN-100 mit 7 Merkmalen und 11 Trainingsmonaten

4.2.2 Ergebnisse für den Gradient Boosting Trees (GBT)

Nachfolgend werden entsprechend der Auswertung der k-nächsten-Nachbarn auch für den Gradient Boosting Tree die Parameterbelegungen analysiert. Dabei erfolgt die Auswertung in der gleichen Reihenfolge, mit dem einzigen Unterschied, dass anstatt die Anzahl an Nachbarn zu erhöhen, beim GBT der Wert für das α entsprechend erhöht wird. Abbildung 4.16 zeigt dementsprechend die Beispieltage im März und Juli aus dem Jahr 2012.

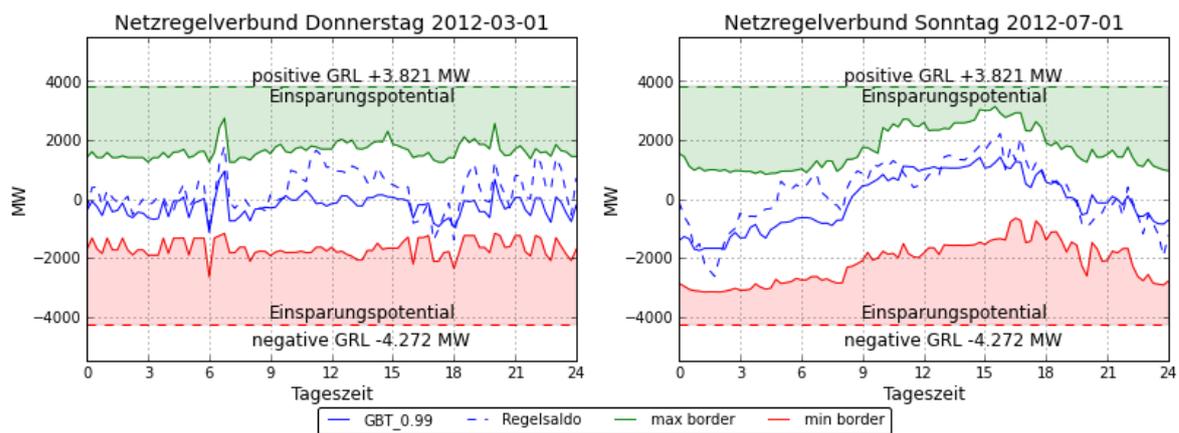


Abbildung 4.16: **Beispielergebnisse** für GBT mit $\alpha = 0.99$ mit 7 Merkmalen und 3 Trainingsmonaten

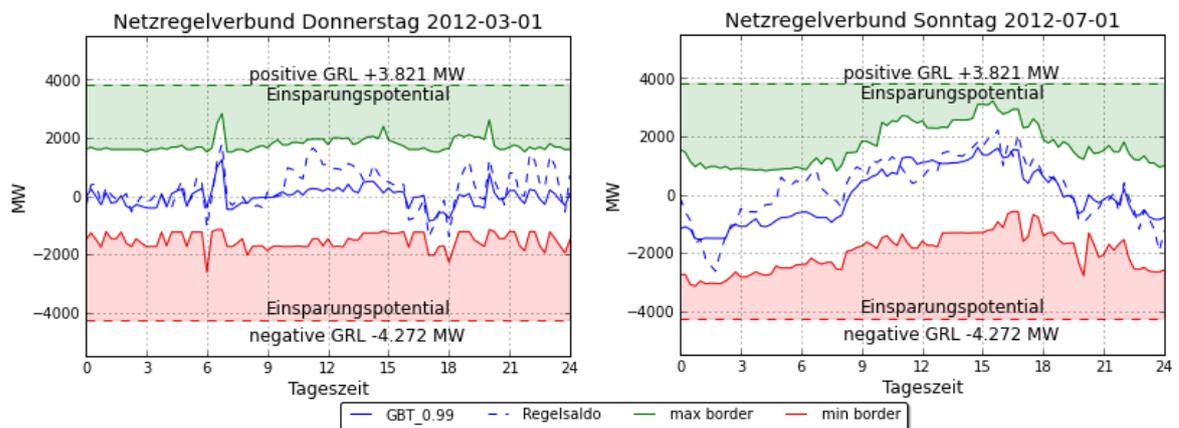


Abbildung 4.17: **Änderung der Merkmalsauswahl**: Ergebnisse für GBT mit $\alpha = 0.99$ mit 11 Merkmalen und 3 Trainingsmonaten

Das Ergebnis ist ähnlich wie bei der KNN-Methode, die Fahrplansprünge konnten im März gut prognostiziert werden. Im Juli konnte ebenfalls der Anstieg des Saldos in den Mittagsstunden vorhergesagt werden. Insgesamt ist bei einem $\alpha = 0.99$ das Konfidenzintervall schmäler als bei der Zuhilfenahme von 100 Nachbarn und es ist wesentlich glatter. Trotzdem konnten die Grenzen an beiden Tagen gehalten werden. Abbildung 4.17 zeigt die Beispieltage wenn die Zeitmerkmale

berücksichtigt werden. Während sich im März ein fast gleiches Bild ergibt, verringert sich im Juli das Konfidenzintervall, d.h. für den GBT sind die Zeitmerkmale entscheidender als für die KNN Methode.

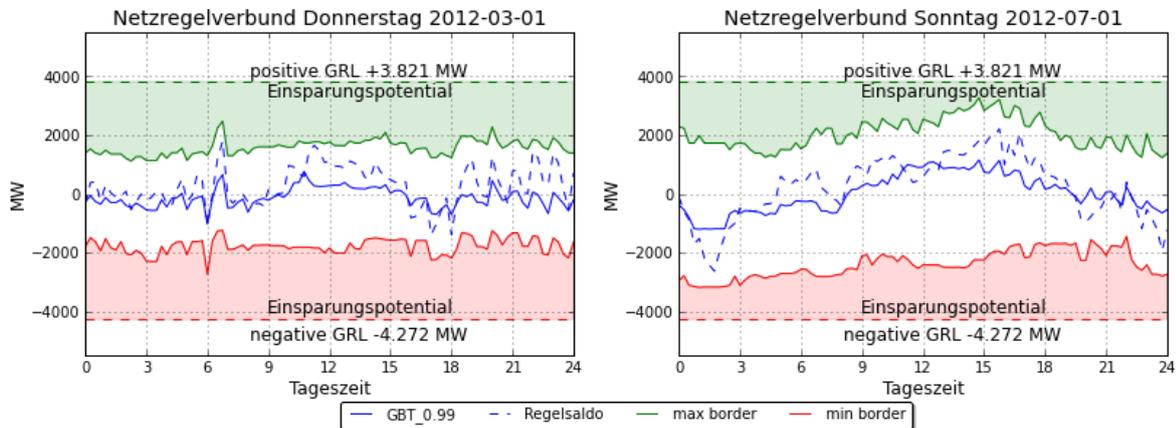


Abbildung 4.18: **Änderung der Trainingsmonate:** Ergebnisse für GBT mit $\alpha = 0.99$ mit 7 Merkmalen und 12 Trainingsmonaten

Bei der Erweiterung der Trainingsmonate reagiert der GBT ebenfalls anders als die KNN. Abbildung 4.18 zeigt die Ergebnisse bei einer Erhöhung der Trainingsmenge auf zwölf Monate. So bewirkt eine Zunahme der Trainingssamples nicht zwingend eine Abnahme des Konfidenzintervalls, sondern im Gegenteil im Juli wird dieses bei Zunahme der Trainingsmenge sogar breiter. Im März sind die beiden Ergebnisse dagegen nahezu identisch. Weiterhin verschlechtert sich bei Zunahme der Trainingsmenge die Genauigkeit des Punktschätzers, dies ist insbesondere an der Abbildung des Fahrplansprungs um 06:00 Uhr erkennbar. Dieses Verhalten ist jedoch zu erwarten gewesen. Während bei KNN eine Erhöhung der Trainingsmenge die Wahrscheinlichkeit erhöht, Nachbarn mit geringem Abstand und damit größerer Ähnlichkeit zu finden, erhöht sich für die Entscheidungsbäume die Anzahl möglicher Teilungen bzw. auch die Anzahl an „Ausreißern“ die womöglich eine geeignete Teilung der Datenmenge erschweren. Dies ist jedoch stark vom eingestellten Wert für α abhängig – und damit von der Toleranz gegenüber Ausreißern – wie die folgende Abbildung 4.19 zeigt. Dabei wird der Wert für α schrittweise erhöht und jeweils die Ergebnisse mit drei und zwölf Trainingsmonaten gegenübergestellt.

Dabei ist zu erkennen, dass der Unterschied zwischen den Trainingsmengen bei einem $\alpha = 0.99$ (obere Abbildung) noch gering ist, mit steigendem Wert für α jedoch zunimmt und dem Verhalten des KNN-Modells entspricht. So ist insbesondere im Fall der höchsten Sicherheitsstufe bei einem $\alpha = 0.9999$ ein deutlicher Unterschied bzw. eine Verbesserung in Bezug auf die Einsparpotentiale bei einer Vergrößerung der Trainingsmenge erkennbar. Insbesondere der Korridor bei einem $\alpha = 0.9999$ im Fall geringer Trainingsbeispiele ist so breit, dass es quasi der jetzigen Bemessungsmethode entspricht. In beiden Fällen verlaufen die Grenzen bei einem $\alpha = 0.9999$ nahezu waagrecht und folgen nicht mehr dem realisierten Saldo. Es lassen sich somit nur mit einem $\alpha = 0.9975$ zum KNN vergleichbare Ergebnisse erzielen.

Nachfolgend werden die Ergebnisse bei einer Berücksichtigung der stündlichen Korrelation mit der Zielgröße diskutiert. Abbildung 4.20 zeigt auf der linken Seite die Ergebnisse ohne Korrelation auf der rechten Seite mit Korrelation. Oben sind die Ergebnisse mit drei Trainingsmonaten dargestellt

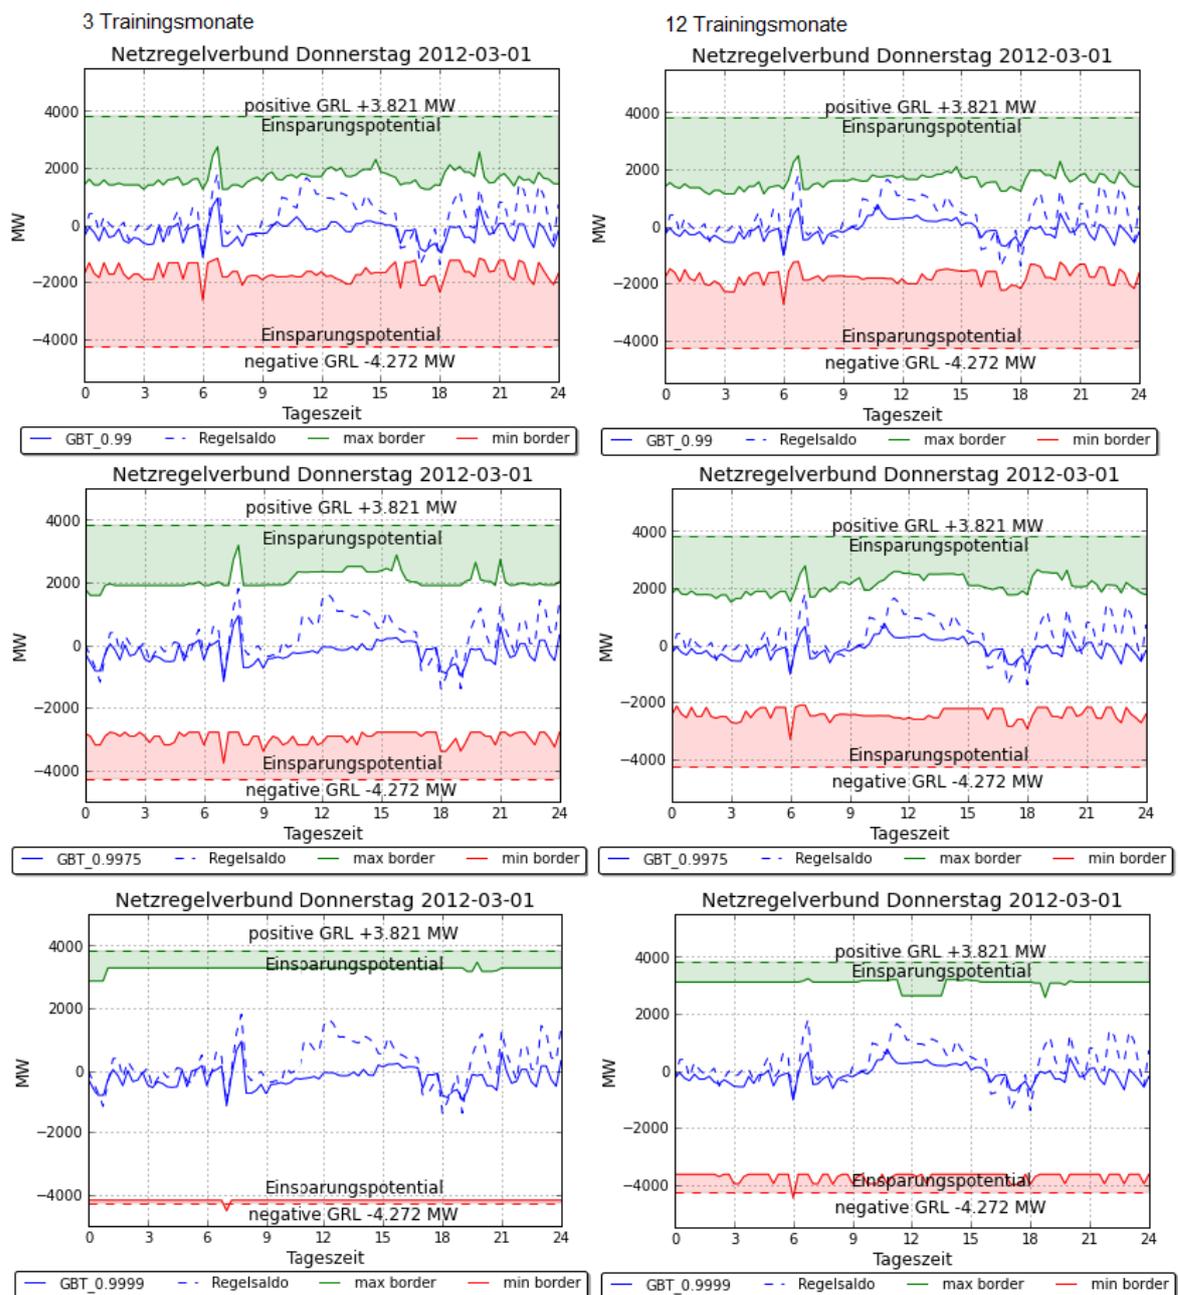


Abbildung 4.19: **Änderung der Parametereinstellung:** Ergebnisse für GBT mit 7 Merkmalen, 3/12 Trainingsmonate und unterschiedlicher Werte α (0,99;0,9975;0,9999)

und unten für zwölf Trainingsmonate. Insgesamt ist zu erkennen, dass sowohl die Zunahme der Trainingsmonate als auch die Berücksichtigung der Korrelation bei den GBT eine geringere Auswirkung hat als bei den KNN. Dies gilt insbesondere für die Vorhersagekurve des Punktschätzers, dieser zeigt nur geringfügige Veränderungen. Die besten Ergebnisse zeigt der untere linke Fall. Dieser Simulationsfall mit zwölf Trainingsmonaten und ohne Berücksichtigung der Korrelation hatte bereits bei den KNN die beste Übereinstimmung mit der realisierten Kurve gezeigt. In Bezug auf die Grenzverlet-

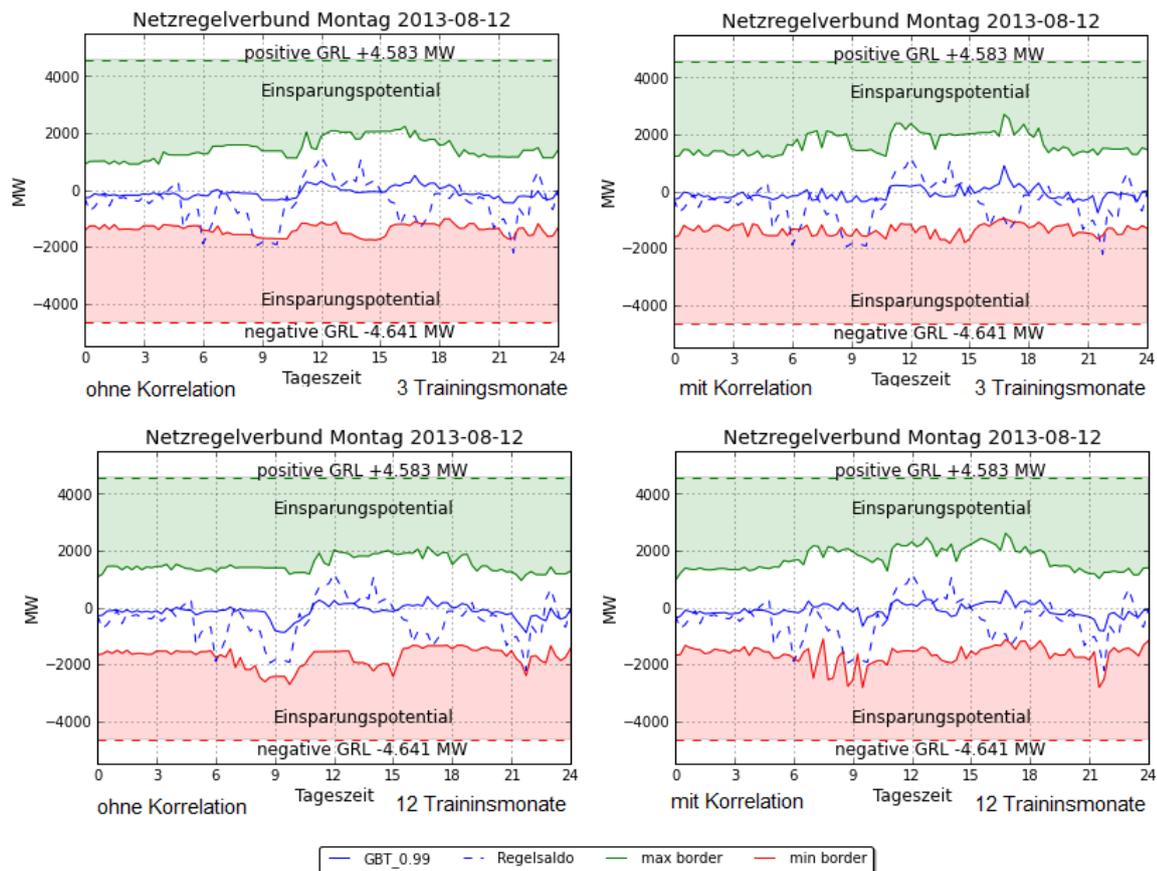


Abbildung 4.20: **Änderung der Merkmalsvorverarbeitung: Ergebnisse für GBT-0.99 mit 10 Merkmalen mit/ohne Korrelation und 3/12 Trainingsmonaten**

zungen ist eine Zunahme der Trainingsmonate daher zwingend erforderlich. So werden in den oberen Abbildungen in beiden Fällen die unteren Grenzen verletzt. Im Fall mit zwölf Trainingsmonaten wird der Grenzverlauf unter Berücksichtigung der Korrelation – wie bei den KNN – rauher, jedoch bei weitem nicht in dem gleichen Ausmaß. Dies hängt damit zusammen, dass der GBT relativ unabhängig von der Merkmalsdimension ist. Somit fällt eine stärkere Gewichtung eines einzelnen Merkmals durch die Multiplikation mit der Korrelation nicht derart ins Gewicht wie bei den Distanzmaßen und dementsprechend bei den KNN.

Wie der GBT auf die Unkenntnis des genauen EE-Fehlers reagiert, zeigt die Abbildung 4.21. Auch hier wurden die Merkmale der EE-Fehler und der EE-Einspeisung durch die EE-Prognosen ersetzt. Ähnlich den KNN ist ebenfalls eine Verbreiterung des Korridors tagsüber und eine Verschmälerung des Konfidenzintervalls nachts erkennbar. Um Grenzverletzungen zu verhindern, muss auch hier die Trainingsmenge zwingend auf zwölf Monate erhöht werden.

In Abbildung 4.22 sind die mittleren Fehler der einzelnen Methoden für einen Beispielsimulationsfall, mit elf/zehn Merkmalen ohne Korrelation und zwölf Trainingsmonaten für die Jahre 2012 und 2013 gegenüber gestellt. Als Vergleich bzw. Evaluation sind die Ergebnisse der Persistenz ausgege-

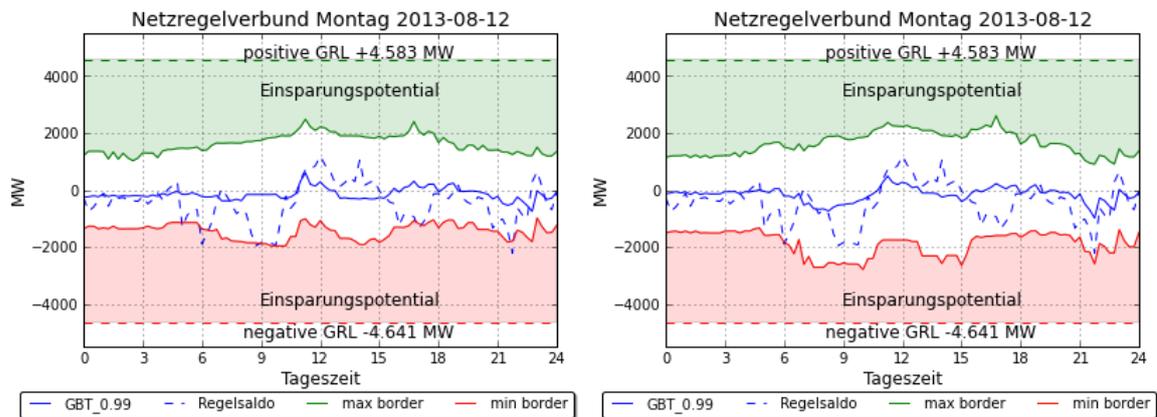


Abbildung 4.21: **Änderung der Merkmalsauswahl: Ergebnisse für GBT-0.99 mit 8 Merkmalen ohne Berücksichtigung des Prognosefehlers**

ben. Die Balken sind jeweils von links nach rechts und oben nach unten dargestellt, d.h. ganz links ist GBT_0.99 dargestellt und jeweils rechts ist die Persistenz abgebildet.

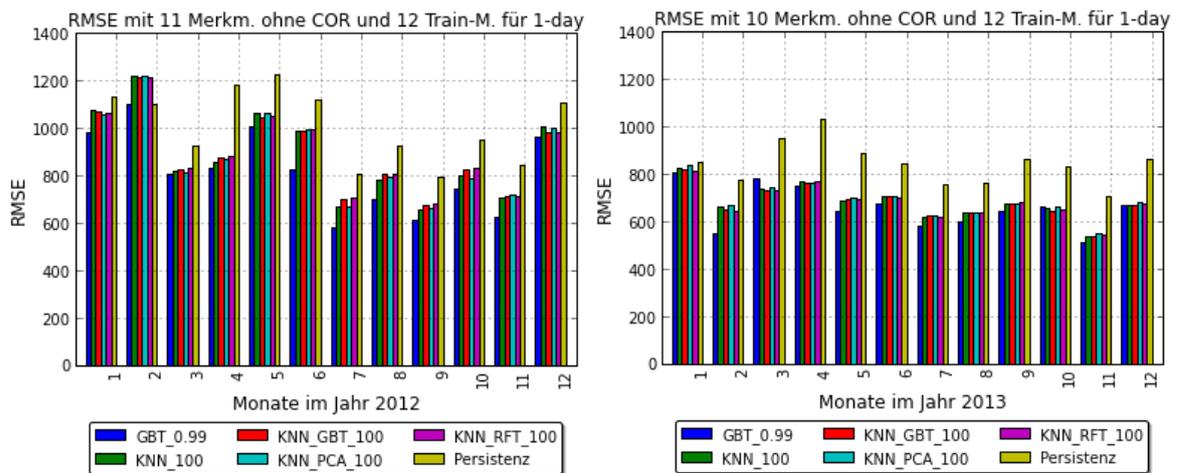


Abbildung 4.22: **RMSE für den NRV 2012 und 2013 1-Day-Ahead**

Man erkennt, dass das Jahr 2012 deutlich schlechter vorherzusagen war als das Jahr 2013. Dies lässt sich größtenteils mit der höheren Varianz des Saldos selbst begründen. So ist die Höhe der Fehler aus der Persistenz ein Indiz für die Spanne zwischen den Salden zweier aufeinanderfolgender Tage. Insgesamt war somit der mittlere Fehler im Jahr 2012 in allen Methoden deutlich höher als im Jahr 2013. Lediglich die zweite Jahreshälfte in 2012 (Juli bis November) zeigt eine ähnlich gute Performanz wie 2013. Dies lässt einen Zusammenhang mit der Einführung der automatisierten Minutenreserveaktivierung ab dem 03.07.2012 vermuten (siehe Kapitel 2.1.2, Seite 16). So erfolgt die MRL-Aktivierung seit Juli 2012 über alle Regelzonen einheitlich nach aufsteigender Merit-Order-Reihenfolge. Dies führt zu einer besseren Übereinstimmung der Werte der einzelnen Regelzonen mit dem NRV und damit einer exakteren Vorhersage des NRV. Abgesehen vom Februar 2012 zeigen auch im Jahr 2012 trotzdem alle Modelle bessere Ergebnisse als die Persistenz. Der Februar 2012

nimmt eine gewissen „Sonderstellung“ ein, da in diesem Monat insbesondere die positiven Regelleistungsabrufe deutlich über dem Jahresdurchschnitt lagen und nicht auf die „üblichen Einflussfaktoren“ zurückzuführen waren, sondern eine starke Abhängigkeit zu den relativ hohen Preisen an der EEX aufzeigten¹⁰. Der Zusammenhang wurde bereits in Kapitel 2 dargestellt (siehe Abbildung 2.17, Seite 35). So sind die Haupteinflussfaktoren auf den Regelsaldo im Winter 2012 andere als zum Beispiel im Sommer 2012 wie Abbildung 4.23 zeigt. Deutlich zu erkennen ist der relativ hohe Einfluss des Phelix Base Preises (EEX) im Winter sowie der untypisch geringe Einfluss der Tageszeit. Im Sommer überwiegen neben den EE-Prognosefehlern die Tageszeit sowie die Windeinspeisung bei den Einflussfaktoren¹¹.

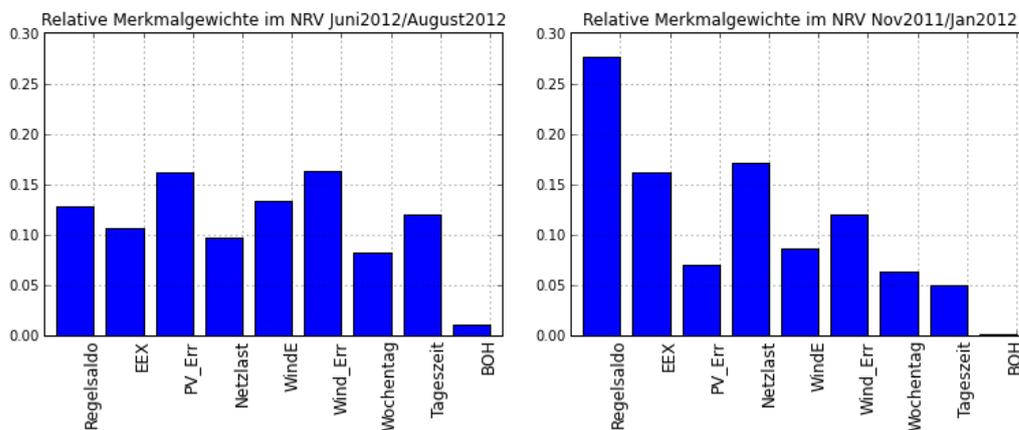


Abbildung 4.23: Feature Importance im Jahr 2012 Winter-Sommer im Vergleich

Um eine Aussage über das Fehlerverhalten der Modelle treffen zu können, wurde die Verteilung der Residuen auf Normalverteilung untersucht (siehe Kapitel 3.3.1, Seite 90). Dazu wurde zum einen ein Q-Q-Plot generiert und zum anderen wurden die Wahrscheinlichkeitsdichtefunktionen für einzelne Monate im Jahr 2013 grafisch mit denen der Normalverteilung verglichen; die Ergebnisse sind für Beispielmonate und Beispielverfahren in Abbildung 4.24 dargestellt. Im Gegensatz zur Auswertung des Februar 2012 (Seite 93) mit Abweichungen im positiven Bereich, zeigt sich im Januar 2013 eher eine Abweichung von der Normalverteilung im Bereich großer negativer Prognosefehler. Die Überschreitung der vorgegebenen Defizitwahrscheinlichkeit in diesem Monat war bereits in Kapitel 2 (siehe Abbildung 2.21b auf Seite 40) zu erkennen gewesen. Die ist auch der Grund für die relativ hohen mittleren Fehler im Januar 2013. Der Sommermonat zeigt hingegen eine guten Übereinstimmung mit der Normalverteilung.

Verringert man den Prognosehorizont auf eine Stunde zeigen die Modelle im Vergleich zur Persistenz keine entscheidende Verbesserung, insbesondere im Jahr 2012 schneiden die Modelle, ausgenommen der GBT, schlechter ab als die Persistenz. Abbildung 4.25 zeigt die Ergebnisse des RMSE für die Einstundenvorhersage. Zwar nimmt der Fehler im Vergleich zur Eintagesprognose deutlich ab, der Unterschied zur Persistenz schwindet jedoch. Insgesamt hat unter den Methoden der GBT die besten Ergebnisse gezeigt. Entscheidend für die Gesamtevaluation der Methoden ist, wie erwähnt, jedoch nicht der mittlere Fehler der Punktvorhersage, sondern insbesondere die Einhaltung des geforder-

¹⁰ Dies führte in der Folge zu einer Kopplung der Ausgleichsenergiepreise an den Phelix Base Preis.

¹¹ Es ist anzumerken, dass nicht gesondert nach Tag und Nacht unterschieden wurde, so dass der effektive Einfluss des PV-Fehlers deutlich höher liegt.

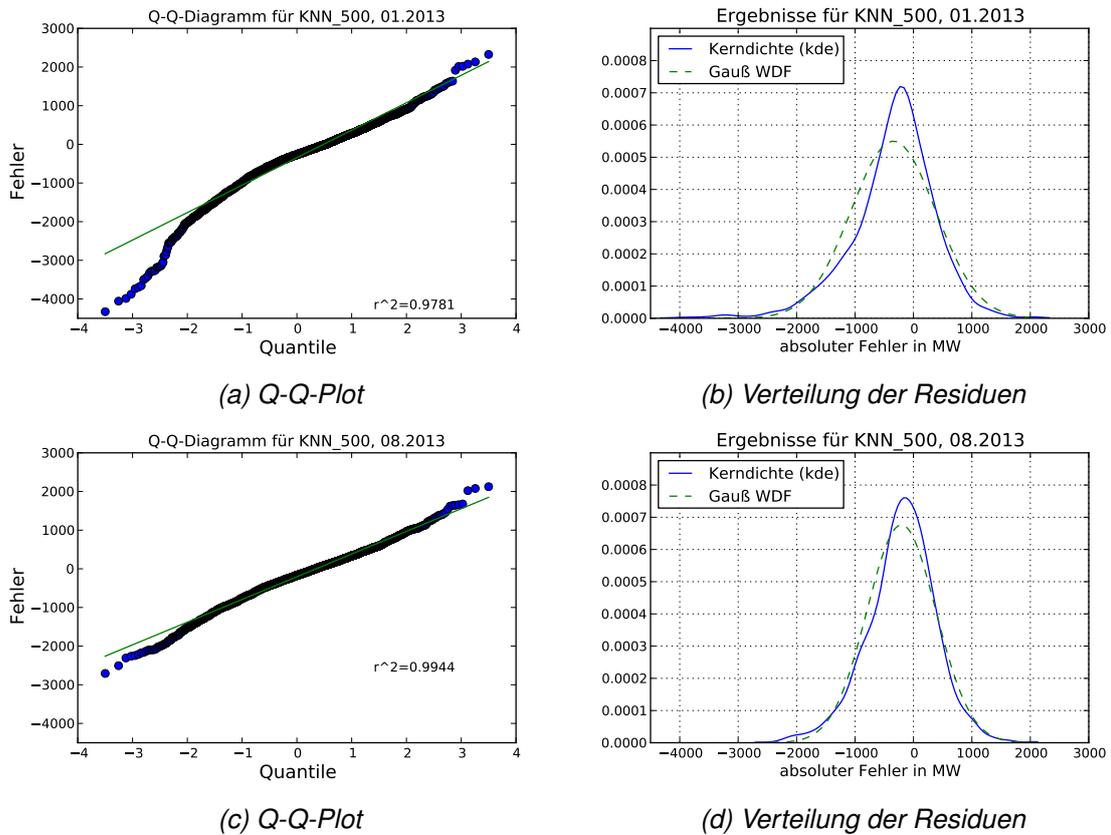


Abbildung 4.24: Verteilung der Residuen für KNN-500 im NRV 01/2013 und 08/2013

ten Sicherheitsniveaus bei gleichzeitiger temporärer Reduzierung der vorzuhaltenden Regelleistungsmengen. Daher wird im folgenden Kapitel das Prognosemodell auf die Regelleistungsbemessung angewandt.

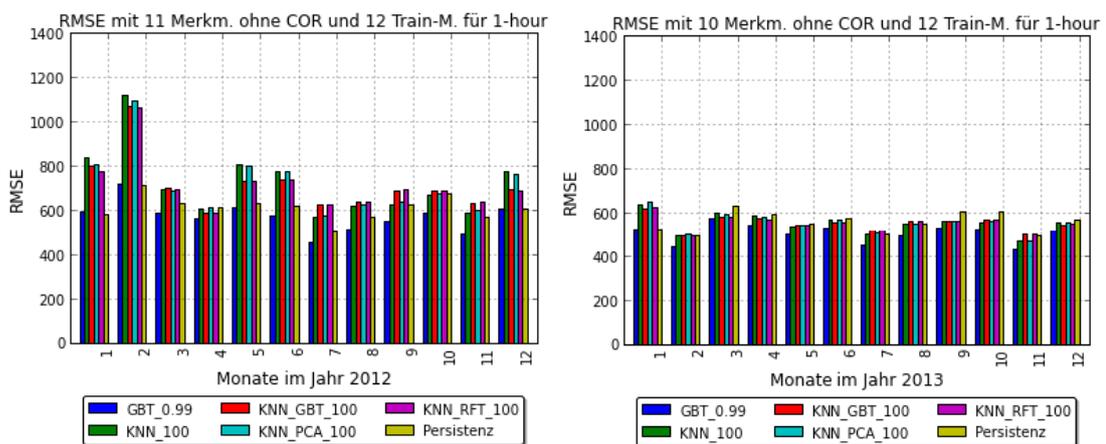


Abbildung 4.25: RMSE für den NRV in 2012 und 2013 1-Hour-Ahead-Prognose

4.3 Anwendung des Prognosemodells auf die Regelleistungsbemessung

Im vorangegangenen Kapitel 4.2 wurde die Performanz des Punktschätzers gezeigt. Dieser zeigt insbesondere in Bezug auf die Vorhersage der Fahrplansprünge beachtliche Ergebnisse. Insgesamt lässt sich feststellen, dass sowohl der KNN als auch der GBT gute Ergebnisse erzielen; so liegt der RMSE – bis auf wenige Ausnahmen – in allen Monaten unter den Werten, die sich mit der Persistenz erzielen lassen. Neben der guten Übereinstimmung des Punktschätzers konnte anhand von Beispieltagen auch bereits gezeigt werden, dass die Konfidenzintervalle – die von den Modellen aufgespannt werden – ausreichend sind, das geforderte Sicherheitsniveau zu halten. Im folgenden Kapitel wird diese Forderung für alle Monate genauer evaluiert bzw. es erfolgt eine Berechnung der entsprechenden Sicherheitsniveaus.

4.3.1 Sicherheitsniveau des Prognosemodells (VaR)

Zur Berechnung des Sicherheitsniveaus werden die Grenzüberschreitungen gemessen, d.h. in wie vielen Intervallen der realisierte Regelsaldo nicht innerhalb der vom Modell bestimmten Grenzen lag. Dabei wird zwischen der Defizitwahrscheinlichkeit PU (probability, upper) in Bezug auf die obere Grenze (positive Regelleistung) und der Überschusswahrscheinlichkeit PL (probability, lower) in Bezug auf die untere Grenze (negative Regelleistung) unterschieden. Des Weiteren wird bei der Bemessung unterschieden, ob die RL-Vorhaltung stündlich oder in vier-Stunden-Blöcken geschieht (PU_4, PL_4). Das Sicherheitsniveau steigt mit Zunahme der Stundenintervalle an, da jeweils der maximale bzw. minimale Wert für die Grenze innerhalb eines Intervalls angesetzt wird. Die beispielhaften Ergebnisse einer One-Day-Ahead Vorhersage mit zehn Merkmalen, und einem Trainingshorizont von zwölf Monaten sind in Abbildung 4.26 für das Jahr 2012 und in Abbildung 4.27 für das Jahr 2013 dargestellt¹².

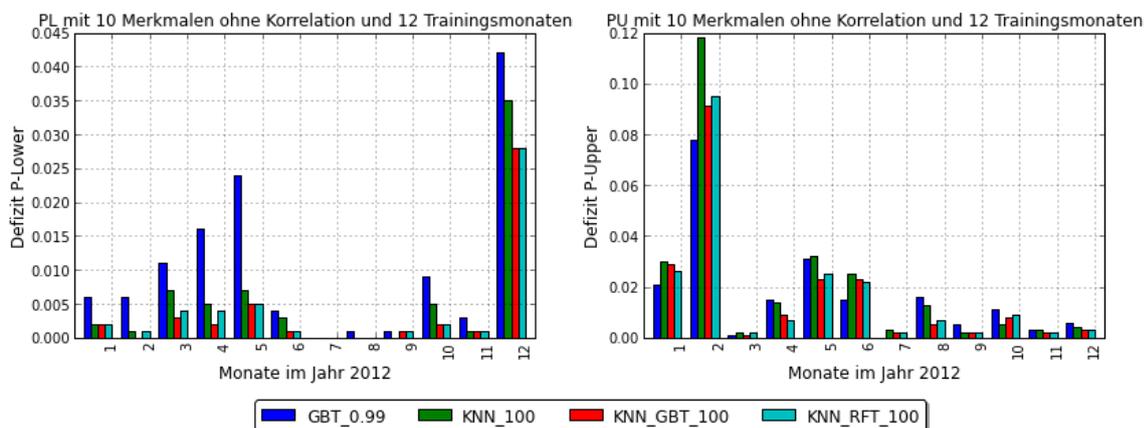


Abbildung 4.26: Ergebnis der Sicherheitsniveaus für das Jahr 2012 mit 1-h-Blöcken

¹² Die Parametereinstellung ergibt sich aus Kapitel 4.2 bzw. ist die „mittlere Parametereinstellung“ anhand derer im Anschluss einzelne Parameter in beide Richtungen evaluiert werden können.

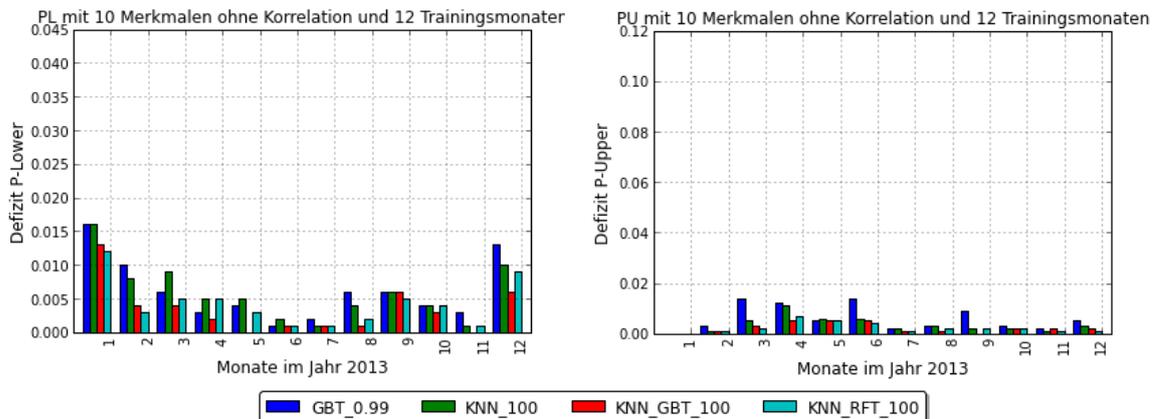


Abbildung 4.27: Ergebnis der Sicherheitsniveaus für das Jahr 2013 mit 1-h-Blöcken

Im Vergleich der beiden Abbildungen erkennt man, dass für das Jahr 2013 deutlich bessere Ergebnisse erzielt werden konnten. Dies deckt sich mit den Ergebnissen der Punktprognose bzw. des mittleren Fehlers. Im Bereich der unteren Grenze konnte insbesondere im Dezember 2012 das Sicherheitsniveau nicht gehalten werden. Im Vergleichsmonat (Dezember 2013) ist die Defizitwahrscheinlichkeit immer noch höher als im Jahresdurchschnitt, jedoch bei Weitem nicht derart ausgeprägt wie im Jahr 2012. Diese ist auf die extrem hohe Abrufhäufigkeit negativer MRL im Dezember 2012 zurückzuführen (siehe Abbildung 2.16, Seite 34). Ähnlich der Sonderstellung des Februar 2012 in Bezug auf die positive Regelleistung, entsprach auch der Dezember 2012 bei der Beanspruchung der negativen MRL nicht dem Regelfall. So blieb dieser Monat bei der aktuellen Bemessung der RL unberücksichtigt [HZ15]. Ebenfalls auffällig für die untere Grenze im Jahr 2012 ist das relativ schlechte Abschneiden des GBT im Vergleich zu den anderen Methoden. Dies ist weder für die obere Grenze im Jahr 2012 noch im Jahr 2013 zu beobachten. Für die obere Grenze zeigt der Februar eine deutliche Überschreitung der Defizitwahrscheinlichkeit. Auf dieses Phänomen, bzw. die Sonderstellung des Februars, was den ungewöhnlich hohen Abruf positiver Regelleistung betrifft, wurde bereits eingegangen (siehe Abbildung 2.17, Seite 35). Über das Jahr gesehen, konnte die untere Grenze (einschließlich dem Dezember) dennoch besser eingehalten werden als die obere Grenze; so ist die unterschiedliche Skalierung der y-Achsen zu beachten.

Bei den einzelnen Methoden hat der KNN_GBT die besten Ergebnisse erzielt, während die GBT am schlechtesten abgeschnitten haben. In Bezug auf die einzelnen Monate kann man erkennen, dass das höchste Sicherheitsniveau in den Sommermonaten erreicht wird. Dies gilt insbesondere für die untere Grenze, da diese Grenzverletzungen hauptsächlich durch die Windeinspeisung und den daraus resultierenden Windfehler generiert werden. In den Sommermonaten, wo vermehrt die Solareinspeisung und der daraus resultierende PV-Fehler für den Bedarf an positiver Regelleistung verantwortlich ist, ist dementsprechend das Einhalten der oberen Grenze problematischer. Hier kann in den Wintermonaten eine gute Performanz erzielt werden, die unter den geforderten Defizitgrenzen liegt. Das schlechteste Ergebnis für die Defizitwahrscheinlichkeit wird in den Frühlingsmonaten erzielt. Dies lässt sich damit begründen, dass insbesondere die PV-Prognosen für diese Monate am schwersten zu treffen sind. Wie sich das Sicherheitsniveau in Bezug auf die Parametereinstellung der Simulationemethode verhält, ist in Abbildung 4.28 dargestellt. Links ist jeweils die untere Grenze und rechts die

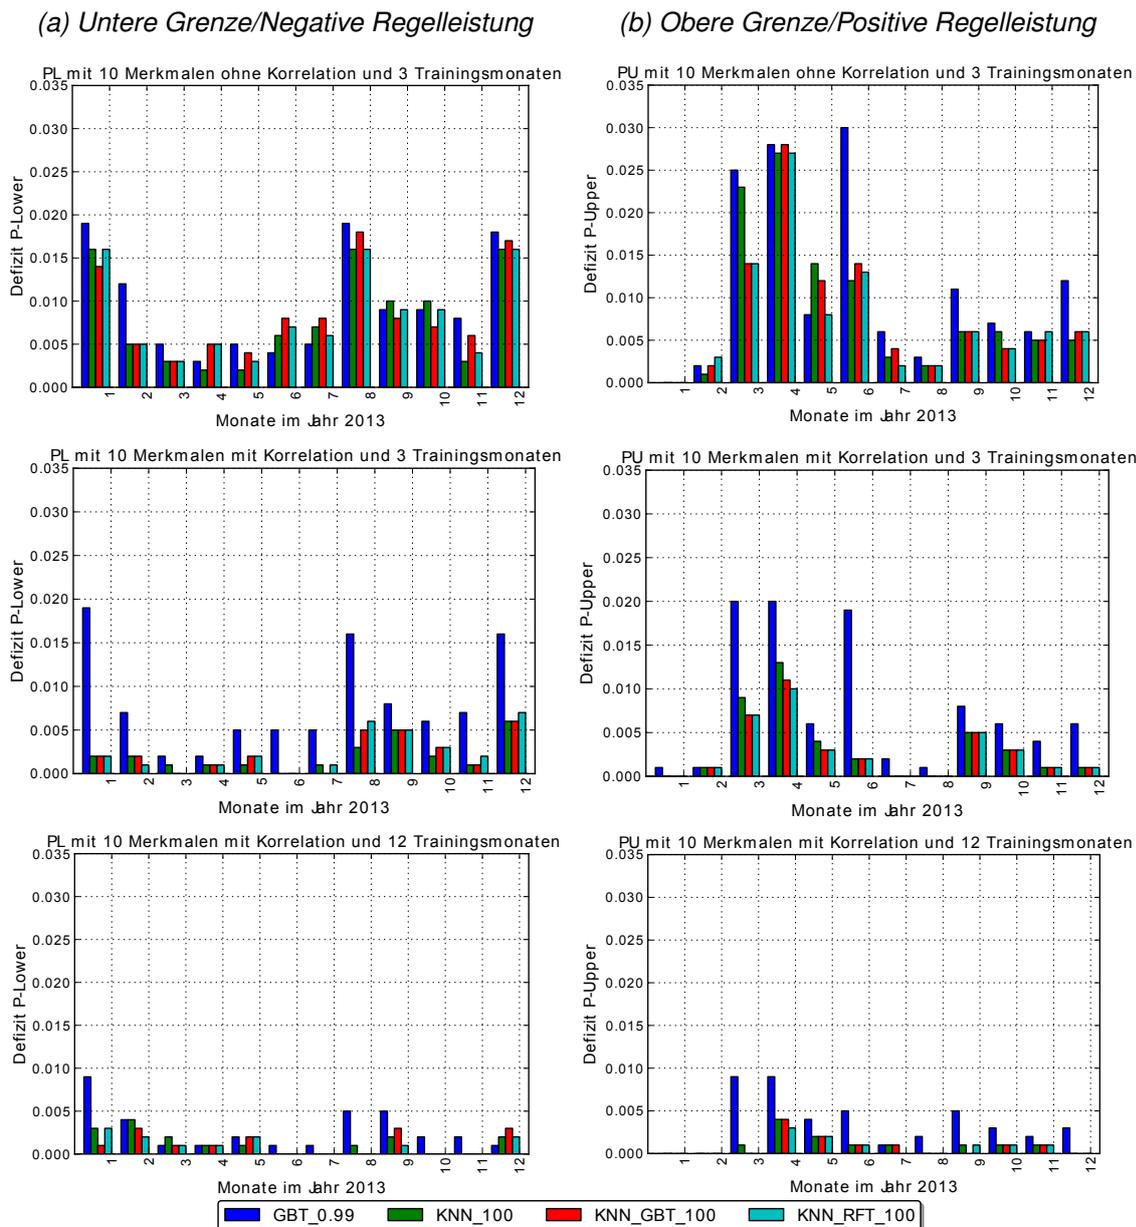


Abbildung 4.28: Sicherheitsniveaus für das Jahr 2013 mit 1-h-Blöcken

obere Grenze dargestellt. Die Zeilen unterscheiden sich jeweils in der Parameterbelegung der Simulationsfälle. Es ist zu erkennen dass sich mit der Zunahme der Korrelation (Zeile 1 zu Zeile 2) eine deutliche Senkung der Defizitniveaus erreichen lässt, nur die GBT weisen noch ein recht hohes Niveau auf. Erhöht man weiterhin die Trainingsmonate, so kann das Defizitniveau noch einmal deutlich reduziert werden. Erhöht man die Anzahl Nachbarn bzw. das Sicherheitsniveau der GBT, und setzt man weiterhin die Ausschreibung von Vier-Stunden-Blöcken voraus, so kann das Sicherheitsniveau weiter gesteigert werden. Abbildung 4.29 zeigt die Ergebnisse für $k = 500$ und $\alpha = 0.9999$. Als Ver-

gleichwert sind außerdem die tatsächlich realisierten Defizit- bzw. Überschusswahrscheinlichkeiten als „Persistenz“¹³ eingetragen.

(a) Untere Grenze/Negative Regelleistung

(b) Obere Grenze/Positive Regelleistung

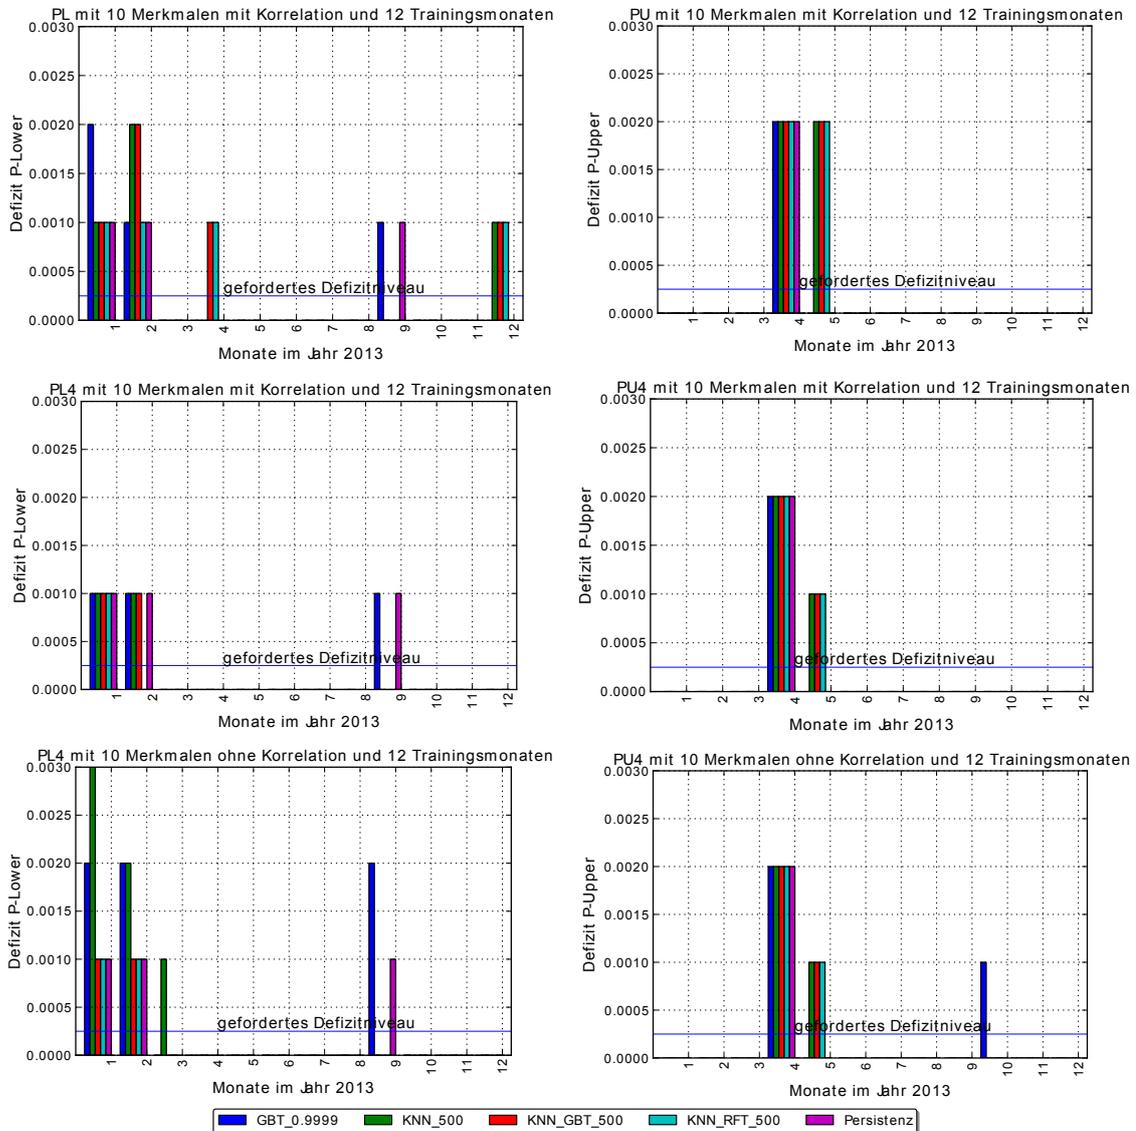


Abbildung 4.29: Sicherheitsniveaus für das Jahr 2013 mit 1h/4h-Blöcken

Die oberen Abbildungen zeigen die Defizitwahrscheinlichkeit für Ein-Stunden-Ausschreibungen und die unteren Abbildungen für Vier-Stunden-Ausschreibungen. Die durchgezogene Linie zeigt jeweils das aktuell (2015) geforderte Defizitniveau von 0,025 %. Für die Einstundendefizite liegen die KNN für die untere Grenze in drei Monaten über dem geforderten Niveau, jedoch nur in einem Monat (April) über dem tatsächlich realisierten Niveau. Die obere Grenze konnte in zwei Monaten nicht gehalten werden, auch hier zeigt jedoch ein Vergleich mit dem tatsächlich realisierten Niveau eine

¹³ Dies entspricht nicht der Defizitwahrscheinlichkeit der Persistenz (wie sie für die RSME berechnet wurde) sondern der Defizitwahrscheinlichkeit in Bezug auf die tatsächlich vorgehaltene GRL.

Überschreitung in nur einem Monat (Mai). Setzt man Vier-Stunden-Blöcke voraus, so verbessert sich das Sicherheitsniveau weiter und es liegt lediglich im Mai 2013 im Bezug auf die positive Regelleistungsmenge unter dem realisierten Sicherheitsniveau. Dabei sind die guten Ergebnisse in erster Linie auf die Zunahme der Trainingsmonate und weniger auf die Korrelation zurückzuführen. So ist in der unteren Zeichnungsebene der Simulationsfall mit zwölf Trainingsmonaten ohne Berücksichtigung der Korrelation abgebildet. Hier erreicht der KNN_GBT das gleiche Sicherheitsniveau wie mit Korrelationsgewichtung. Die Werte für den KNN sowie die GBT sind geringfügig schlechter als im mittleren Fall mit Korrelationsgewichtung.

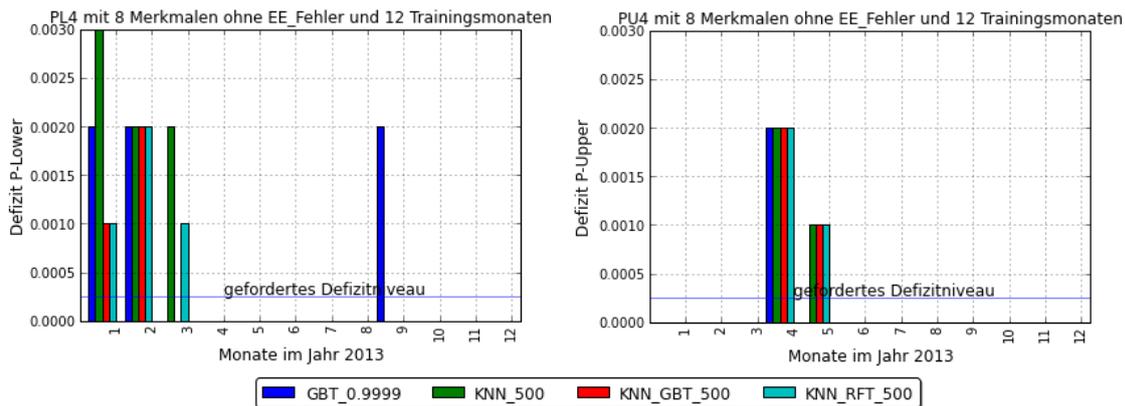


Abbildung 4.30: Sicherheitsniveaus für das Jahr 2013 mit 4h-Blöcken ohne Kenntnis des EE-Fehlers

Wie sich das Sicherheitsniveau verhält, wenn der EE-Fehler nicht bekannt ist, zeigt Abbildung 4.30. Ein Unterschied ist nur im Januar und Februar in Bezug auf die negative Regelleistung zu erkennen, hier liegt das Defizitniveau bei 0,2%, das entspricht einer Überschreitung in 90 Minuten pro Monat. Gefordert sind 0,025%/a, was einer monatlichen Überschreitungszeit von 12,5 Minuten entspricht. Das heißt insbesondere in den Wintermonaten mit hohen Windeinspeisungen (Januar/Februar) – und damit hohen potentiellen Prognosefehlern – trägt deren Kenntnis zu einer besseren Vorhersagefähigkeit der Modelle bei. In den übrigen Monaten bringen diese Informationen in Bezug auf das Sicherheitsniveau nur geringe Vorteile.

4.3.2 Einsparpotentiale des Prognosemodells

Neben der Einhaltung des geforderten Sicherheitsniveaus war ein weiteres Ziel des Prognosemodells, eine Reduzierung bzw. bedarfsgerechtere Vorhaltung der Regelleistungsmengen zu ermöglichen. Im Folgenden werden daher die mit dem Prognosemodell theoretisch erzielbaren Einsparpotentiale ermittelt. Mit dem entwickelten Modell kann ausschließlich eine Aussage über die GRL getroffen werden, eine Unterscheidung in SRL und MRL ist nicht möglich. Entsprechend der jetzigen Bemessungsmethode wird daher eine vollständige Substituierbarkeit von SRL und MRL unterstellt, d.h. es werden nur Aussagen über das Sicherheitsniveau und die Vorhaltung der Gesamtregelleistung getroffen¹⁴. Zur

¹⁴ Diese Annahme wird auch in vergleichbaren Studien vorgenommen und ist in Anbetracht der Abnahme zeitlich kritischer Beanspruchungen von RL im Rahmen dieser Untersuchung ebenfalls tolerierbar.

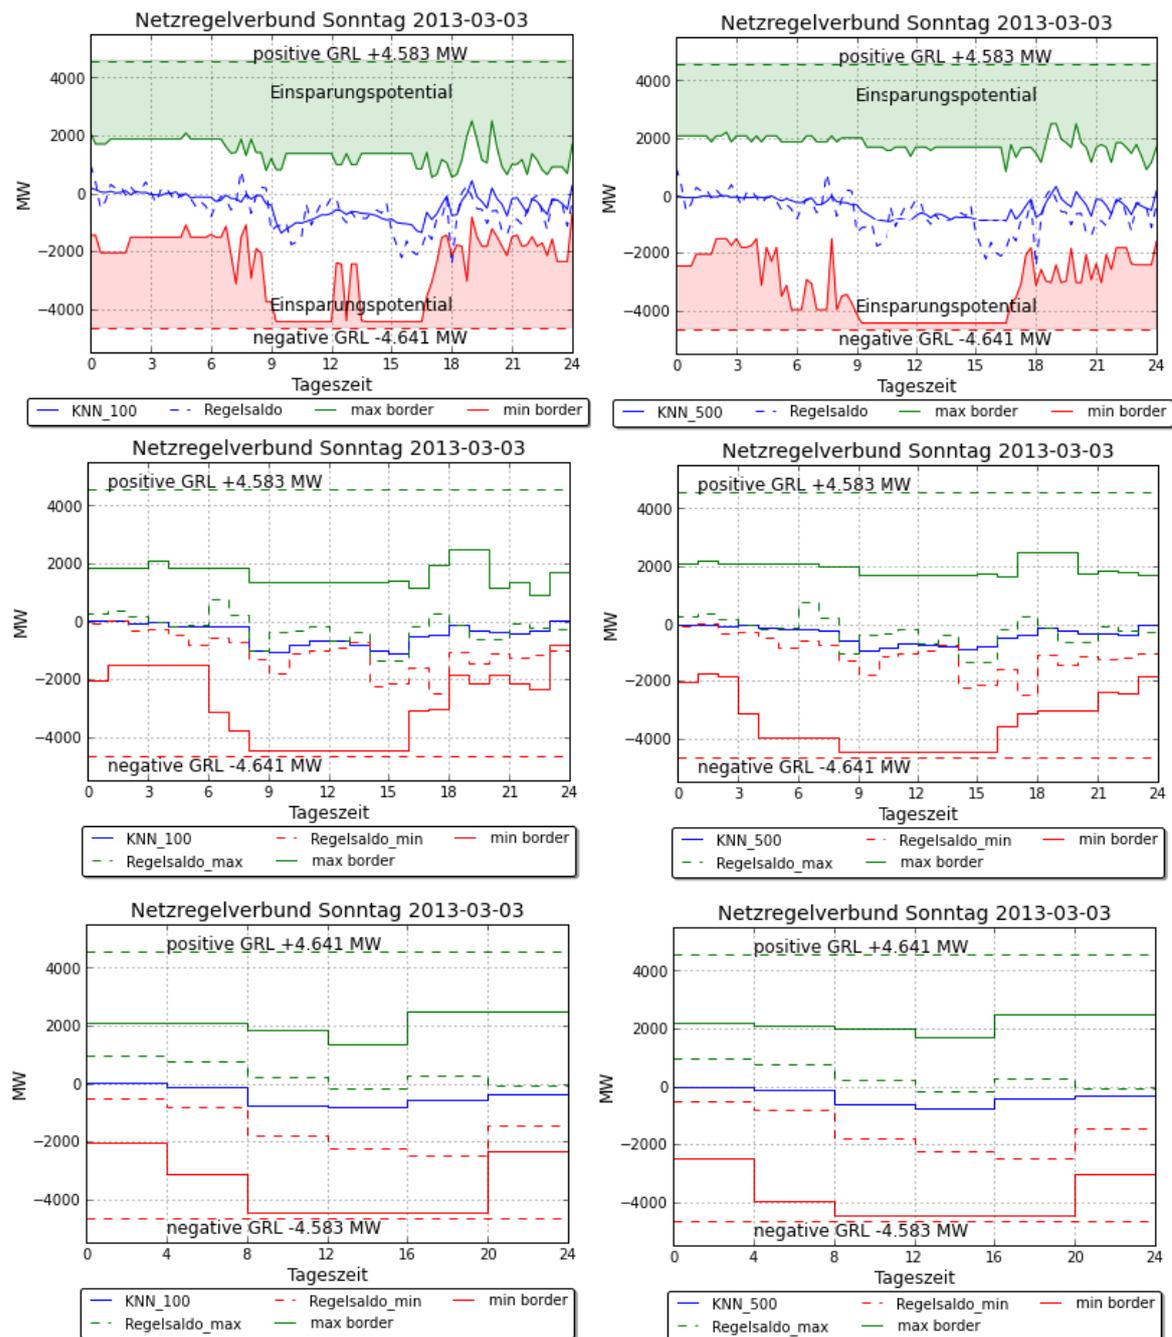


Abbildung 4.31: Anpassung an die 1h/4h Blöcke aus den Ergebnissen der KNN

Berechnung der Einsparpotentiale müssen hierfür die Prognoseergebnisse in eine Bemessung überführt werden. Dazu werden die Grenzen der Konfidenzintervalle zur Berechnung der vorzuhaltenden Mengen heran gezogen. Damit ein Vergleich mit der heutigen Methode möglich wird, bzw. damit eine Beschaffung der Mengen am derzeitigen Regelleistungsmarkt im Form einer Ausschreibung möglich wird, werden die Prognosewerte auf Vier-Stunden-Werte entsprechend den aktuellen Ausschreibungs-

blöcken umgerechnet. Alternativ wird der Fall untersucht, wenn die Ausschreibungszeitscheiben auf eine Stunde reduziert würden. Theoretisch wäre mit dem Prognosemodell auch eine viertelstündliche Ausschreibung möglich, wie sie für Wirkleistungsprodukte an der EEX bereits im Herbst 2014 eingeführt wurde. Im Rahmen dieser Arbeit wird darauf nicht näher eingegangen. Zur Ermittlung der Ausschreibungsmengen wird für die obere Grenze jeweils der Maximalwert über dem entsprechenden Zeitabschnitt gebildet, und für die untere Grenze entsprechend der Minimalwert. Für die Punktprognose wird der Mittelwert gebildet. Anschließend wird die theoretisch einzusparende Gesamtregelleistung, d.h. die Differenz zur vorgehaltenen Gesamtmenge aus SRL und MRL bestimmt. Diese Differenz-Leistungsmenge wird anschließend mit dem mittleren Leistungspreis für Minutenreserveleistung (MRL) im entsprechenden Zeitabschnitt multipliziert, so dass man anschließend auch eine monetäre Bewertung der eingesparten Leistungsmengen erhält¹⁵. Diese Werte werden anschließend jeweils monatlich gemittelt und tabellarisch aufbereitet. Das Vorgehen wird exemplarisch für das Jahr 2013 vorgestellt.

Abbildung 4.31 zeigt die Anwendung des Prognosemodells KNN auf die Regelleistungsbemessung für einen Beispieltag am 03. März 2013. Auf der linken Seite ist das Ergebnis für 100 Nachbarn und auf der rechten Seiten für 500 Nachbarn dargestellt. Die obere Abbildung zeigt die Ergebnisse des Prognosemodells, die mittlere Abbildung zeigt die Wandlung in Ein-Stunden-Blöcke und die untere Reihe zeigt die Wandlung in Vier-Stunden-Blöcke. Die mittlere durchgezogene Linie zeigt den vorhergesagten Saldo des jeweiligen Modells, d.h. den stündlichen bzw. vierstündlichen Mittelwert der Punktprognose. Die darüber liegende gestrichelte Linie zeigt den jeweils oberen Wert für den Regelsaldo im entsprechenden Zeitabschnitt, während die untere gestrichelte Linie jeweils den unteren Wert zeigt. Der Bereich zwischen den beiden mittleren gestrichelten Linien zeigt somit die Spanne des Saldos innerhalb des Zeitintervalls. Idealerweise sollte die durchgezogene Linie somit genau in der Mitte zwischen den beiden gestrichelten Linien liegen. Wichtiger als der Punktschätzer ist allerdings die Einhaltung der oberen und unteren Grenzen. So müssen die gestrichelten Linien oben und unten jeweils unter bzw. oberhalb der durchgezogenen Linien liegen, ansonsten würde es bedeuten, dass die Regelleistung nicht ausgereicht hätte. Diese Tatsache ist für alle Abbildungen gegeben, allerdings nimmt der Sicherheitsabstand sowohl von links nach rechts als auch von oben nach unten zu. So steigt das Sicherheitsniveau sowohl mit der Länge der Kontrakte als auch mit der Anzahl an Nachbarn. Man erkennt jedoch deutlich, dass der Unterschied zwischen den unterschiedlichen Anzahlen von Nachbarn mit Zunahme der Blocklänge abnimmt. So unterscheiden sich die unteren Abbildungen nur noch geringfügig im Bereich der unteren Grenze. Dies hat zur Folge, dass der Sicherheitsabstand um 20:00 Uhr bei 500 Nachbarn deutlich größer ist als bei 100 Nachbarn.

Anders sieht das Ergebnis für die GBT aus, welches in Abbildung 4.32 dargestellt ist. Hier unterscheiden sich die Ergebnisse für die unterschiedlichen *alpha*-Werte erheblich. So nimmt das Einsparpotential für ein *alpha* von 0.9999 gegenüber einem *alpha* von 0.99 deutlich ab. Des Weiteren ist der Unterschied zwischen den 15 Minuten Intervallen und den Vier-Stunden-Kontrakten nicht derart ausgeprägt wie bei den KNN. Dies ist damit begründet, dass die Grenzen bereits bei den 15 Minutenintervallen wesentlich „glatter“ waren als bei den KNN. Die monatlichen Einsparpotentiale für das gesamte Jahr 2013 zeigen die Abbildungen 4.33 und 4.35 jeweils für Ein-Stunden bzw. Vier-Stunden Ausschreibungen.

¹⁵ Der größte Anteil einzusparender RL ergibt sich im Bereich der MRL, der geringe Anteil einzusparender SRL, der in der Folge mit dem – im Vergleich – zu niedrigem MRL-Preis bewertet wird, ist vernachlässigbar gering.

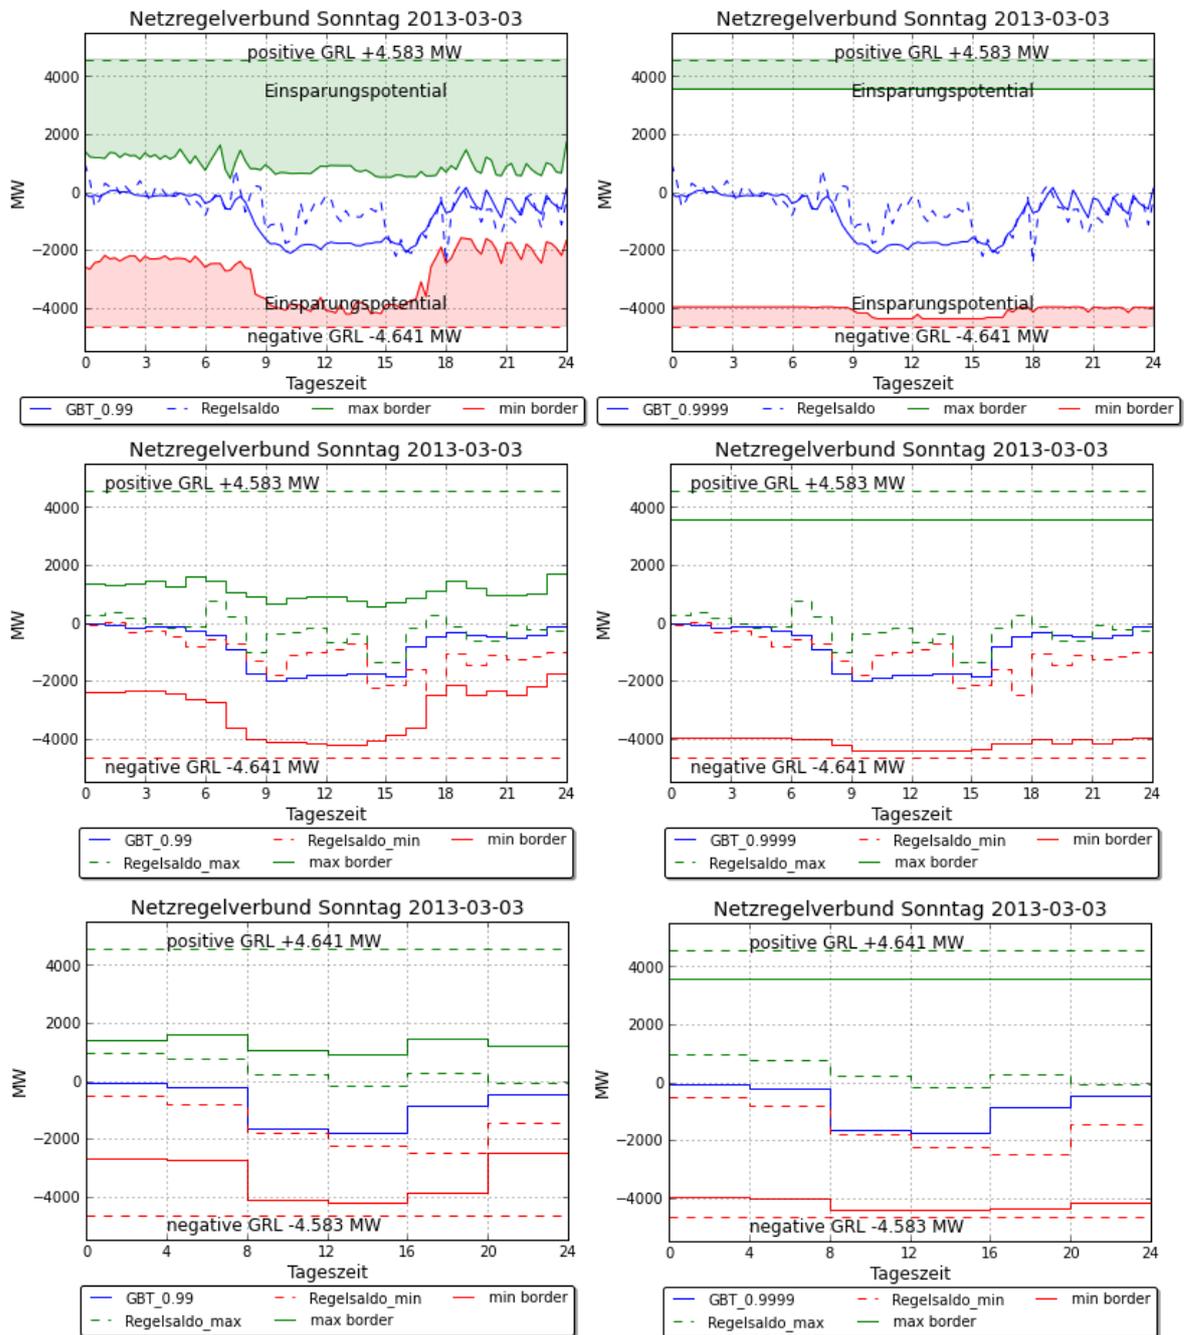


Abbildung 4.32: Anpassung an die 1h/4h Blöcke für die Werte aus den GBT

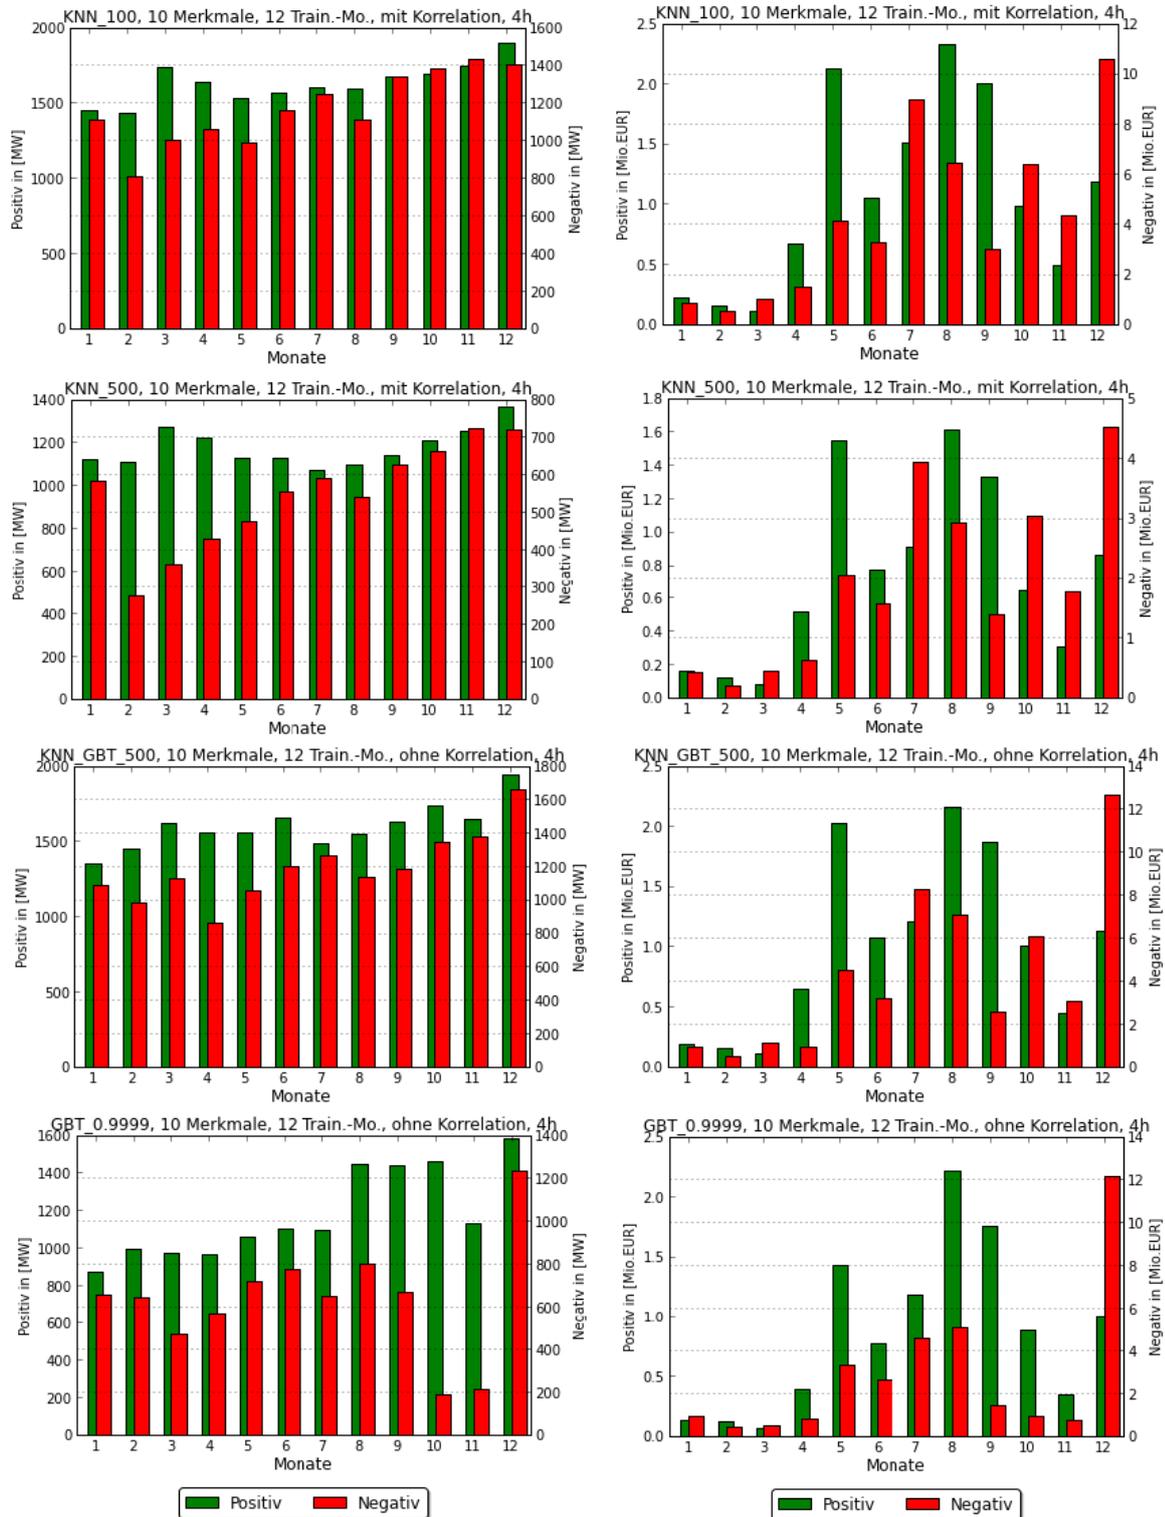


Abbildung 4.33: Einsparungspotentiale für das Jahr 2013 für 4 Stunden Blöcke

Auf der linken Seite ist jeweils die mögliche einzusparende Regelleistungsmenge in MW angegeben. Die hinteren (grünen) Balken zeigen die einzusparende positive Regelleistungsmenge und sind auf der linken y-Achse abzulesen, während die vorderen (roten) Balken die einzusparende negative Regelleistungsmenge zeigen (rechte y-Achse). Dabei repräsentiert jeder Balken den monatlichen Mittelwert. Von oben nach unten erhöht sich die Anzahl Nachbarn von 100 auf 500 bzw. die untere Reihe zeigt die Ergebnisse für den GBT mit einem α von 0.9999. An der unterschiedlichen Skalierung der y-Achsen zeigt sich, dass mehr positive Regelleistung eingespart werden kann. Dieser Unterschied ist jedoch hauptsächlich bei der Berücksichtigung der Korrelation zu beobachten (zweite Zeile). Hier ließen sich insbesondere in den Monaten Februar bis Mai nur geringe negative Leistungsmengen einsparen. Ohne Berücksichtigung der Korrelation ist der Unterschied zwischen positiver und negativer RL nicht derart auffällig. Die eingesparten Mengen sind für KNN über das Jahr hinweg relativ einheitlich und liegen im Mittel für KNN_500 bei 1.388 MW (negativ) und 1.668 MW (positiv). Für die GBT lässt sich zum Ende des Jahres deutlich mehr positive Regelleistung einsparen während die Mengen für die negative Regelleistung sinken. Im Dezember ist ein auffälliger Anstieg der einzusparenden Mengen erkennbar. Dieses Verhalten ist eine Folge der Verschiebung des Mittelwertes in den negativen Bereich bzw. der geringen negativen Ausprägungen des Saldos im Dezember, wie er bei der Auswertung des Regelsalos in Kapitel 2 (siehe Abbildung 2.17, Seite 35) gezeigt werden konnte. Bei den KNN bewirkt die Hinzunahme der Korrelation eine deutliche Reduzierung der Einsparmengen. So beträgt die durchschnittliche Menge in Bezug auf die negative Regelleistung nur noch 544 MW. Dies ist mehr als eine Halbierung. Bei den GBT ist das Einsparpotential allgemein niedriger als bei den KNN; so liegt der Mittelwert bei 1.180 MW (positiv) und 633 MW (negativ). Das heißt auch hier halbieren sich die Einsparmengen in Bezug auf die negative Regelleistung.

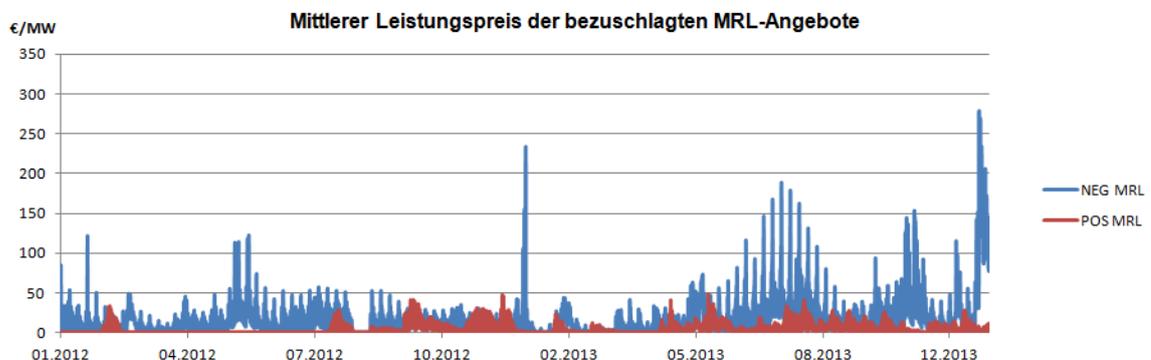


Abbildung 4.34: Preise MRL

Aufgrund der sehr unterschiedlichen Preisniveaus für die Regelleistung im Verlauf des Jahres ergibt sich auf der rechten Seite der Abbildung 4.33 für die einzusparende Mengen in Euro ein sehr differenziertes Bild. Die einzusparenden Mengen in Euro werden ermittelt, indem die Leistungsmenge jeweils mit dem mittleren Leistungspreis für MRL multipliziert wird. Man erkennt eine dreieckige Form mit einem Maximum im Sommer sowie weiteren Spitzen im Oktober und Dezember. Auch hier haben die positiven und negativen Mengen jeweils eine eigene y-Achse und damit Skalierung, da die Preise für negative Regelleistungsvorhaltung deutlich höher sind. So zeigt sich, dass sich in Bezug auf die Mengen zwar wesentlich mehr positive Regelleistung einsparen lässt, in der monetären Bewertung jedoch die negative Regelleistung aufgrund der wesentlich höheren Leistungspreise den

Ausschlag gibt. So liegen die einzusparenden Kosten bei KNN_500 ohne Berücksichtigung der Korrelation bei 12.486 TEUR (positiv) und 61.336 TEUR (negativ), d.h. die negativen „Gewinne“ sind fünfmal so hoch. Bei den GBT beträgt der Unterschied immerhin noch das dreifache. Auffällig ist der extreme Anstieg im Dezember. So wird ca. ein fünftel der „Gewinne“ durch den vergleichsweise hohen Leistungspreis alleine im Dezember generiert. Vergleicht man die rechten Abbildungen mit dem Preisverlauf für die Leistungspreise MRL, wie er in Abbildung 4.34 dargestellt ist, so entspricht der Verlauf der einzusparenden Kosten genau dem Verlauf des Preisniveaus.

Würde man die Ausschreibungszeitscheiben in Ein-Stunden-Blöcke umwandeln, würden sich die einzusparenden Mengen entsprechend erhöhen, wie dies in Abbildung 4.35 erkennbar ist. So ließen sich die „Gewinne“ in etwa auf das 1,4-fache steigern. Wie im vorherigen Kapitel gezeigt, geht dies allerdings zu Lasten des Sicherheitsniveaus. Da die Empirie gezeigt hat, dass sich die Regelleistungspreise bei geringeren Zeitscheiben und einer höheren Zahl an Anbietern reduzieren, stellen die dargestellten Einsparpotentiale Höchstgrenzen dar.

Im Folgenden werden die einzelnen Simulationsfälle – wie sie in Kapitel 4.2 untersucht wurden – in Bezug auf die drei Zielfunktionen ausgewertet. So werden jeweils die Defizitwahrscheinlichkeiten, die mittleren Fehler, sowie die Einsparungspotentiale berechnet. Dazu werden für die Methoden KNN_100, KNN_500, KNN_GBT_500, GBT_0.9975 sowie GBT_0.9999 jeweils die jährlichen Mittelwerte (RMSE, Einsparpotentiale) bzw. Höchstwerte (Defizit- Überschusswahrscheinlichkeit) ermittelt. Für die Einsparpotentiale in [TEUR] sind jeweils die jährlichen Summen angegeben¹⁶. Die Ergebnisse sind in Tabelle 4.1 zusammenfassend dargestellt¹⁷. In Bezug auf das notwendige Kriterium des Sicherheitsniveaus wird die geforderte Grenze auf 0,2% gesetzt (dies entspricht dem tatsächlich realisierten Niveau im Jahr 2013). Dementsprechend können nur die türkis eingefärbten Parametereinstellungen das geforderte Niveau erreichen. Dies sind die Simulationsfälle „10_12“ (Zehn Merkmale mit zwölf Trainingsmonaten) sowie der Fall mit Berücksichtigung der Korrelation (10C_12) bzw. einer zusätzlichen Doppeltgewichtung der Merkmale (10CDW). Für die Parameterbelegung der Methoden selbst ist der KNN_100 (10CDW) und der KNN_500 (10C_12, 10CDW) in der Lage das Niveau zu halten. Eine Kombination der beiden Methoden (KNN_GBT) reduziert die Defizitwahrscheinlichkeiten und erzielt selbst im Simulationsfall ohne EE-Fehler sehr gute Ergebnisse. Der GBT mit einem α von 0.9999 in ebenfalls in der Lage das Sicherheitsniveau im geforderten Niveau zu halten. Aufgrund der wesentlich größeren Einsparpotentiale ohne Berücksichtigung der Korrelation bei gleichem Sicherheitsniveau werden für die weiteren Berechnungen bzw. die Vergleichsevaluation mit der DESIRE-Studie im nächsten Abschnitt die folgenden Simulationsfälle ausgewählt:

- 10_12: 10 Merkmale und 12 Trainingsmonate
 - KNN_GBT : mit 500 Nachbarn
 - GBT : mit einem alpha von 0,9999
- 8_12: 8 Merkmale und 12 Trainingsmonate (ohne EE-Prognosefehler)
 - KNN_GBT : mit 500 Nachbarn
 - GBT : mit einem alpha von 0,9999

¹⁶ Für eine bessere Lesbarkeit sind die Einsparpotentiale positiv dargestellt, obwohl es sich natürlich um Mindermengen handelt.

¹⁷ Die Tabellen mit den Einzelergebnissen für KNN-100 sowie GBT-0.975 befinden sich im Anhang.

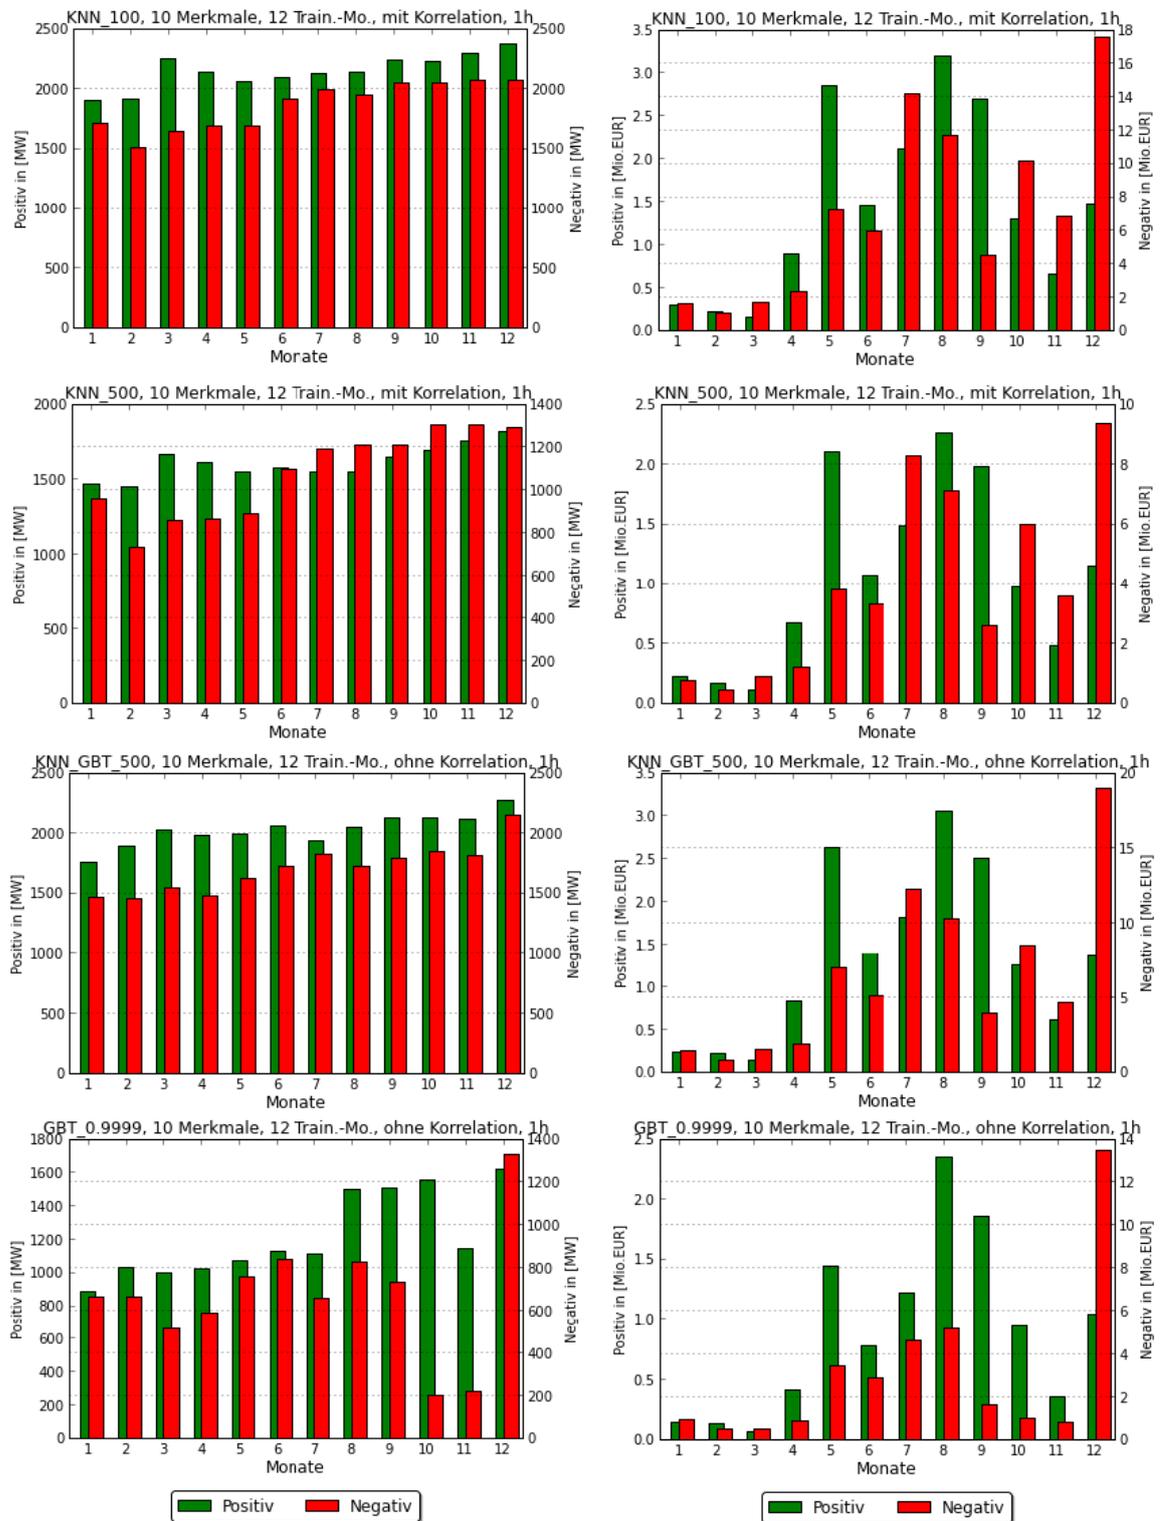


Abbildung 4.35: Einsparungspotentiale für das Jahr 2013 für 1 Stunden Blöcke

Sim-Case	10_12	6_3	10_3	10C_12	6C_12	8_12	10CDW
Merkmale	10	6	10	10	6	8	10
Monate	12	3	3	12	12	12	12
Korrelation	nein	nein	nein	ja	ja	nein	ja+DW
KNN_100							
PU4 []	0,006	0,011	0,013	0,002	0,006	0,005	0,002
PL4 []	0,007	0,008	0,006	0,003	0,007	0,006	0,002
RSME [MW]	681	685	680	681	685	712	652
Pos. [MW]	2.184	2.462	2.455	1.629	2.157	2.021	1.708
Neg. [MW]	2.007	2.282	2.290	1.169	1.905	1.805	1.319
Pos. [TEUR]	16.780	18.821	18.742	12.811	16.641	14.710	12.908
Neg. [TEUR]	91.800	116.215	116.965	50.939	82.319	78.919	59.192
KNN_500							
PU4 []	0,002	0,004	0,004	0,002	0,002	0,002	0,002
PL4 []	0,005	0,005	0,005	0,001	0,002	0,003	0,001
RSME [MW]	666	674	672	675	671	697	684
Pos. [MW]	1.668	2.016	2.017	1.176	1.682	1.454	1.1293
Neg. [MW]	1.388	1.813	1.800	544	1.324	1.288	762
Pos. [TEUR]	12.486	15.508	15.472	8.834	12.520	10.047	9.660
Neg. [TEUR]	61.336	94.138	93.499	22.858	55.328	52.969	35.120
KNN_GBT_500							
PU4 []	0,002	0,004	0,004	0,002	0,002	0,002	0,002
PL4 []	0,001	0,005	0,005	0,001	0,001	0,002	0,001
RSME [MW]	665	676	674	673	674	700	682
Pos. [MW]	1.190	1.755	1.704	477	436	1.149	633
Neg. [MW]	1.597	1.989	2.002	1.142	1.165	1.369	1.253
Pos. [TEUR]	12.004	15.334	15.457	8.541	8.901	9.210	9.039
Neg. [TEUR]	50.804	92.745	90.349	19.576	16.279	45.273	27.995
GBT_0.9975							
PU4 []	0,002	0,013	0,015	0,002	0,002	0,005	0,002
PL4 []	0,005	0,015	0,005	0,009	0,005	0,004	0,003
RSME [MW]	656	688	678	665	656	679	662
Pos. [MW]	2.191	2.395	2.422	1.938	2.108	2.038	2.035
Neg. [MW]	1.845	2.147	2.179	1.650	1.750	1.759	1.682
Pos. [TEUR]	17.550	19.281	19.370	15.415	17.102	15.569	16.137
Neg. [TEUR]	85.152	109.931	111.803	76.650	74.809	77.336	77.074
GBT_0.9999							
PU4 []	0,002	0,006	0,006	0,002	0,002	0,002	0,002
PL4 []	0,002	0,004	0,004	0,003	0,002	0,002	0,002
RSME [MW]	656	688	678	665	656	679	662
Pos. [MW]	1.180	1.551	1.560	1.047	1.116	1.079	1.070
Neg. [MW]	633	1.224	1.228	332	516	740	595
Pos. [TEUR]	10.327	12.732	12.747	8.423	9.356	8.831	8.841
Neg. [TEUR]	33.483	73.725	73.995	12.594	22.692	32.127	29.040

Tabelle 4.1: Ergebnis der Einsparungspotentiale für das Jahr 2013 Vergleich der Simulationsfälle auf 4 Stunden Basis

4.3.3 Vergleich mit der situativen faltungs-basierten Bemessung

Im Rahmen des Projekts „DESIRE - Marktdesign für zukunftsfähige Elektrizitätsmärkte unter besonderer Berücksichtigung der vermehrten Einspeisung von erneuerbaren Energien“ wurde von der Universität Duisburg, BET und Trianel (gefördert durch das Bundeswirtschaftsministerium) das Marktdesign zukünftiger Elektrizitätsmärkte untersucht[Buc14]. Ein Schwerpunkt war die Weiterentwicklung von Kurzfrist- und Regelleistungsmärkten, unter anderem die Weiterentwicklung des aktuellen Regelleistungsmarkt-Designs. In diesem Zusammenhang wurde die Auswirkung einer sogenannten „situativen Regelleistungsbemessung“ auf die Vorhaltekosten untersucht.

Untersuchungen im Rahmen des Projekts haben ebenfalls eine zeit- und wochentag-abhängigen Bedarf an Regelleistung ermittelt (eine genaue Beschreibung des Vorgehens siehe (Kapitel 2.3.2)). So kommen die Gutachter zu der Erkenntnis, dass „der Reservebedarf vor allen in den Nebenzeiten (20:00 bis 8:00 Uhr) u.a. durch den wegfallenden Einfluss der fluktuierenden Photovoltaikeinspeisung in den Nachtstunden sowie geringerer Nachfrageschwankungen an Wochenenden und Feiertagen geringer sein dürfte“ (DESIRE Studie, Seite 114). Daher wurde der aktuelle faltungs-basierte Ansatz weiterentwickelt, indem der RL-Bedarf jeweils für Vier-Stunden-Blöcke berechnet wurde. Als Sicherheitsniveau wurden dabei 99,9971 % angesetzt. Das entspricht einem Defizitniveau von 0,0029 % (15 Minuten pro Zeitscheibe)¹⁸. Als Ergebnis der Studie konnte gezeigt werden, dass sich in den Nebenstunden Regelleistung einsparen ließe, während diese in den Hauptzeiten leicht ansteigt. Die Einsparungen beliefen sich auf durchschnittlich 362 MW positive Regelleistung und 450 MW negative Regelleistung.

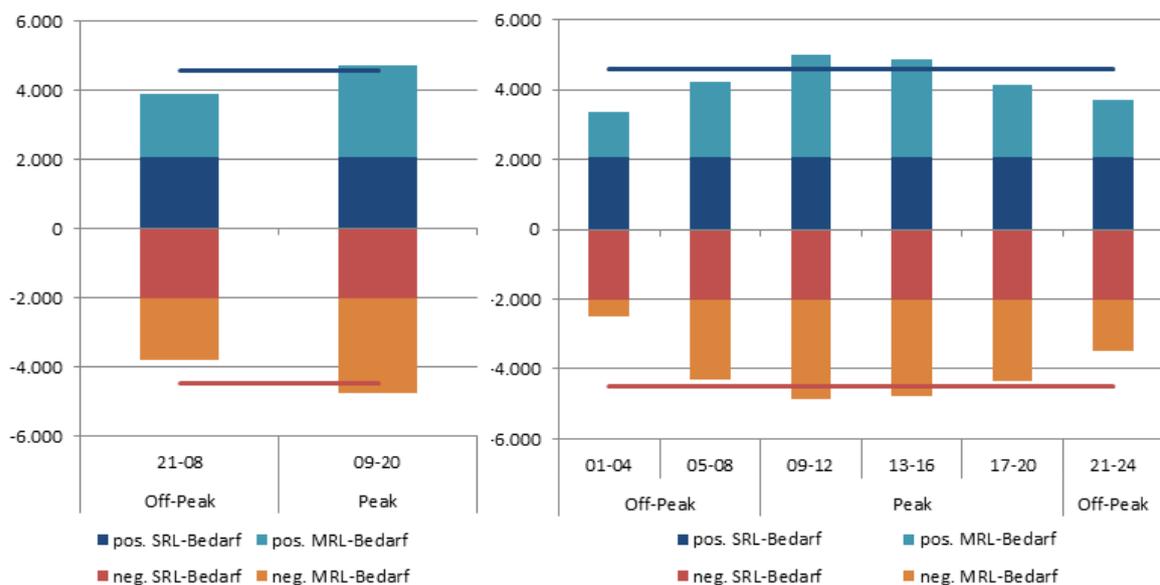


Abbildung 4.36: Ergebnis der Einsparungspotentiale für das Jahr 2013 DESIRE[BET2014]

Die Einsparungen wirken sich dabei nur unwesentlich auf die Sekundärregelleistung aus, sondern vielmehr auf die Minutenreserve. So lassen sich bei der Minutenreserve ein Einsparpotentiale in den NT-Zeiten von bis zu 2.017 MW für negative MRL und bis zu 1.219 MW für positive MRL ge-

¹⁸ Das entspricht damit bei sechs Zeitscheiben genau dem aktuellen Sicherheitsniveau.

nerieren. Eine Unterscheidung zwischen den einzelnen Monaten wurde in dieser Studie nicht vorgenommen. Die Ergebnisse sind in Abbildung 4.36 zusammengefasst. Dabei zeigen die durchgezogenen Linien jeweils die zum Vergleich angesetzten aktuell vorgehaltenen Menge auf die sich die Einsparpotentiale der Studie beziehen. Im Folgenden werden die Ergebnisse dieser Arbeit mit denen der Studie verglichen. Allerdings wird im Rahmen dieser Arbeit keine strikte Trennung nach den Stundenblöcken vorgenommen, bzw. die Uhrzeit ist nur eins von mehreren Zeitmerkmalen. Zur Vergleichbarkeit werden die Ergebnisse dieser Arbeit daher in die Zeitscheiben am Regelleistungsmarkt umgerechnet, das Vorliegen des Monatsmerkmals wird jedoch weiterhin für die Unterscheidung in Sommer- und Wintermonate genutzt, so sind in Tabelle 4.3. und 4.4. die Einsparpotentiale der Studie mit denen der KNN_GBT und des GBT gegenübergestellt¹⁹. Für die KNN und GBT wurde jeweils der Simulationsfall 10_12 gewählt mit 500 Nachbarn für KNN und einem alpha für 0.9999 für GBT, da dieser Simulationsfall mit dem in der Studie gewählten sehr hohen Sicherheitsniveau vergleichbar ist. Die Werte „Theorie-Wi“, „Theorie-So“ ergeben sich, wenn man die tatsächlich realisierte Verteilung des Regelsaldos in Bezug auf die Jahres- und Tageszeiten für das Jahr 2013 filtert, und entsprechend der Defizitwahrscheinlichkeiten²⁰ die vorzuhaltenden Mengen berechnet. Dieses Vorgehen ist exemplarisch in Abbildung 4.37 dargestellt. Dabei zeigen die durchgezogenen senkrechten Linien jeweils die berechnete RL-Menge (entsprechen den oberen Werten) und die gestrichelte Linie zeigt jeweils die vorgehaltene Menge (unter Werte)²¹.

Einsparpotential negative MRL in [MW]							
Zeitscheibe	Theorie-Wi	Theorie-So	Studie	KNN-Wi	KNN-So	GBT-Wi	GBT-So
00:00-04:00	-2.226	-2.634	-2.017	-1.354	-1.537	-682	-659
04:00-08:00	-50	-2.421	-215	-1.054	-1.213	-672	-660
08:00-12:00	-129	-152	+386	-1.278	-1.006	-580	-627
12:00-16:00	-207	-128	+282	-1.199	-1.007	-564	-612
16:00-20:00	-1.510	-2.393	-134	-1.327	-1.106	-635	-640
20:00-24:00	-1.097	-1780	-877	-1.190	-1.095	-648	-621

Tabelle 4.2: Ergebnis der Einsparpotentiale für negative MRL im Vergleich

Einsparpotential positive MRL in [MW]							
Zeitscheibe	Theorie-Wi	Theorie-So	Studie	KNN-Wi	KNN-So	GBT-Wi	GBT-So
00:00-04:00	-2.791	-1.915	-1.219	-1.808	-1.957	-1.138	-1.284
04:00-08:00	-2.132	-1.676	-342	-1.555	-1.582	-1.126	-1.214
08:00-12:00	-1.727	-69	+419	-1.409	-1.388	-1.104	-1.185
12:00-16:00	-2.176	-902	+399	-1.409	-1.396	-1.110	-1.168
16:00-20:00	-746	-1.463	-457	-1.668	-1.483	-1.125	-1.206
20:00-24:00	-1.290	-2.003	-877	-1.772	-1.759	-1.136	-1.255

Tabelle 4.3: Ergebnis der Einsparpotentiale für positive MRL im Vergleich

¹⁹ Entsprechend den Ergebnissen der Studie sind Defizitmengen im Unterschied zum vorherigen Kapitel negativ dargestellt und Mehrmengen positiv.

²⁰ Hier wurde die gleiche Defizitwahrscheinlichkeit angenommen, wie in der DESIRE Studie von 0,00285%.

²¹ Die Ergebnisse ohne Berücksichtigung der EE-Prognosefehler sind im Anhang zu finden auf Seite 168.

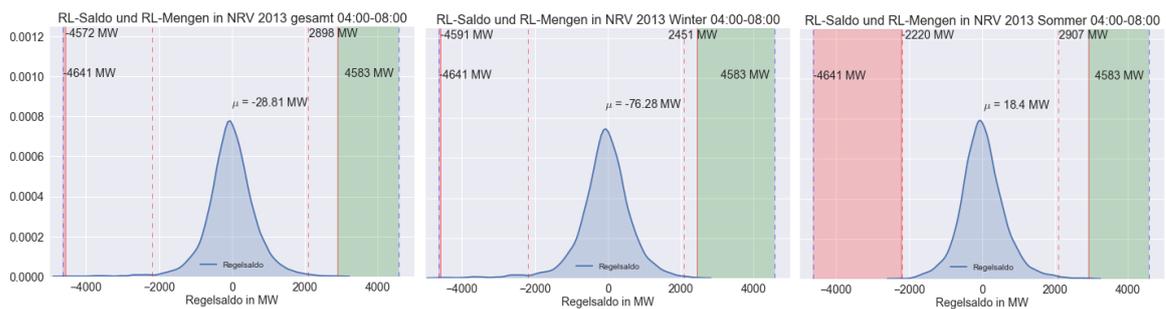


Abbildung 4.37: Tatsächlich realisierte Potentiale 2013 in verschiedenen Zeitblöcken

In der tabellarischen Auswertung auffällig ist die Differenz zwischen den Sommer- und Wintermonaten für das Einsparpotential der negativen Minutenreserve zwischen 04:00 Uhr und 08:00 Uhr morgens (fett hervorgehoben). Daher wurde diese Zeitscheibe gewählt, die theoretische Ermittlung der Mengen vorzustellen. So lässt sich in Abbildung 4.37 deutlich der Unterschied der tatsächlich realisierten Einsparpotentiale zwischen den Sommermonaten (rechts) und den Wintermonaten (Mitte) erkennen²². Betrachtet man das gesamte Jahr durchgehend (Abbildung links) ergibt sich ein sehr geringes negatives Einsparpotential. Betrachtet man allerdings die Sommermonate zwischen April und September gesondert, so ergibt sich ein bemerkenswertes Einsparpotential von 2.421 MW, was in etwa der gesamten vorgehaltenen negativen MRL entspricht. Für die positive MRL ist das Trennen zwischen den Jahreszeiten ebenfalls von Vorteil, hier ließe sich das positive Einsparpotential im Vergleich zum Gesamtjahr ebenfalls erhöhen. So unterscheiden sich die Einsparpotentiale nicht nur zwischen den Tag- und Abendstunden sondern vielmehr zwischen den Monaten. Während in den Sommermonaten das Einsparpotential an negativer MRL während der Nachtstunden groß ist, ist der Bedarf während der Wintermonaten sogar teilweise höher.

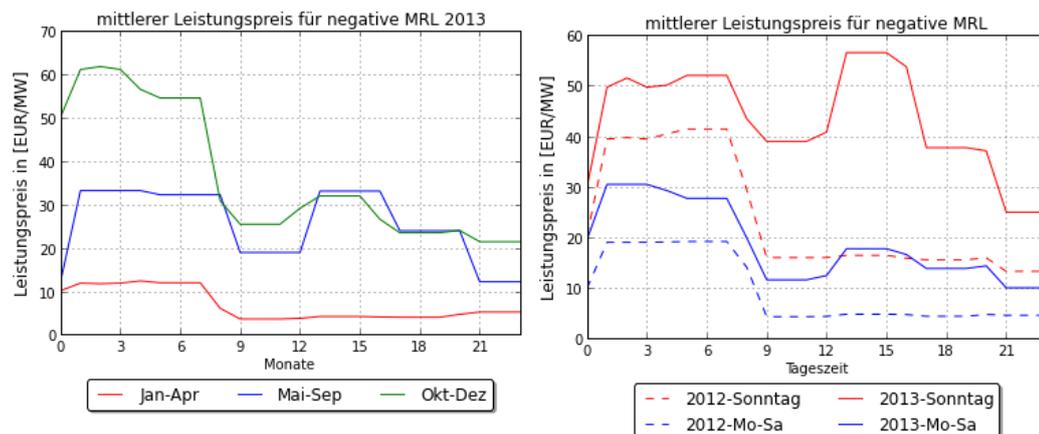


Abbildung 4.38: Leistungspreis für Minutenreserve nach Monaten und Uhrzeiten

²² Die Unterscheidung zwischen Sommer und Winter erfolgte mit Bezug zur Zeitumstellung, d.h. der Sommer gilt hier von April bis September.

Abschließend erfolgt ein Vergleich der monetären Bewertung der Einsparpotentiale. Dabei werden die zuvor aufgeführten Parameterbelegungen (Sim-Case 10_12 und 08_12) verglichen. Die Ergebnisse zeigen, dass in der Studie das meiste Potential nachts zwischen 00:00 Uhr und 04:00 Uhr generiert wurde. So wurden alleine mit der negativen MRL 30 Mio. EUR eingespart, was einem Anteil von 64 % entspricht. Bei den KNN_GBT und den GBT dieser Arbeit lassen sich zwar ebenfalls in dieser Zeitscheibe die meisten Kosten einsparen, ca. 17 Mio. EUR (KNN) und 8 Mio. EUR (GBT), allerdings lassen sich im folgenden Zeitabschnitt zwischen 04:00 Uhr und 08:00 Uhr ebenfalls ähnliche Größenordnungen einsparen. Auffällig ist, dass diese Summe zum größten Teil im Sommer generiert wird (70 %). Dies liegt an den sehr unterschiedlichen Preisen für die MRL im Verlauf des Jahres. Abbildung 4.38 zeigt den mittleren Leistungspreis für MRL im Verlauf des Jahres 2013, links im Bezug auf die Monate und rechts im Vergleich mit dem Jahr 2012 bzw. in Bezug auf die Wochentage. In der linken Abbildung entsprechen die Kurven von oben nach unten der Legende von rechts nach links. So waren im Herbst die höchsten Preise zu erzielen, gefolgt vom Sommer, während die Preise zu Jahresbeginn deutlich niedriger waren. Insbesondere der Preisunterschied zwischen den Nacht- und den Tagesstunden hat im Verlauf des Jahres zugenommen, so lag der Preisunterschied zu Beginn des Jahres unter 10 EUR, während er im Herbst ca. 30 EUR betrug. Im Vergleich zum Jahr 2012 (Abbildung rechts) haben sich die Preise zum einen deutlich erhöht, und zum anderen haben die Unterschiede zwischen den Wochentagen (Mo-Sa) und den Sonntagen (jeweils die obere Linie) zugenommen. Während die Preisdifferenz zwischen dem Sonntag und den Wochentagen im Jahr 2012 tagsüber nur 10 EUR betrug, waren es im Jahr 2013 bereits 30 EUR. Dies ist sowohl auf die veränderten Preisspannen am Wirkleistungsmarkt als auch auf die veränderte Anbietersituation am Regelleistungsmarkt zurückzuführen. So wird der Konkurrenzkampf auf beiden Märkten insbesondere für konventionelle Kraftwerke zunehmend härter und schwerer zu bestehen, was in der Folge zu weniger „Must-Run-Kapazitäten“ führt und damit zu größeren Preisdifferenzen. So kann festgestellt werden, dass die preisliche Differenzierung auf dem RL-Markt, insbesondere für negative RL, im Jahr 2013 deutlich stärker ausgeprägt war, und zwar sowohl zwischen den Monaten, den Wochentagen als auch zwischen den Tageszeiten. In Bezug auf die einzusparenden Gesamtmengen nehmen diese für die Modelle dieser Arbeit in der Tabelle von links nach rechts ab, d.h. die größten Kosten (63 Mio. EUR) ließen sich mit KNN_GBT_500 mit Kenntnis der Prognosefehler erzielen und die geringsten Werte (41 Mio. EUR) werden mit den GBT ohne Kenntnis der Fehler generiert. Unbeachtet der Kenntnis des EE-Fehlers besteht bei den Parametereinstellungen immer ein Trade-Off zwischen den Einsparungsmengen und dem Sicherheitsniveau. Insgesamt lassen sich die Ergebnisse dieser Arbeit gut in die Ergebnisse der Studie (47. Mio. EUR) einordnen. Insbesondere für den vergleichbaren Fall (8_12) liegen die Ergebnisse der Studie genau zwischen den Ergebnissen der KNN_GBT und der GBT. Dabei ist das Sicherheitsniveau der KNN_GBT im Vergleich der GBT für die untere Grenze sogar höher bei gleichzeitig höherem Einsparpotential, liegt jedoch unter dem Wert der Studie. Anzumerken ist, dass es sich bei der Vorhersage in der Studie um eine Einstundenprognose handelt. In Kenntnis besserer Prognosezeitreihen – ebenfalls eine Stunde im voraus – ist für das Prognosemodell dieser Arbeit mit besseren Ergebnissen zu rechnen.

	Positive MRL						Negative MRL						Summe									
	Einsparpotential[TEUR]						Einsparpotential[TEUR]						Einsparpotential [TEUR]									
	DESIRE	KNN _GBT 500	KNN _GBT 500	GBT	GBT	GBT	DESIRE	KNN _GBT 500	KNN _GBT 500	GBT	GBT	GBT	DESIRE	KNN _GBT 500	KNN _GBT 500	GBT	DESIRE	KNN _GBT 500	KNN _GBT 500	GBT	GBT	
Zeit		10_12	8_12	10_12	8_12	8_12		10_12	8_12	10_12	10_10	8_12		10_12	8_12	10_12		10_12	8_12	10_12	10_12	8_12
00-04 Winter		8	7	6	5		6.419	5.451	4.475	4.475	2.640		6.428	5.458	4.482		6.428	5.458	4.482	4.482	4.482	2.645
00-04 Sommer		482	459	334	350		10.354	10.964	4.302	4.302	5.805		10.836	11.423	4.636		10.836	11.423	4.636	4.636	4.636	6.155
00-04 Summe	410	490	466	340	355		16.774	16.415	8.778	8.445	8.445	30.709	17.264	16.881	9.118	30.709	17.264	16.881	9.118	9.118	9.118	8.800
04-08 Winter		90	79	75	53		5.132	3.385	3.951	2.450	2.450		5.222	3.464	4.026		5.222	3.464	4.026	4.026	4.026	2.503
04-08 Sommer		975	728	754	747		6.985	6.628	4.111	4.889	4.889		7.960	7.356	4.865		7.960	7.356	4.865	4.865	4.865	5.635
04-08 Summe	349	1.065	807	829	800		12.117	10.013	8.061	7.338	7.338	7.208	13.182	10.820	8.891	7.208	13.182	10.820	8.891	8.891	8.891	8.138
08-12 Winter		344	223	329	242		1.695	1.320	1.287	900	900		2.039	1.543	1.617		2.039	1.543	1.617	1.617	1.617	1.142
08-12 Sommer		2.043	1.348	1.976	1.604		3.051	2.312	2.234	2.410	2.410		5.094	3.660	4.211		5.094	3.660	4.211	4.211	4.211	4.015
08-12 Summe	-1.433	2.387	1.571	2.306	1.847		4.746	3.632	3.5212	3.310	3.310	-2.883	7.133	5.203	5.828	-2.883	7.133	5.203	5.828	5.828	5.828	5.157
12-16 Winter		270	157	277	198		1.392	1.358	1.409	1.336	1.336		1.661	1.515	1.685		1.661	1.515	1.685	1.685	1.685	1.535
12-16 Sommer		1.602	1.196	1.605	1.316		5.188	4.429	3.723	4.494	4.494		6.790	5.625	5.328		6.790	5.625	5.328	5.328	5.328	5.810
12-16 Summe	-722	1.872	1.353	1.881	1.515		6.580	5.787	5.132	5.830	5.830	-1.646	8.452	7.140	7.013	-1.646	8.452	7.140	7.013	7.013	7.013	7.345
16-20 Winter		1.030	785	809	537		1.964	1.609	1.719	1.087	1.087		2.994	2.394	2.527		2.994	2.394	2.527	2.527	2.527	1.624
16-20 Sommer		2.311	1.811	2.040	1.689		4.077	3.628	2.826	3.256	3.256		6.388	5.439	4.866		6.388	5.439	4.866	4.866	4.866	4.945
16-20 Summe	1.474	3.341	2.596	2.848	2.227		6.040	5.237	4.545	4.343	4.343	4.716	9.382	7.833	7.393	4.716	9.382	7.833	7.393	7.393	7.393	6.569
20-24 Winter		312	236	227	154		2.363	1.748	2.027	1.092	1.092		2.675	1.984	2.254		2.675	1.984	2.254	2.254	2.254	1.247
21-24 Sommer		2.537	2.181	1.882	1.935		2.184	2.438	1.417	1.769	1.769		4.721	4.619	3.299		4.721	4.619	3.299	3.299	3.299	3.703
20-24 Summe	1.943	2.849	2.417	2.109	2.089		4.547	4.186	3.444	2.861	2.861	9.330	7.396	6.603	5.553	9.330	7.396	6.603	5.553	5.553	5.553	4.950
Summe	2.022	12.004	9.210	10.313	8.831		50.804	45.273	33.482	32.127	32.127	47.435	62.808	54.483	43.794	47.435	62.808	54.483	43.794	43.794	43.794	40.958

Tabelle 4.4: Vergleich der Einsparungspotentiale für das Jahr 2013 - DESIRE mit KNN_GBT und GBT

4.4 Ergebnisse für die einzelnen Regelzonen

Nachfolgend werden exemplarisch Ergebnisse für die einzelnen Regelzonen vorgestellt und besprochen. Dabei wird insbesondere auf die Ergebnisse in der 50 Hertz Regelzone genauer eingegangen, da diese Regelzone mit einer relativ hohen EE-Einspeisung²³ am besten zur Demonstration der EE-Einflussfaktoren geeignet ist. Für die einzelnen Regelzonen wurden als weitere Simulationsfälle auch die Parameterbelegung für die KNN mit (10,20,50) Nachbarn untersucht.

4.4.1 Ergebnisse für 50 Hertz

Abbildung 4.39 zeigt die Ergebnisse für den 01.02.2012 für KNN_GBT mit zehn Nachbarn (links) und 100 Nachbarn (rechts). Beide Parameterbelegungen können den Verlauf der realisierten Kurve gut wiedergeben. Im Fall mit 10 Nachbarn ist allerdings der starke Einbruch des prognostizierten Saldos um 06:00 Uhr auffällig, der nicht realisiert wurde. Wird die Anzahl Nachbarn erhöht, fallen derartige Einzelwerte nicht mehr in dem Maße ins Gewicht und der absolute Fehler des Punktschätzers konnte durch eine Erhöhung der Anzahl an Nachbarn reduziert werden. Das Konfidenzintervall ist im Fall von 100 Nachbarn ebenfalls deutlich breiter, folgt aber weiterhin dem Kurvenverlauf. Die Grenzen konnten bereits bei zehn Nachbarn eingehalten werden.

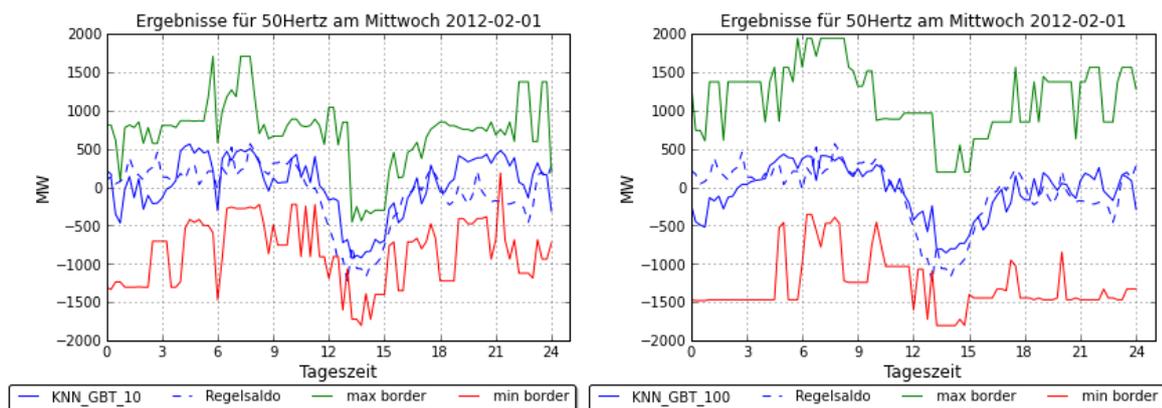


Abbildung 4.39: Ergebnisse für 50 Hertz im Februar 2012 - Vergleich 10/100 Nachbarn

Abbildung 4.40 zeigt den 01.07.2012 im Vergleich zwischen dem KNN_GBT_100 und dem GBT_0.99. Beide Verfahren können den Kurvenverlauf gut wiedergeben und die Grenzen werden ebenfalls in beiden Fällen eingehalten, sieht man von der unteren Grenzverletzung um 01:30 Uhr ab. Auf diesen starken Abfall des Regelzonensaldos wurde bereits in der Auswertung des NRV hingewiesen²⁴. Er resultiert aus einem extrem starken Windfehler (Windüberschuss) wie die Abbildung 4.41 zeigt. So folgt die Kurve des Regelzonensaldos exakt der des Windfehlers, während sie in den übrigen Stunden zwar dem Verlauf des Windfehlers weiter folgt, jedoch nicht direkt mit diesem überlagert ist. Zu sehen ist dies insbesondere zwischen 21:00 Uhr und 24:00 Uhr. Den Anstieg des Saldos in dieser Zeit konnten beide Methoden gut prognostizieren. Abbildung 4.42 zeigt den partiellen Zusammenhang

²³ Dies ist in Relation zur vertikalen Netzlast zu verstehen.

²⁴ In der Prognose des NRV konnte die Grenze gehalten werden.

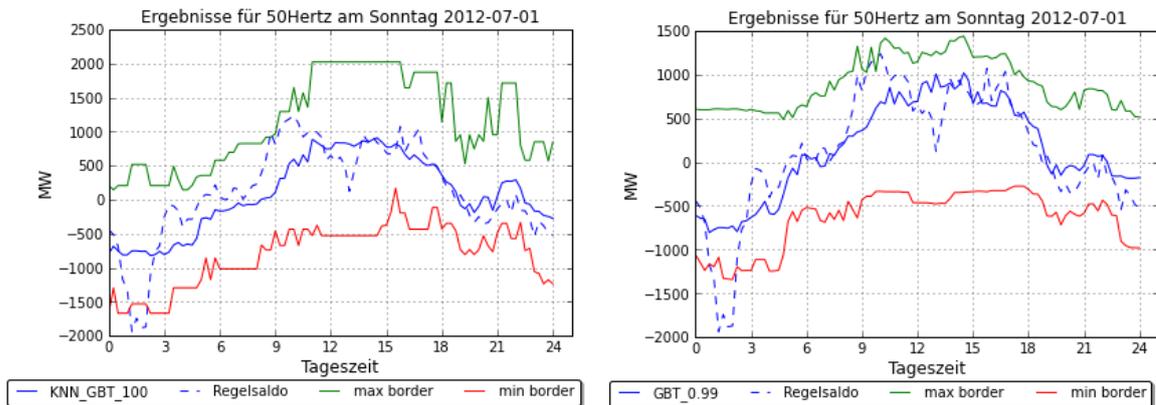


Abbildung 4.40: Ergebnisse für 50 Hertz im Juli 2012 - Vergleich KNN_GBT mit GBT

zwischen dem Regelzonensaldo, dem Windfehler und der vertikalen Netzlast in der Regelzone von 50 Hertz. So ist in der rechten Abbildung der eindeutige lineare Zusammenhang zwischen dem Windfehler und dem Regelzonensaldo zu erkennen, in der linken Abbildung ist zudem die Wechselwirkung mit der vertikalen Netzlast zu erkennen. So führt ein negativer Windfehler in Zeiten schwacher Netzlast zu einem extrem niedrigen Regelzonensaldo, während der gleiche Windfehler in Zeiten extrem hoher vertikaler Netzlast zu einem ausgeglichenen Regelzonensaldo führt.

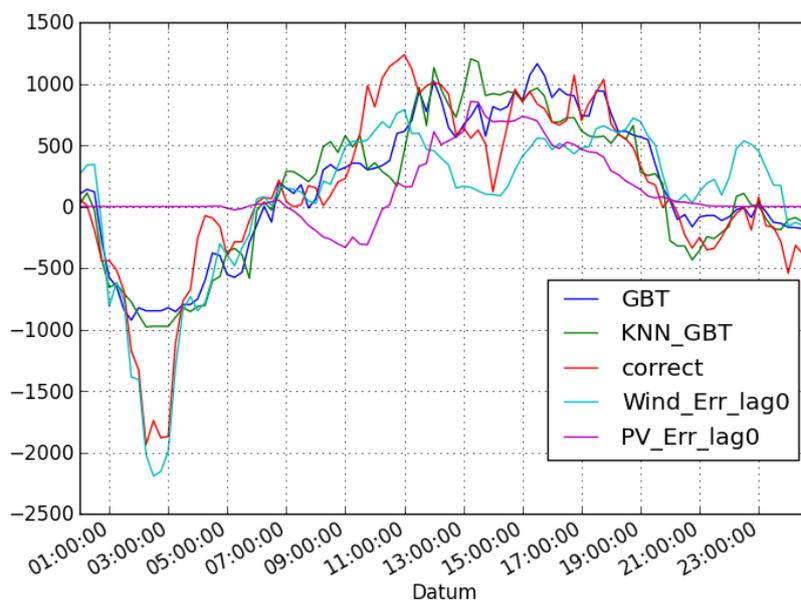


Abbildung 4.41: Beispieltag Dienstag, der 01.07.2012 in der Regelzone 50 Hertz

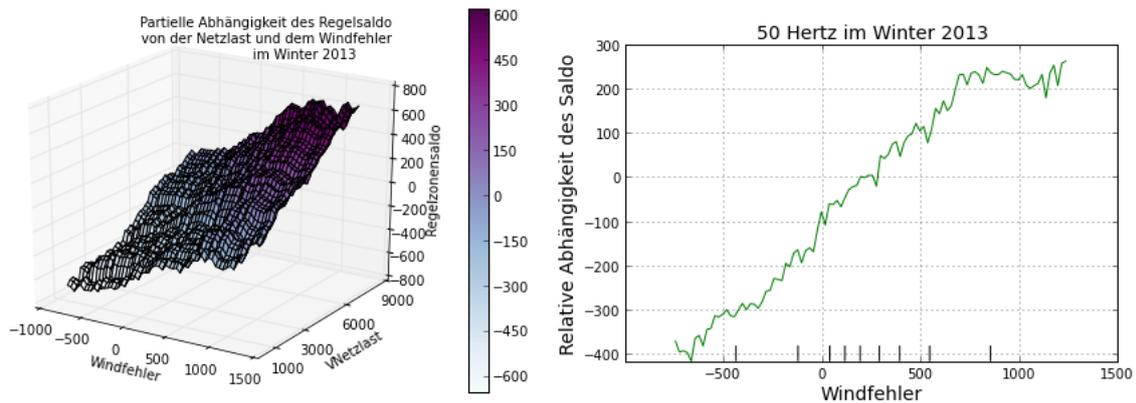


Abbildung 4.42: Partielle Abhängigkeit zwischen dem Regelzonensaldo und dem Windfehler im Winter 2013

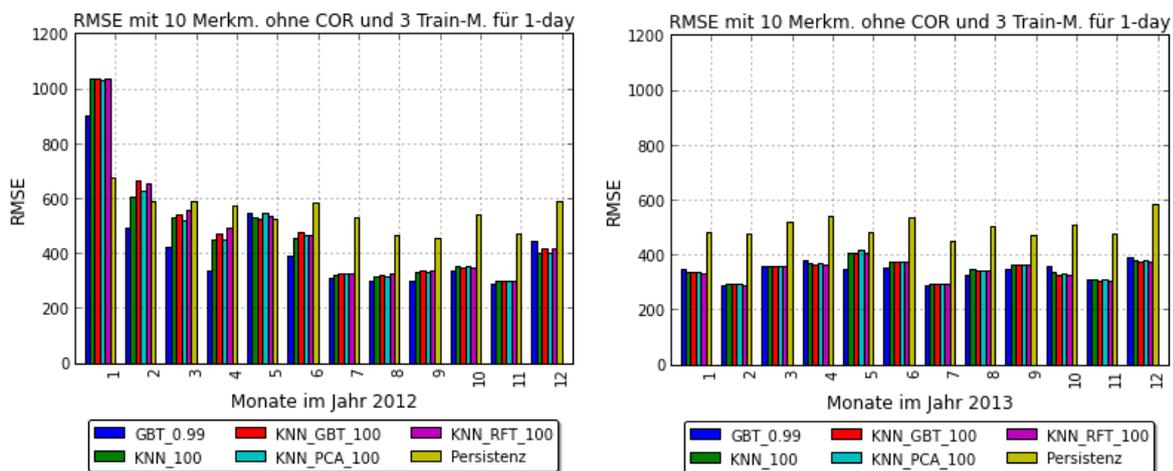


Abbildung 4.43: RMSE der einzelnen Methoden für 50 Hertz in den Jahren 2012 und 2013

Abbildung 4.43 zeigt den Vergleich des RMSE für die Regelzone 50 Hertz im Jahr 2012 und 2013²⁵. Man erkennt, dass alle Methoden ab dem Juli 2012 deutlich besser performen als die Persistenz. Im Jahr 2012 fallen insbesondere die Monate Februar, März und Mai mit relativ hohen Fehlerwerten auf. Der GBT zeigt in allen Monaten sehr gute Ergebnisse, die abgesehen vom Januar 2012, immer unter denen der Persistenz liegen. Die Gründe hierfür wurden bereits in vorangegangenen Kapitel erläutert und liegen insbesondere an den Windprognosefehlern. Diese haben in Regelzonen wie 50 Hertz mit einem hohen Anteil Erzeugung aus Windkraftanlagen einen großen Einfluss. Der Januar 2012 stellt sicherlich einen Sonderfall dar. Dieser Monat war gezeichnet durch extrem hohe Varianzen im Regelsaldo, der sich auch im relativ hohen Fehlerwert der Persistenz spiegelt. So lag der Wert im Januar 2012 im Mittel 600 MW entfernt vom Vortagswert. Dies wird deutlich wenn man sich die Verteilungen des Regelzonensaldos jeweils für den Januar in den Jahren 2012 und 2013 im

²⁵ Die genauen Zahlenwerte sind tabellarisch im Anhang zusammengestellt.

Vergleich anschaut, wie er in Abbildung 4.44 dargestellt ist. Die Standardabweichung im Januar 2012 lag bei 552 MW und war damit deutlich höher als im Vergleichsmonat 2013, wo diese lediglich bei 337 MW lag. Stellt man diese Standardabweichungen in Relation zum Mittelwert im jeweiligen Jahr, so beträgt die Standardabweichung im Jahr 2012 das 1,2 fache, während sie im Januar 2013 nur das 0,87 fache betrug.

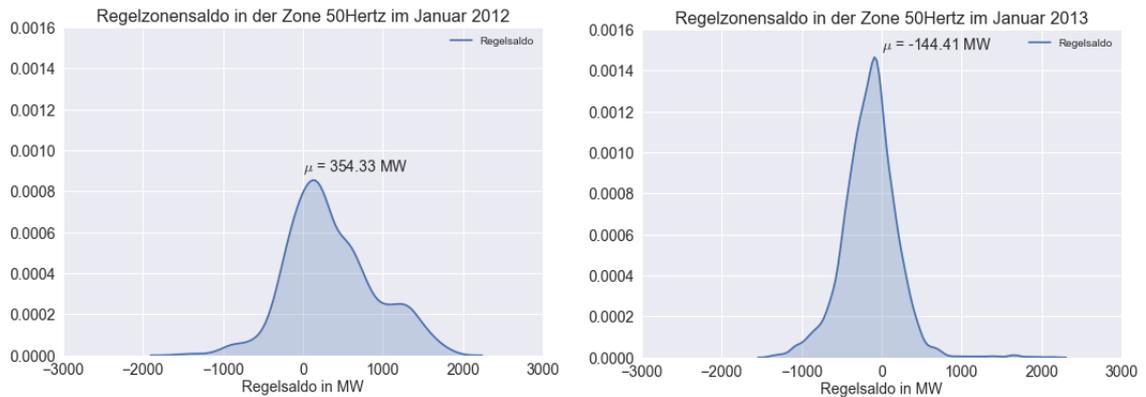


Abbildung 4.44: Verteilung des Regelzonensaldos für 50 Hertz jeweils im Januar in den Jahren 2012 und 2013

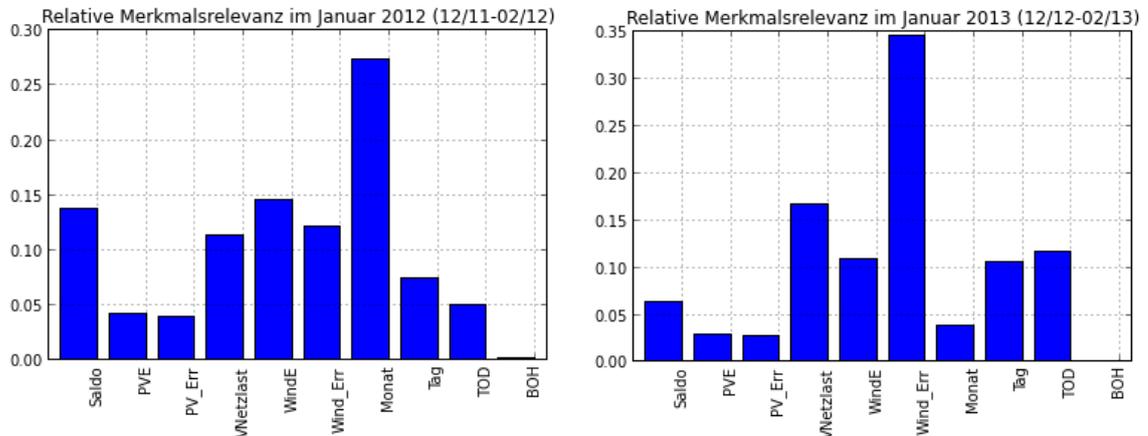


Abbildung 4.45: Relative Merkmalsrelevanz für 50 Hertz jeweils im Januar in den Jahren 2012 und 2013

Ein weiteres Indiz für das relativ schlechte Ergebnis im Januar 2012 liefert die Betrachtung der relativen Merkmalsgewichte aus dem GBT, wie sie in Abbildung 4.45 dargestellt sind. Man erkennt, dass im Januar 2012 fast alle Merkmale (abgesehen von der Solareinspeisung und dem Fehler daraus) gleich bedeutend waren. Der hohe Anteil an den Zeitmerkmalen lässt weiterhin darauf schließen, dass keine eindeutigen Auslöser für die Systemungleichgewichte identifiziert werden konnten. Demgegenüber ist im Januar 2013 eindeutig der Prognosefehler aus der Windeinspeisung hauptverantwortlich für das Systemungleichgewicht. Die partielle Abhängigkeit zwischen dem Windfehler und dem Regelzonensaldo ist in Abbildung 4.42 dargestellt.

4.4.2 Ergebnisse für Amprion

Abbildung 4.46 zeigt die Ergebnisse für den 1.7.2013 in der Amprion Regelzone im Vergleich zwischen dem KNN_GBT_100 und dem GBT_0.99.

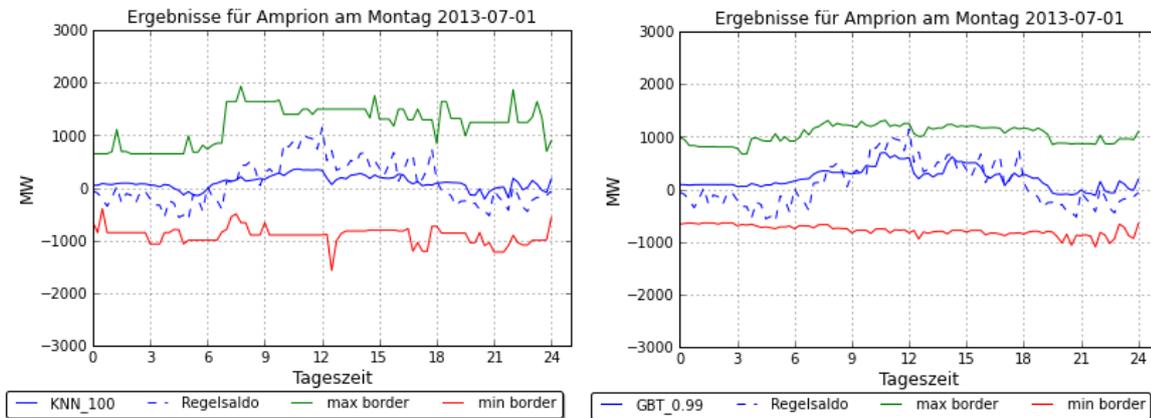


Abbildung 4.46: Ergebnisse für Amprion im Juli 2013 - Vergleich KNN_100 / GBT_0.99

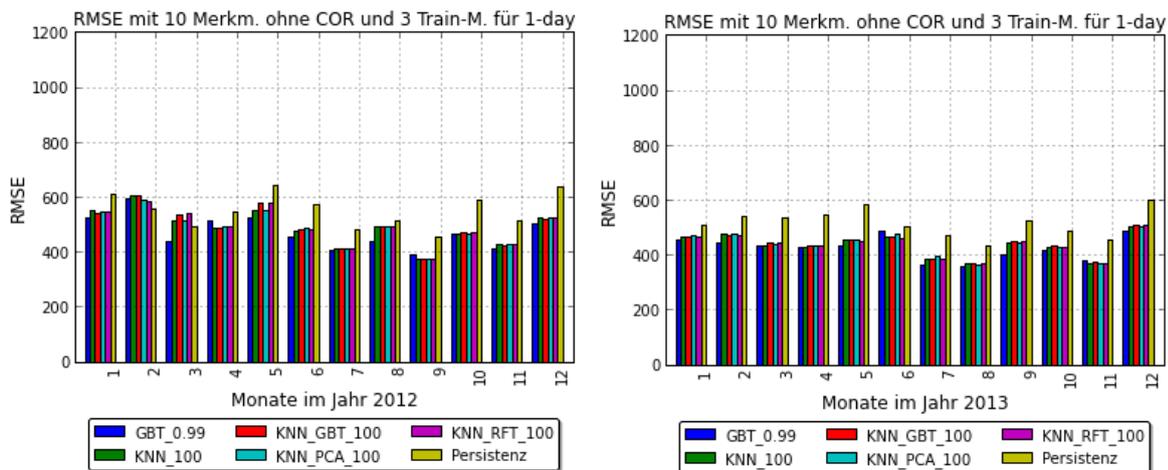


Abbildung 4.47: RMSE der einzelnen Methoden für Amprion in den Jahren 2012 und 2013

Beide Punktschätzer folgen dem Verlauf der Kurve, der GBT schafft dies jedoch insbesondere zwischen 09:00 und 15:00 Uhr deutlich besser. Auch das Konfidenzintervall ist bei GBT deutlich schmaler als bei KNN. Dies ist das gleiche Ergebnis das bereits in der Regelzone von 50 Hertz beobachtet werden konnte. Der GBT scheint demnach in den Regelzonen ein besseres Ergebnis als im Netzregelverbund zu erzielen, was darauf zurückzuführen ist, dass die relative Relevanz der Einflussfaktoren stark regional differenziert.

Dies zeigt sich auch in den Ergebnissen des RMSE in Abbildung 4.47, in denen deutlich zu erkennen ist, dass der GBT dominiert. Weiterhin ist zu erkennen, dass der Vorteil gegenüber der Persistenz nicht derart stark ist wie noch zuvor in der Regelzone von 50 Hertz. Dies liegt daran, dass nicht

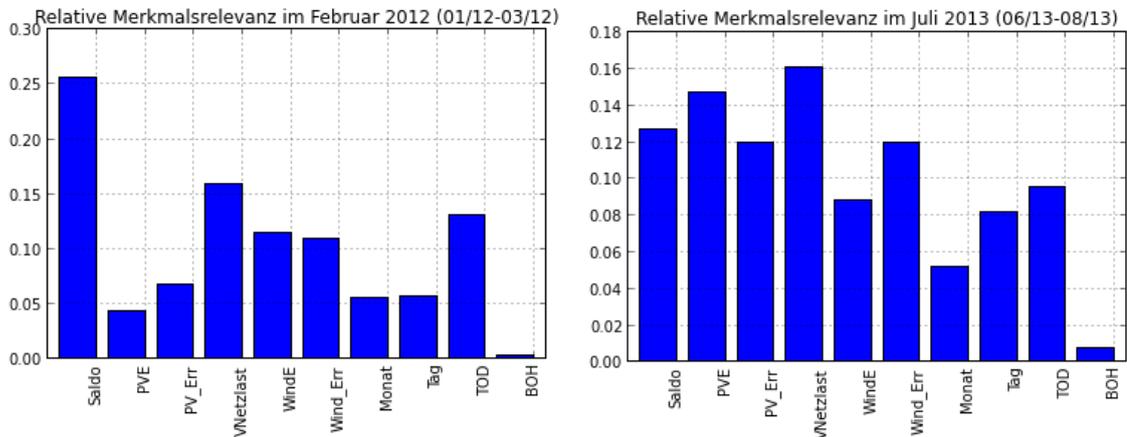


Abbildung 4.48: Relative Merkmalsrelevanz für Amprion im Januar 2012 und im Juli 2013

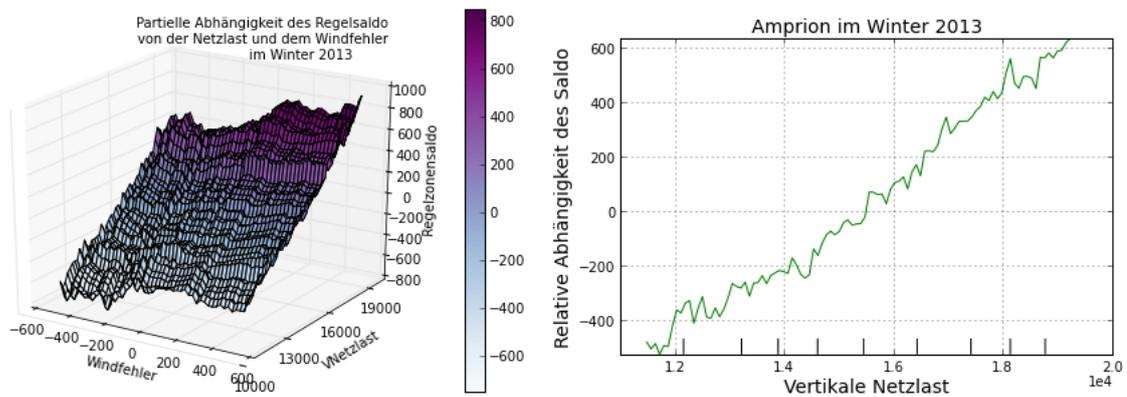


Abbildung 4.49: Partielle Abhängigkeit zwischen dem Regelzonensaldo und der vertikalen Netzlast in der Amprion Regelzone im Winter 2013

mehr der Windfehler die dominierende Einflussgröße auf den Regelzonensaldo ist, sondern alle Einflussgrößen einen annähernd gleichen Einfluss haben. Dazu wurden in Abbildung 4.48 die relativen Relevanzen der einzelnen Merkmale für den Februar 2012 (links) und den Juli 2013 (rechts) abgebildet. Es ist zu erkennen, dass insbesondere im Februar der Windfehler eine wesentlich geringere Relevanz besitzt als die vertikale Netzlast. In Abbildung 4.49 ist daher die partielle Abhängigkeit des Regelzonensaldos vom Windfehler und der vertikalen Netzlast gezeigt. Es ist deutlich zu erkennen, dass der Einfluss der vertikalen Netzlast überwiegt (lineare Abhängigkeit) während der Einfluss des Windfehlers nur in Zeiten hoher vertikaler Netzlast einen Einfluss auf den Regelaldo hat.

4.4.3 Ergebnisse für Tennet

Abbildung 4.50 zeigt die Ergebnisse für die Regelzone von Tennet an Beispieltagen für das Jahr 2012.

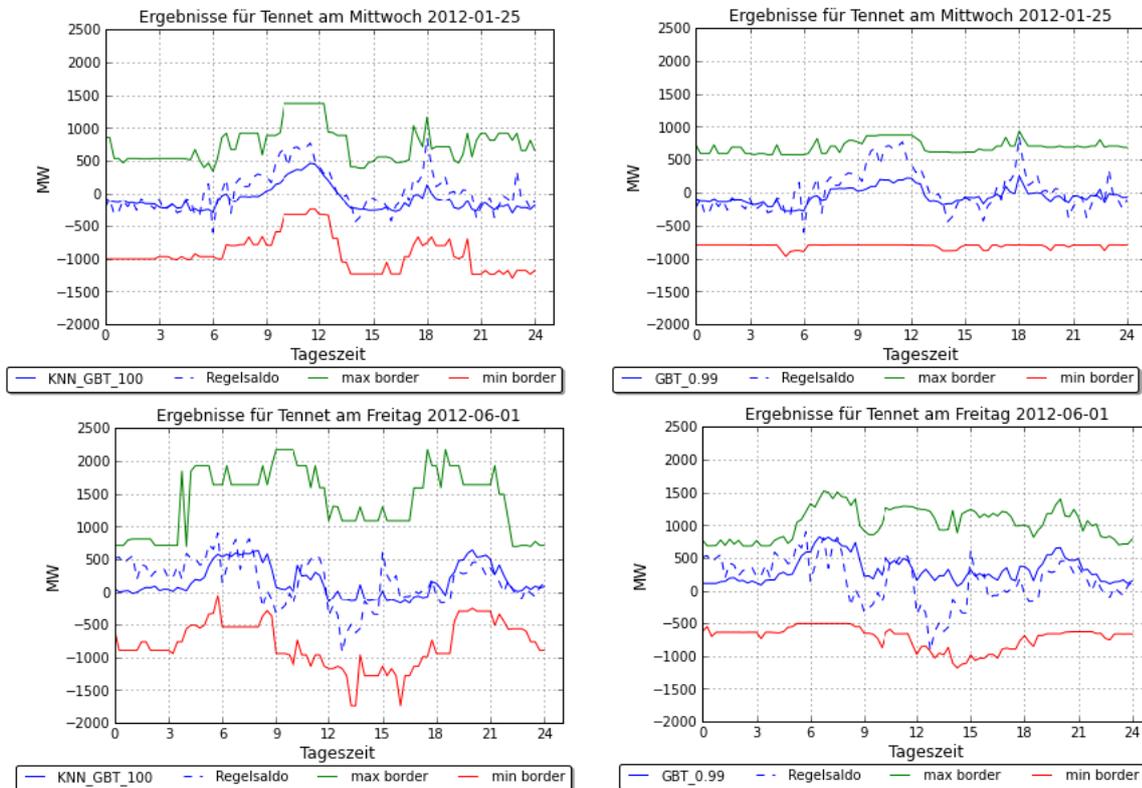


Abbildung 4.50: Ergebnisse für Tennet im Januar/Juni 2012 - Vergleich KNN-GBT mit GBT

Die KNN_GBT ist deutlich besser in der Lage den genauen Verlauf der Kurve vorherzusagen, und auch der Grenzverlauf folgt bei den KNN besser der Zielgröße, wenngleich das Konfidenzintervall bei GBT schmäler ist unter Einhaltung der Grenzen. So ist dementsprechend in der Auswertung der mittleren Fehler in Abbildung 4.51 nicht der GBT die dominierende Methode, sondern die KNN haben einen geringeren mittleren Fehler. Alle Methoden zeigen jedoch eine deutliche Verbesserung zur Persistenz. Der Unterschied zwischen den Jahren 2012 und 2013 ist in dieser Regelzone nicht derart ausgeprägt wie zum Beispiel in der 50 Hertz Zone.

Abbildung 4.52 zeigt die partielle Abhängigkeit des Regelzonensaldos vom Windfehler und der vertikalen Netzlast im Vergleich der Jahreszeiten. Es ist zum einen zu erkennen, dass die vertikale Netzlast im Winter ca. 3.000 MW höher ist als im Sommer (was durch eine starke PV-Einspeisung in den unteren Netzebenen während der Sommermonat spricht), und zum anderen ist zu erkennen, dass der Windfehler in Zeiten schwacher Netzlast (also zum Beispiel nachts) im Sommer einen deutlich stärkeren Einfluss hat als im Winter. Dieses konnte bereits in der Regelzone von 50 Hertz gezeigt werden, wo der Regelzonensaldo nachts direkt dem Windfehler folgte.

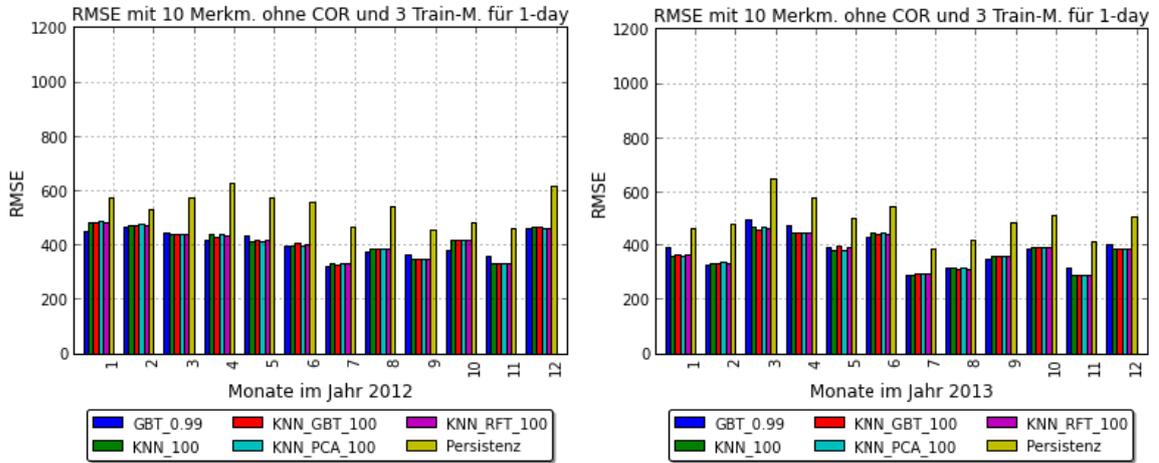


Abbildung 4.51: RMSE der einzelnen Methoden für Tennet in den Jahren 2012 und 2013

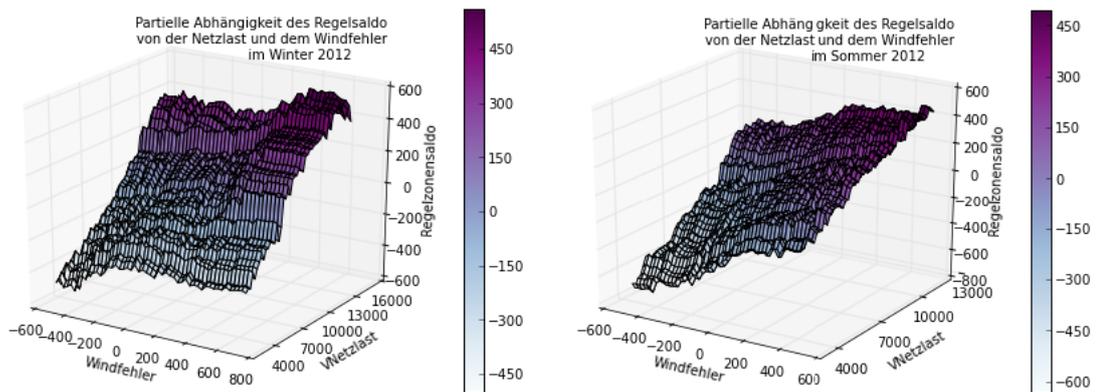


Abbildung 4.52: Partielle Abhängigkeit des Regelsaldos von dem Windfehler und der Netzlast in der Tennet Zone im Vergleich Sommer - Winter 2012

4.4.4 Ergebnisse für TransnetBW

Abschließend werden die Ergebnisse für die Regelzone von TransnetBW vorgestellt. Abbildung 4.53 zeigt die Ergebnisse für den 1.3.2012 und den 1.7.2012 im Vergleich für den GBT.

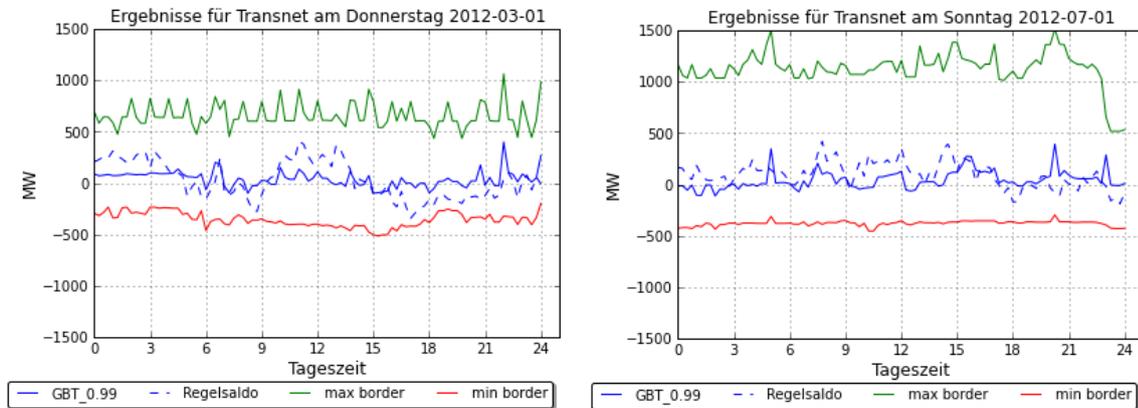


Abbildung 4.53: Ergebnisse für den GBT in der Regelzone TransnetBW im Jahr 2012
Winter-Sommer-Vergleich

Die Regelzone von TransnetBW lässt sich schwer prognostizieren, da abgesehen von der PV-Einspeisung und dem PV-Fehler im Sommer, keine eindeutig dominierenden Einflussgrößen vorliegen. Der starke Einfluss des PV-Fehlers im Sommer führt allerdings dazu, dass sich die obere Grenze deutlich nach oben verschiebt. Der Einfluss des PV-Fehlers findet sich dementsprechend auch in der relativen Merkmalsrelevanz, die in Abbildung 4.54 für den Winter und den Sommer 2012 dargestellt ist sowie in der partiellen Abhängigkeit des Regelzonensaldos vom PV-Fehler und der vertikalen Netzlast in Abbildung 4.55.

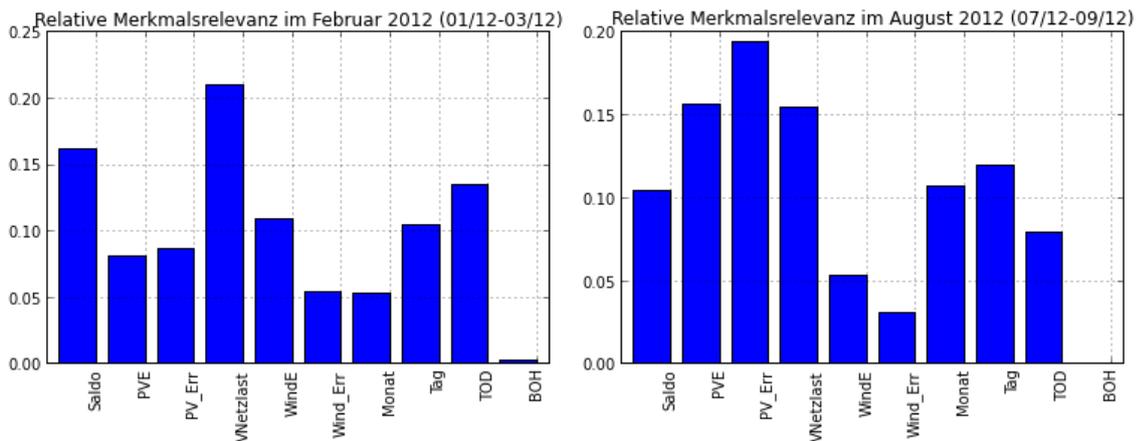


Abbildung 4.54: Merkmalsrelevanz im Bereich der Regelzone TransnetBW im Winter Sommer 2012 im Vergleich

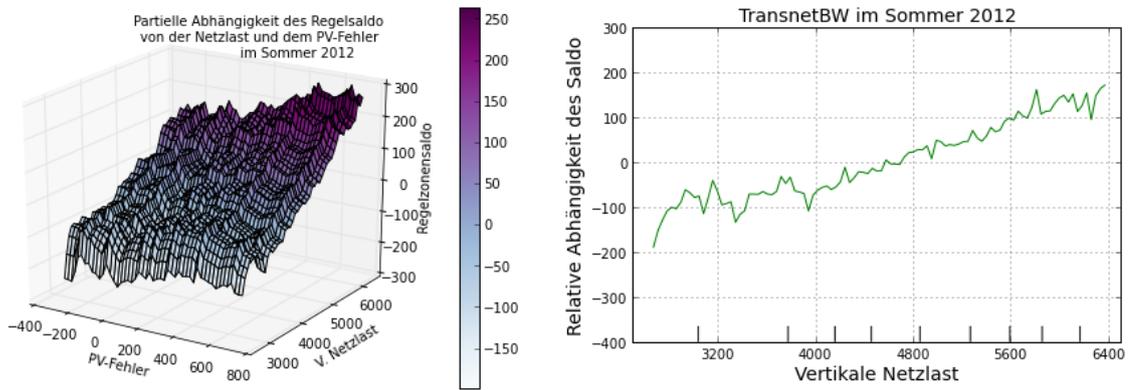


Abbildung 4.55: Partielle Abhängigkeit des Regelzonalensaldos von der vertikalen Netzlast und dem PV-Fehler in der Regelzone von TransnetBW

Abschließend zeigt Abbildung 4.56 den mittleren Fehler für die Regelzone. Die besten Ergebnisse erzielt der GBT, welcher in fast allen Monaten die Persistenz unterbietet. Allgemein sind der April und der Mai 2012 die Monate mit den schlechtesten Ergebnissen. Auch dies lässt auf den starken Einfluss der PV-Einspeisung auf den Regelsaldo in dieser Regelzone schließen.

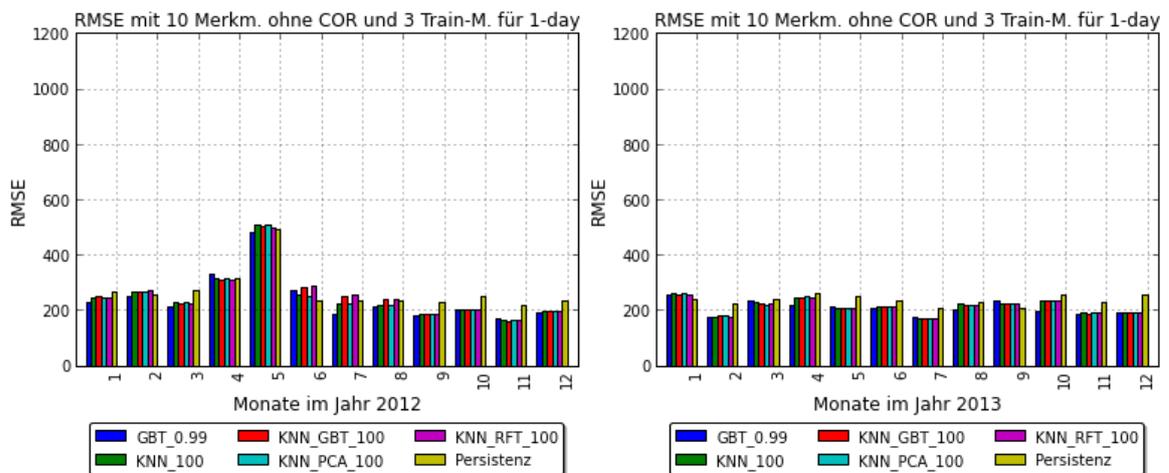


Abbildung 4.56: Mittlerer Fehler (RMSE) im Bereich der Regelzone TransnetBW in den Jahren 2012 und 2013

4.5 Zusammenfassung

Im vorangegangenen Kapitel wurde das Prognosemodell anhand verschiedener Simulationsszenarien evaluiert. Dabei wurde zunächst die Prognose der Regelsalden für den Netzregelverbund vorgestellt und anschließend die Ergebnisse für einzelne Regelzonen. Für den NRV wurden ausgewählte Simulationsfälle vorgestellt, anhand derer eine Sensitivitätsanalyse der Parametereinstellungen vorgenommen wurde. Die Ergebnisse dieser Sensitivitätsanalyse lassen sich dabei wie folgt zusammenfassen:

- **Änderung der Merkmalsauswahl:**

Die Hinzunahme der Zeitmerkmale (month, weekday, TOD und BOH) und damit die Vergrößerung der Merkmalsdimension von sieben auf zehn hat bei den KNN weder Einfluss auf den Punktschätzer noch auf das Konfidenzintervall. Bei den GBT hat die Hinzunahme der Zeitmerkmale im Sommer eine Reduktion des Konfidenzintervalls zu Folge. Insbesondere die untere Grenze konnte angehoben werden. Über das Testjahr und mit einem Ausschreibungszeitfenster von vier Stunden hat die Erweiterung der Merkmalsdimension jedoch kein größeres Einsparpotential generiert. Dennoch konnte die Überschusswahrscheinlichkeit an der unteren Grenze (PL4) bei den GBT von 1,5% auf 0,5% verbessert werden. Bei den KNN konnte keine wesentliche Verbesserung der Sicherheitsniveaus erreicht werden.

- **Änderung der Trainingsmonate:**

Die Erhöhung von drei Trainingsmonaten auf zwölf Trainingsmonate unter Beibehaltung von sieben Merkmalen führt zu einer Vervielfachung der Samplemenge. Dies hat auf beide Verfahren sehr unterschiedliche Auswirkungen. Während bei den KNN die Zunahme der Beispieldatenpunkte die Wahrscheinlichkeit ähnliche Nachbarn zu finden erhöht und damit eine bessere Schätzung der Verteilung erlaubt, wird es für die GBT durch die Zunahme der Trainingsmenge schwieriger die Zielfunktion – das Einhalten der Defizitgrenzen – zu erreichen. Während eine Vergrößerung des Suchraums bei den KNN nur einen indirekten Einfluss auf die Nachbarn und damit die Berechnung der Verteilung hat, erfolgt die Induktion des GBT auf der gesamten Datenmenge. So nähert sich der GBT bei zunehmender Trainingsmenge und zunehmendem Sicherheitsniveau dem aktuellen Verfahren an, dessen Bemessung ebenfalls genau auf einer Datenmenge von 12 Monaten erfolgt. Dennoch ließe sich mit den GBT bei zehn Merkmalen für das Testjahr 2013 ein Einsparungspotential von 43.800 EUR generieren. Im Vergleich zu drei Trainingsmonaten ist dies jedoch eine Halbierung und auch für die KNN bedeutet die Zunahme der Suchraummenge eine Reduktion der Einsparpotentiale. In gleichem Maße erhöht sich jedoch für beide Methoden das Sicherheitsniveau. Im Fall von GBT_0.9999 und KNN_GBT_500 lässt sich ein Sicherheitsniveau von 0,2%²⁶ und für KNN_500 von 0,5% erreichen.

- **Änderung der Anzahl Nachbarn:**

Die Erhöhung der Anzahl Nachbarn von 100 auf 500 bzw. die Erhöhung des Sicherheitsniveaus bei den GBT von $\alpha = 0.99$ auf $\alpha = 0.9999$ hat in allen Simulationsfällen eine Verbesserung des Sicherheitsniveaus zur Folge. Bei den GBT ist genau diese Verbesserung Ziel der Optimierung des Algorithmus. Bei den KNN bewirkt eine Erhöhung der Anzahl Nachbarn eine Verbreiterung des Konfidenzintervalls und damit auch eine Reduktion der Defizitgrenzen. Insbesondere für die untere Grenze bedeutet eine Zunahme an Nachbarn eine Verbesserung von ca. 0,2%. Dies ist darauf zurückzuführen, dass die Grenzverletzungen an der unteren Grenze insbesondere auf große zufällige Windprognosefehler zurückzuführen sind, die nicht einer derartigen zeitlichen

²⁶ Das heißt das eingestellte Sicherheitsniveau in den GBT von 0,01% lässt sich nicht für alle Intervalle erreichen.

Abhängigkeit und Regelmäßigkeit unterliegen wie die PV-Prognosefehler, die für die Einhaltung der oberen Grenze verantwortlich sind. Dementsprechend ist der Datenraum im Bereich großer Windfehler spärlicher besetzt bzw. diese unterliegen keiner Tageszeitabhängigkeit und es bedarf dementsprechend einer größeren Anzahl Nachbarn, diese Extremwerte sicher mit in das Modell zu integrieren.

- **Änderung der Merkmalsgewichtung:**

Die Merkmalsgewichtung mit den Merkmalsgewichten aus den Trees (KNN_GBT) hat bei den KNN zu einer Erhöhung des Sicherheitsniveaus bei gleichzeitiger Reduzierung des Konfidenzintervalls geführt. Die „Principal Component Analysis“ (KNN_PCA) führte insbesondere zu einer Verbreiterung der Intervalle, konnte jedoch in Bezug auf die Sicherheitsniveaus keine bedeutende Verbesserung erreichen. Dies hängt am zeitlich differenzierten Einfluss der unterschiedlichen Einflussfaktoren, die keine globale Transformation auf einer großen Anzahl Samples ermöglicht. Zeitlich eingeschränkt in einzelnen Regelzonen kann die PCA dennoch Vorteile bringen, so konnte auf gefilterten Datenpunkten in der 50 Hertz Regelzone die erfolgreiche Anwendung der PCA gezeigt werden.

- **Änderung der Merkmalsvorverarbeitung:**

Die adaptive Merkmalsgewichtung durch Multiplikation mit der stündlichen Korrelation (COR) bzw. eine Doppeltgewichtung (DW) der einzelnen Zeitreihenmerkmale hat einen weitaus größeren Einfluss auf die KNN als auf die GBT. So sind Entscheidungsbäume unabhängig von der unterschiedlichen Dimensionierung der einzelnen Einflussfaktoren während diese bei den KNN das Distanzmaß beeinflussen. Insbesondere die Multiplikation mit der Korrelation hat bei den GBT somit nahezu keine bzw. negative Auswirkungen. Das Quadrieren der Merkmalswerte ermöglicht jedoch auch bei den GBT eine differenzierte Samplemenge und damit eindeutigere Verbesserungen der Zielfunktion/Trennungsoptionen. So lässt sich bei beiden Verfahren das Sicherheitsniveau halten (GBT) bzw. verbessern (KNN) und ein Wert von 99,98% erreichen. Dies geht allerdings zu Lasten der vorzuhaltenden Mengen, so dass die dynamische Gewichtung aus den Trees der adaptiven Korrelationsgewichtung vorzuziehen ist.

- **Änderung der Merkmalszusammensetzung:**

Verzichtet man auf die einschränkende Annahme, dass die EE-Fehler a-priori bekannt sind ²⁷, erhöhen sich die Defizitwahrscheinlichkeiten und das Sicherheitsniveau sinkt entsprechend. Dennoch lässt sich auch mit dieser realitätsnahen Annahme ein Sicherheitsniveau von 99,8 % erreichen. Die Einsparpotentiale reduzieren sich gegenüber dem unkorrelierten Fall mit zehn Merkmalen geringfügig. Bei den GBT mit dem maximalen Sicherheitsniveau von 99,99% hat die Kenntnis des EE-Fehlers nahezu keine Auswirkungen, weder auf den Punktschätzer noch auf das Konfidenzintervall.

- **Änderung der Merkmalsgenerierung:**

Wird die Anzahl der Werte pro Zeitreihenmerkmal auf zwei erhöht – Änderung des Verzögerungswertes auf lag[0,1] – bedeutet dies eine Vergrößerung der Merkmalsdimension. Dies erfordert die Vergrößerung der Trainingsmenge auf zwölf Monate, sollen die Sicherheitsniveaus gehalten werden. Eine wesentliche Verbesserung konnte jedoch nicht erreicht werden.

²⁷ Das heißt diese Merkmale stehen nicht zur Verfügung. So wird lediglich die Wind- und PV-Prognose anstatt des Wind- und PV-Fehlers und der Wind- und PV-Einspeisung berücksichtigt.

- **Änderung des Prognosehorizonts:**

Die Änderung des Prognosehorizonts von einem Tag (96) auf eine Stunde (4) hat eine Reduktion des Konfidenzintervalls zur Folge. Dabei nähert sich der Punktschätzer der Persistenz. So können durch die KNN und GBT keine derartigen Verbesserungen gegenüber der Persistenz erreicht werden wie bei der One-Day-Ahead Prognose. Des Weiteren ist dieser Prognosehorizont für die Ausschreibung am RL-Markt zu kurz.

Das höchste Sicherheitsniveau in Abhängigkeit zur eingesparten Leistung von 99,8% (positiv) und 99,9% (negativ) lässt sich mit der Parametereinstellung von zehn Merkmalen, zwölf Trainingsmonaten ohne Berücksichtigung der stündlichen Korrelation zwischen den Einflussgrößen und der Zielgröße erreichen. Dies entspricht einem Defizit bzw. Überschuss an Energie in 1,5 Stunden pro Monat. Dies entspricht genau den tatsächlich realisierten Sicherheitsniveaus im Jahr 2013 von 99,90 % für die negative Regelleistung und von 99,80 % für die positive Regelleistung, die ebenfalls unter dem geforderten Niveau von 99,975 lagen. Das heißt im Januar, Februar und September 2013 hat die negative RL nicht ausgereicht, die Überschussenergie im Netz auszugleichen, und im April 2013 war nicht genügend positive RL vorhanden, um das Leistungsdefizit auszugleichen²⁸. In Bezug auf die Parametereinstellungen innerhalb der Methoden konnte gezeigt werden, dass bei den KNN eine Anzahl von 500 Nachbarn und bei den GBT ein *alpha* von 0.9999 die besten Ergebnisse für die Einhaltung des Sicherheitsniveaus liefern.

Bezüglich der Einsparpotentiale hat sich gezeigt, dass sich hauptsächlich in den Sommernächten negative Regelleistung einsparen ließe. Für die monetäre Bewertung wurden die Ergebnisse dieser Arbeit mit denen der DESIRE Studie [Buc14] (situative Bemessung der RL) verglichen. Je nach ausgewähltem Simulationsfall liegen die Ergebnisse dieser Arbeit dabei über, bzw. unter den Ergebnissen der Studie. So beträgt das Einsparpotential ohne Kenntnis des EE-Fehlers ca. 40 Mio. EUR (GBT) bzw. 54 Mio. EUR (KNN_GBT). Die DESIRE-Studie liefert einen Vergleichswert von 47. Mio. EUR. Dem gegenüber stehen Gesamtkosten für die RL im Jahr 2013 von ca. 337 Mio. EUR. In Bezug auf die einzusparenden Leistungsmengen lässt sich im Vergleich mit der Studie feststellen, dass neben dem Merkmal der Tageszeit auch die Jahreszeit sowie der Wochentag einen wesentlichen Einfluss auf die Höhe der benötigten Regelleistung haben. Die Methode des KNN ermöglicht es, diese Merkmale parallel zu betrachten und den Datensatz entsprechend zu filtern.

Abschließend wurde das Prognosemodell für die One-Hour-Ahead Prognose in den einzelnen Regelzonen evaluiert. Dabei konnte festgestellt werden, dass sich für den Netzregelverbund keine wesentliche Verbesserung zur statistischen direkten Prognose der Persistenz ergibt. Dennoch kann das Modell des GBT sinnvolle Hinweise über die Wechselwirkung der einzelnen Einflussgrößen sowie deren quantitativen Einfluss auf den Regelzonensaldo liefern.

Insgesamt kann festgestellt werden, dass KNN eine flexible und adaptive Regelleistungsbemessung ermöglicht, während dies bei den GBT durch die Parametrierung des Modells auf der gesamten Trainingsmenge nicht möglich ist. Dies hat Auswirkungen auf das Konfidenzintervall, dass bei den KNN flexibel der Kurve des Punktschätzers folgt, während es sich bei den GBT mit Zunahme der Trainingsmenge den aktuellen Bemessungswerten annähert. Dennoch ermöglichen auch die GBT eine stabile Prognose bei gleichzeitiger zeitlicher Reduktion der Mengen.

²⁸ In diesem Fällen ist jedoch durch einen Austausch mit den assoziierten Ländern dennoch ein Ausgleich möglich.

5 Zusammenfassung und Ausblick

Die „Energiewende“ hat in Deutschland die wirtschaftliche und technische Struktur der elektrischen Energieversorgung innerhalb der letzten Jahre zum Teil erheblich verändert. Insbesondere der Ausbau der Erneuerbaren Energien hat dabei verstärkt Einfluss auch auf die Versorgungssicherheit. So hat die Zunahme erneuerbarer Energiequellen im Erzeugungsmix eine volatile dezentrale Einspeisung zur Folge, während gleichzeitig durch die Umsetzung der europäischen Richtlinien zur Liberalisierung des Strommarktes zentrale Steuerungsmöglichkeiten entfallen sind. Die Auswirkungen, die diese Entwicklung auf das Design der Regel- und Reserveleistung zur Aufrechterhaltung einer konstanten Netzfrequenz durch den permanenten Ausgleich von Erzeugung und Verbrauch hat, wurden im Rahmen dieser Arbeit aufgezeigt sowie Verbesserungspotentiale abgeleitet. Insbesondere für die Regelleistungsdimensionierung konnten Schwachstellen im aktuellen statisch faltungsbasierten Bemessungsmodell identifiziert werden. Daher wurde im Rahmen dieser Arbeit ein neues Prognosemodell zur Vorhersage von Systemungleichgewichten entwickelt, das eine dynamische Regelleistungsdimensionierung ermöglicht. Die Ergebnisse der Arbeit werden im folgenden zusammengefasst sowie Ansatzpunkte für weitere Entwicklungen aufgezeigt.

5.1 Zusammenfassung

Die Zielsetzung dieser Arbeit war die „Entwicklung eines flexiblen Prognosemodells mit Methoden des maschinellen Lernens zur adaptiven Bemessung der erforderlichen Regelleistungsmengen“. Aus diesem Ziel wurden in der Einleitung die folgenden Anforderungen an das zu entwickelnde Prognosemodell abgeleitet: *Skalierbarkeit*, *Dynamik*, *Adaptivität* und *Sicherheit*. Im Rahmen dieser Arbeit wurde dazu ein Prozess vorgestellt, der die Entwicklung eines flexiblen Prognosemodells ermöglicht, dass in der Lage ist, die Vorhersage der Systemungleichgewichte auf die Charakteristik der jeweiligen Regelzone anzupassen. Dieser Prozess ist in Abbildung 5.1 zusammenfassend dargestellt.

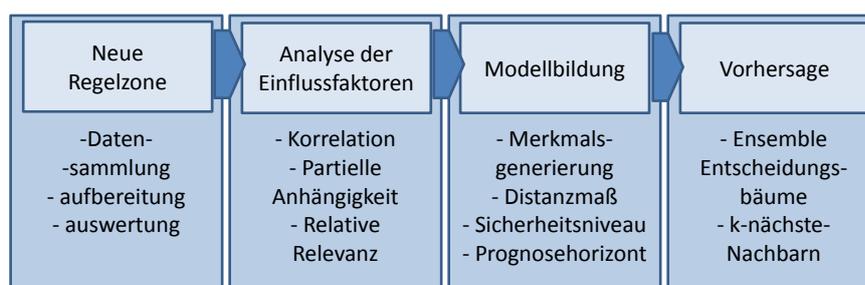


Abbildung 5.1: Prozessverlauf Erstellung flexibles Prognosemodell

In Kapitel 2 wurde der Prozess der Datenanalyse genauer vorgestellt. Dabei wurden insbesondere die Anforderungen der *Skalierbarkeit* und *Dynamik* umgesetzt, indem die Daten in Form eines dreidimensionalen Panels in HDF5-Format aufbereitet und gespeichert wurden. Diese Struktur erlaubt sowohl einen schnellen automatisierten Zugriff als auch eine automatisierte dreidimensionale Auswertung. So ist neben der zeitlichen auch eine räumliche Analyse der Daten möglich.

Die erfolgreiche Datenaufbereitung ermöglicht die Entwicklung eines nicht parametrischen instanzbasierten Prognosemodells. In Kapitel 3 wurden dazu sowohl die Grundlagen nicht parametri-

scher Modelle und ihre Unterschiede zu parametrischen mathematischen Modellen gezeigt, als auch eine kurze Einführung in das maschinelle Lernen und die hier verwendeten Modelle der Gradient Boosting Trees sowie der k-Nächsten-Nachbarn gegeben. Insbesondere die GBT erlauben eine detaillierte Analyse der einzelnen Einflussfaktoren auf den Regelleistungsbedarf. So konnten sowohl mit Hilfe ausführlicher Korrelationsanalysen als auch durch die modellimpliziten Auswertungen der GBT die partiellen Abhängigkeiten zwischen einzelnen Einflussfaktoren und dem Bedarf an Regelleistung gezeigt werden. Zum Teil konnten dabei lineare Zusammenhänge identifiziert werden. Des Weiteren konnte die relative Relevanz einzelner Einflussfaktoren quantifiziert und dabei sowohl zeitliche als auch räumliche Differenzen aufgezeigt werden.

Diese Ursache-Wirkungs-Zusammenhänge können anschließend in die Modellbildung übernommen werden. So wurde in Kapitel 3 das Vorgehen der dynamischen sowie adaptiven Merkmalsgewichtung vorgestellt. Damit wurden die Anforderungen der *Dynamik* und *Flexibilität* im Modell erfolgreich umgesetzt.

Abschließend wurde das Modell in Kapitel 4 evaluiert. Dazu wurde das Modell zum einen mit dem einfachen direkten Prognosemodell der Persistenz verglichen und zum anderen mit der situativen faltungsbasierten Regelleistungsbemessung eines vergleichbaren Forschungsprojekts ([Buc14]). Im Rahmen der Datenanalyse und der Evaluation wurden dabei die folgenden Arbeitshypothesen, die dieser Arbeit zu Grunde lagen, genauer untersucht.

- **Die derzeitige Regelleistungsvorhaltung ist ineffizient.**

Es konnte in der Datenanalyse der Jahre 2001 bis 2013 gezeigt werden, dass insbesondere bei der MRL eine Optimierung der Vorhaltungsmengen möglich ist, bzw. die vorhandene Vorhaltung ineffizient ist. So lag der Abrufgrad¹ für MRL im Jahr 2012 bei durchschnittlich 0,30, d.h. 70% der vorgehaltenen Energie wurden nicht benötigt. In 90% der Zeit fand kein Abruf von MRL statt, das entspricht einer durchschnittlichen Abrufhäufigkeit von 0,10.

- **Die Aktivierung von Regelleistung erfolgt nicht zufällig.**

Es konnten im Rahmen der Datenanalyse eindeutige zeitliche und räumlich Ursache-Wirkungs-Zusammenhänge aufgezeigt werden. Insbesondere die Auswertung der partiellen Abhängigkeiten haben lineare Zusammenhänge zwischen einzelnen Einflussfaktoren ergeben, die eine quantitative Aussage über den Zusammenhang zwischen dem aktuellen Systemzustand und der Aktivierung von Regelleistung ermöglichen. Darüber hinaus konnten strategische Zusammenhänge zwischen dem Wirkleistungsmarkt und dem Regelleistungsbedarf aufgezeigt werden.

- **Methoden des maschinellen Lernens können genutzt werden.**

Es konnte gezeigt werden, dass sowohl die Methode der k-Nächsten-Nachbarn als auch Ensembles von Entscheidungsbäumen geeignet sind, Systemungleichgewichte vorherzusagen. Letztere ermöglichen zudem Aussagen über die relative Relevanz einzelner Einflussgrößen. Die Datenmenge von drei Jahren war dabei ausreichend sowohl eine Generalisierungsmöglichkeit des Modell als auch einen zehndimensionalen Merkmalsraum zu ermöglichen.

¹ Abgerufene Menge an MRL/vorgehaltene Menge

- **Die vorzuhaltenden Mengen lassen sich reduzieren und Kosten einsparen.**

Die Evaluation hat gezeigt, dass sich im Bereich der Minutenreserveleistung Mengen einsparen lassen. Diese variieren je nach Tageszeit und liegen im Jahresdurchschnitt (2013) für KNN bei 556 MW (negativ) und 1.183 MW (positiv). Für die GBT sind die Mengen geringfügig niedriger und liegen im Mittel bei 337 MW (negativ) und 1.055 MW (positiv). Daraus ergeben sich maximal mögliche einzusparende Kosten von ca. 54 Mio.EUR. Dies entspricht in etwa 16% der Gesamtkosten für die Regelleistungsvorhaltung.

- **Das aktuelle Defizitniveau kann gehalten werden.**

Das aktuell geforderte Defizitniveau beträgt jeweils 0,025%. Dies entspricht einem Defizitzeitraum von ca. 2h/a bzw. 12,5 Min/Mon. In der Evaluation konnte gezeigt werden, dass bei Aufrechterhaltung der 4-Stunden-Ausschreibungsblöcke sowohl mit den KNN als auch mit den GBT das Defizitniveau in zehn Monaten gehalten werden konnte. Lediglich in jeweils zwei Monaten² wurde ein höheres Defizitniveau von 0,1% (untere Grenze) bzw. 0,2% (obere Grenze) erreicht. Das tatsächlich realisierte Defizitniveau lag in diesen Monaten jedoch ebenfalls in diesem hohen Bereich. Damit konnte auch die Anforderung der *Sicherheit* an das Prognosemodell erfüllt werden.

Zusammenfassend lässt sich die Forschungsfrage, ob eine adaptive tägliche Regelleistungsbemessung mit Methoden des maschinellen Lernens möglich ist, daher positiv beantworten.

5.2 Ausblick

Der Bereich des Maschinellen Lernens ist ein vielfältiges komplexes Themengebiet, dass in den vergangenen Jahren stetig gewachsen ist. Insbesondere im Bereich der Energiewirtschaft werden die Methoden bereits erfolgreich zur Prognose von Wind- oder PV-Einspeisung sowie der Lastvorhersage eingesetzt. Ihr Einsatz im Bereich der Versorgungssicherheit bietet daher noch erhebliches Potential. Dies gilt sowohl für die Bereich der *marktbezogenen Maßnahmen* wie der Regelleistung, der im Rahmen dieser Arbeit vorgestellt wurde, als auch in den anderen Bereichen der *netzbezogenen Maßnahmen* oder der *Anpassungen*. So ist zum Beispiel auch eine Vorhersage der nötigen Netzschaltungen bzw. Netzüberlastungen mit Methoden des maschinellen Lernens denkbar. So werden ähnliche Methoden zum Beispiel im Bereich der optimalen Server- bzw. Leitungsauslastung für die Informations- und Kommunikationswirtschaft bereits erfolgreich eingesetzt. Eine Übertragung auf den Bereich der elektrischen Energieversorgung wäre daher denkbar. Ebenso wäre ein Einsatz im Bereich des Engpassmanagements möglich zur Prognose der Eintrittswahrscheinlichkeiten von Engpässen an Kuppelstellen oder Leitungs- bzw. Trafoüberbeanspruchungen.

Im Bezug auf das entwickelte Prognosemodell sind ebenfalls noch Erweiterungen möglich. So bietet neben einer weiteren Optimierung der Modellparametrierung auch die Auswahl weiterer Methoden wie zum Beispiel SVM oder Neuronale Netze mögliches Verbesserungspotential. Die fortschreitende Weiterentwicklung der Informations- und Kommunikationsinfrastruktur innerhalb der elektrischen Energieversorgung zu „*Smart Grids*“ wird in den kommenden Jahren sicherlich auch einen verstärkten Einsatz von Data Mining Methoden zur Sicherstellung der Versorgungssicherheit mit sich bringen. So kann die Energieinformatik in den kommenden Jahren einen wichtigen Beitrag zur sicheren Transformation der elektrischen Energieversorgung zu einer klimaverträglichen Erzeugung auf Basis erneuerbarer Energien leisten, die zudem kosteneffizient und (versorgungs-)sicher ist.

² Januar und Februar(untere Grenze) und April und Mai (obere Grenze)

6 Anhang

6.1 Evaluation

Ergebnisse der Simulationsfälle für den NRV

Ergebnisse für die einzelnen Simulationsfälle jeweils für die Vortagsprognose im Jahr 2013 für 4-Stunden-Zeitscheiben und KNN_100 bzw. GBT_0.9975.

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.7	825	1972.82	284.52	1828.75	2109.01
2013-02	0.0	0.2	661	2128.02	235.36	1843.21	1085.00
2013-03	0.0	0.6	737	2233.69	160.75	1908.50	1963.76
2013-04	0.6	0.1	766	2147.24	819.24	1900.84	2419.23
2013-05	0.2	0.0	689	2240.55	2961.76	1916.27	8660.83
2013-06	0.1	0.0	705	2111.22	1407.58	2004.62	6366.94
2013-07	0.0	0.0	618	2052.43	1815.11	1964.34	13502.11
2013-08	0.0	0.0	639	2107.83	3101.19	1909.86	11638.29
2013-09	0.1	0.2	672	2262.61	2654.15	2071.64	4716.21
2013-10	0.0	0.1	652	2263.63	1280.37	2087.49	10305.57
2013-11	0.0	0.0	538	2210.52	631.18	2230.87	6900.22
2013-12	0.0	0.1	671	2475.22	1429.77	2420.12	22133.32

Tabelle 6.1: Ergebnisse für KNN-100 für 10 Merkmale und 12 Trainingsmonate ohne Berücksichtigung der Korrelation

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.5	808	2018.12	277.58	1767.14	1870.31
2013-02	0.0	0.4	552	2368.95	285.72	1820.37	1176.41
2013-03	0.2	0.0	779	2259.48	150.90	1450.42	1472.63
2013-04	0.2	0.0	752	2008.79	790.65	1539.50	2104.38
2013-05	0.2	0.1	642	2115.90	2839.84	1916.29	8317.01
2013-06	0.2	0.0	678	2234.17	1522.41	1877.02	5948.73
2013-07	0.0	0.0	579	2056.47	2057.18	2284.24	15817.45
2013-08	0.0	0.0	602	2342.57	3561.15	1987.48	12198.27
2013-09	0.1	0.2	643	2214.51	2686.47	1928.36	4228.62
2013-10	0.1	0.1	662	2175.02	1266.98	1618.13	7703.81
2013-11	0.1	0.0	510	2152.53	635.71	1895.46	5727.39
2013-12	0.0	0.1	667	2342.11	1478.64	2052.63	18587.49

Tabelle 6.2: Ergebnisse für GBT-09975 für 10 Merkmale und 12 Trainingsmonate ohne Berücksichtigung der Korrelation

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.5	789	2046.99	291.15	1928.40	1732.22
2013-02	0.0	0.1	593	2415.34	293.46	1772.32	1004.29
2013-03	0.7	0.3	771	2636.49	196.42	1637.44	1499.82
2013-04	1.1	0.0	838	2679.34	1099.59	1772.60	2446.68
2013-05	0.5	0.1	711	2466.94	3176.26	2042.19	8992.98
2013-06	0.6	0.0	704	2339.79	1637.97	2315.15	8384.71
2013-07	0.0	0.3	602	2199.41	2061.67	2543.96	17696.32
2013-08	0.0	0.5	697	2292.56	3336.14	2645.56	16483.16
2013-09	0.2	0.6	676	2463.68	2847.08	2728.22	6130.81
2013-10	0.2	0.2	636	2668.08	1525.38	2698.57	15066.90
2013-11	0.0	0.2	542	2699.70	755.32	2591.32	10659.66
2013-12	0.1	0.8	663	2640.50	1600.72	2717.93	26117.88

Tabelle 6.3: Ergebnisse für KNN-100 für 6 Merkmale und 3 Trainingsmonate ohne Berücksichtigung der Korrelation

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.5	778	2305.40	325.59	1591.86	1277.85
2013-02	0.0	0.5	585	2307.70	274.22	1864.83	1173.24
2013-03	0.4	0.1	934	2399.19	169.29	1068.52	1080.65
2013-04	0.6	0.1	820	2402.26	994.30	1652.23	2252.85
2013-05	0.3	0.1	680	2451.76	3317.07	2162.30	9621.94
2013-06	1.3	0.0	697	2407.09	1677.39	2284.09	8068.29
2013-07	0.0	0.0	633	2100.65	2211.72	2596.90	17863.36
2013-08	0.0	0.3	635	2332.25	3597.64	2529.58	15630.65
2013-09	0.2	0.5	670	2396.21	2836.59	2585.81	5769.99
2013-10	0.3	0.2	611	2479.52	1443.25	2395.74	12814.57
2013-11	0.2	0.1	524	2647.01	810.38	2538.80	10277.12
2013-12	0.2	0.5	690	2513.73	1624.03	2502.08	24100.02

Tabelle 6.4: Ergebnisse für GBT-09975 für 6 Merkmale und 3 Trainingsmonate ohne Berücksichtigung der Korrelation

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.5	771	2013.00	289.46	1892.15	1717.79
2013-02	0.0	0.3	595	2480.45	306.50	1693.57	1052.62
2013-03	0.7	0.3	762	2627.17	200.54	1571.78	1458.56
2013-04	1.3	0.0	825	2692.50	1101.48	1897.24	2793.33
2013-05	0.4	0.2	698	2450.58	3181.64	2128.36	9433.16
2013-06	0.6	0.1	703	2309.47	1601.03	2323.79	8269.80
2013-07	0.0	0.3	598	2187.81	2003.88	2591.03	17957.41
2013-08	0.0	0.5	692	2275.47	3358.26	2629.86	16377.97
2013-09	0.2	0.6	677	2448.36	2842.97	2725.93	6115.36
2013-10	0.2	0.2	638	2659.05	1517.45	2699.09	15078.00
2013-11	0.0	0.2	543	2695.29	752.21	2605.31	10753.21
2013-12	0.1	0.5	660	2617.30	1585.66	2721.53	25958.00

Tabelle 6.5: Ergebnisse für KNN-100 für 10 Merkmale mit 3 Trainingsmonaten ohne Berücksichtigung der Korrelation

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.1	0.5	822	2344.69	352.65	1656.00	1711.39
2013-02	0.0	0.4	587	2409.57	298.71	1892.18	1221.49
2013-03	0.9	0.1	917	2582.85	184.62	1088.10	1107.15
2013-04	0.6	0.1	792	2365.32	979.99	1674.82	2263.03
2013-05	0.3	0.1	652	2422.71	3280.36	2271.30	10052.61
2013-06	1.5	0.1	678	2394.09	1668.52	2266.54	8059.19
2013-07	0.0	0.0	629	2119.22	2225.97	2659.17	18232.73
2013-08	0.0	0.4	625	2319.48	3590.91	2550.45	15789.83
2013-09	0.2	0.5	667	2421.03	2867.50	2562.94	5713.72
2013-10	0.3	0.2	604	2532.10	1489.80	2486.77	13349.25
2013-11	0.2	0.1	519	2645.05	810.03	2547.78	10316.01
2013-12	0.2	0.5	642	2507.23	1621.54	2489.95	23986.80

Tabelle 6.6: Ergebnisse für GBT-09975 für 10 Merkmale mit 3 Trainingsmonaten ohne Berücksichtigung der Korrelation

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.7	857	1958.33	269.43	1724.26	1540.03
2013-02	0.0	0.3	672	1941.65	202.81	1821.54	1221.43
2013-03	0.1	0.5	734	2189.16	159.50	1880.89	1986.45
2013-04	0.6	0.2	761	2183.97	816.65	1909.37	2385.48
2013-05	0.1	0.0	697	2150.58	2768.50	1755.96	7587.28
2013-06	0.1	0.0	692	2127.17	1432.16	1864.79	5810.59
2013-07	0.0	0.0	619	2074.46	1910.08	1869.93	13128.61
2013-08	0.0	0.0	643	2155.76	3098.91	1966.10	11939.36
2013-09	0.1	0.1	672	2270.10	2691.70	2038.00	4543.51
2013-10	0.1	0.1	658	2220.38	1238.54	2000.18	10065.24
2013-11	0.0	0.0	537	2264.39	630.89	2112.51	6783.12
2013-12	0.0	0.1	677	2357.50	1422.37	1927.62	15327.75

Tabelle 6.7: Ergebnisse für KNN-100 für 6 Merkmale mit 12 Trainingsmonaten und einem LAG von [0,1]

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.5	780	1994.77	276.79	1786.39	1719.20
2013-02	0.0	0.4	587	1988.85	225.74	1908.82	1228.06
2013-03	0.1	0.0	733	1980.20	130.95	1520.14	1468.05
2013-04	0.2	0.1	751	1920.60	748.82	1578.11	2082.22
2013-05	0.2	0.1	660	1981.51	2638.26	1635.72	6683.71
2013-06	0.0	0.0	678	2057.75	1404.47	1746.60	5342.49
2013-07	0.0	0.0	591	2051.44	2050.04	2155.28	14955.34
2013-08	0.0	0.0	607	2309.06	3424.00	1963.12	12007.82
2013-09	0.1	0.1	658	2372.72	2849.87	1825.47	3991.59
2013-10	0.1	0.0	654	2200.11	1264.56	1541.75	7443.60
2013-11	0.1	0.0	516	2176.22	655.01	1855.43	5443.01
2013-12	0.0	0.0	664	2266.29	1433.68	1491.08	12444.86

Tabelle 6.8: Ergebnisse für GBT-09975 für 6 Merkmale mit 12 Trainingsmonaten und einem LAG von [0,1]

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.6	809	2028.80	327.83	1694.49	1339.41
2013-02	0.0	0.2	702	2113.03	242.68	1561.51	893.21
2013-03	0.4	0.4	820	2136.04	145.42	1689.20	1775.23
2013-04	0.5	0.0	810	2039.64	749.09	1505.14	1871.69
2013-05	0.1	0.0	729	1901.62	2417.55	1603.69	6613.80
2013-06	0.0	0.0	715	1975.48	1282.75	1749.70	5101.96
2013-07	0.0	0.0	659	1960.11	1730.71	1884.91	12651.39
2013-08	0.0	0.0	663	1905.98	2710.52	1865.25	10889.98
2013-09	0.0	0.1	677	1996.72	2218.61	1996.65	4485.87
2013-10	0.0	0.1	678	1971.98	1027.90	1966.97	10027.63
2013-11	0.0	0.0	572	2068.63	583.19	2076.77	5845.66
2013-12	0.0	0.0	707	2165.16	1274.17	2069.29	17423.46

Tabelle 6.9: Ergebnisse für KNN-100 für 8 Merkmale ohne EE-Fehler mit 12 Trainingsmonaten

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.4	771	1951.94	273.33	1650.34	1778.27
2013-02	0.0	0.4	637	1960.15	228.95	1668.88	1159.88
2013-03	0.5	0.1	820	2308.41	154.61	1520.78	1553.34
2013-04	0.3	0.0	766	1936.63	699.79	1475.99	1944.94
2013-05	0.1	0.1	678	1853.30	2345.76	1482.49	5990.48
2013-06	0.0	0.0	700	1980.22	1318.34	1840.62	6147.70
2013-071	0.0	0.0	608	1997.96	1958.60	2248.56	15622.74
2013-08	0.0	0.0	630	2141.82	3157.52	2044.01	12657.17
2013-09	0.0	0.2	646	2079.84	2376.91	1926.92	4270.15
2013-10	0.1	0.0	692	2009.53	1122.32	1635.54	8153.35
2013-11	0.1	0.0	515	2114.55	593.09	2115.98	6550.85
2013-12	0.0	0.0	683	2132.50	1340.06	1505.00	11507.20

Tabelle 6.10: Ergebnisse für GBT-09975 für 8 Merkmale ohne EE-Fehler mit 12 Trainingsmonaten

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.2	836	1615.45	241.85	1347.32	1094.15
2013-02	0.0	0.2	658	1551.80	178.67	975.59	579.54
2013-03	0.1	0.1	747	1815.93	123.64	1134.15	1109.72
2013-04	0.2	0.0	779	1694.50	686.39	999.39	1496.37
2013-05	0.2	0.0	711	1634.68	2168.75	1058.29	4448.38
2013-06	0.0	0.0	715	1681.65	1092.11	1360.96	4130.91
2013-07	0.0	0.0	615	1617.79	1303.94	1422.01	10486.74
2013-08	0.0	0.0	675	1609.72	2325.97	1329.33	7952.94
2013-09	0.0	0.2	662	1749.83	2089.12	1424.77	3184.94
2013-10	0.0	0.0	665	1765.68	985.36	1511.88	7240.07
2013-11	0.0	0.0	542	1826.04	516.52	1632.86	4428.54
2013-12	0.0	0.0	696	1942.24	1196.44	1633.05	13039.76

Tabelle 6.11: Ergebnisse für KNN-100 mit 10 Merkmalen und 12 Trainingsmonaten und Berücksichtigung der Korrelation sowie doppelter Gewichtung

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.3	813	1920.61	273.99	1402.46	1562.48
2013-02	0.0	0.3	620	1815.13	208.17	1542.61	1104.07
2013-03	0.1	0.0	773	2323.03	155.17	1254.75	1283.59
2013-04	0.2	0.0	774	1979.42	788.38	1499.51	2178.35
2013-05	0.1	0.1	660	1839.91	2506.40	1641.06	7114.58
2013-06	0.0	0.0	669	1891.05	1265.76	1907.41	6484.04
2013-07	0.0	0.0	583	2018.60	2019.23	2311.98	16456.48
2013-081	0.0	0.0	605	2151.34	3200.11	2014.08	12523.60
2013-09	0.1	0.2	649	2179.10	2599.83	1901.76	4170.49
2013-10	0.1	0.0	630	2103.81	1197.00	1607.54	7992.48
2013-11	0.0	0.0	505	2063.03	589.35	2008.15	6892.02
2013-12	0.0	0.0	663	2145.46	1334.45	1104.05	9312.62

Tabelle 6.12: Ergebnisse für GBT-09975 mit 10 Merkmalen und 12 Trainingsmonaten und Berücksichtigung der Korrelation sowie doppelter Gewichtung

KNN	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.2	846	1448.30	222.87	1108.13	853.00
2013-02	0.0	0.2	656	1429.58	158.83	804.59	508.49
2013-03	0.0	0.0	747	1738.23	108.99	1001.49	1021.47
2013-04	0.2	0.0	774	1633.23	663.86	1059.01	1489.67
2013-05	0.2	0.0	707	1525.43	2121.48	988.39	4136.46
2013-06	0.0	0.0	709	1563.37	1045.31	1159.18	3273.25
2013-07	0.0	0.0	605	1600.15	1510.66	1246.78	8942.70
2013-08	0.0	0.0	636	1594.51	2323.13	1107.41	6443.11
2013-09	0.1	0.1	653	1673.02	1999.79	1336.18	3012.38
2013-10	0.1	0.0	652	1695.08	983.63	1384.16	6380.56
2013-11	0.0	0.0	524	1748.80	489.04	1433.85	4328.40
2013-12	0.0	0.0	669	1898.99	1183.48	1406.25	10549.73

Tabelle 6.13: Ergebnisse für KNN-100 mit 10 Merkmalen und 12 Trainingsmonaten und Berücksichtigung der Korrelation

GBT	PU4[%]	PL4[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.2	812	1772.52	259.90	1245.51	1717.00
2013-02	0.0	0.3	638	1694.76	192.77	1551.69	1231.11
2013-03	0.2	0.0	799	2223.97	141.78	1364.09	1482.24
2013-04	0.2	0.0	782	1850.74	737.03	1406.13	2038.87
2013-05	0.1	0.1	665	1710.55	2297.72	1559.19	6751.81
2013-06	0.0	0.0	679	1780.04	1203.86	1926.89	6654.35
2013-07	0.0	0.0	584	1975.42	2000.58	2237.54	15929.69
2013-08	0.0	0.0	608	2101.19	3105.99	1956.61	12291.86
2013-09	0.1	0.2	649	2072.45	2472.40	1902.81	4279.40
2013-10	0.1	0.0	632	2027.46	1151.26	1661.14	8866.67
2013-11	0.0	0.0	504	1988.56	580.46	2163.15	7968.82
2013-12	0.0	0.0	660	2069.28	1272.18	826.46	7438.23

Tabelle 6.14: Ergebnisse für GBT-09975 mit 10 Merkmalen und 12 Trainingsmonaten und Berücksichtigung der Korrelation

Vergleichsergebnis des Einsparungspotentials ohne Berücksichtigung des EE-Fehlers.

	Einsparpotential negative MRL in [MW]						
Zeitscheibe	Theorie-Wi	Theorie-So	Studie	KNN-So	KNN-Wi	GBT-So	GBT-Wi
00:00-04:00	-2.226	-2.634	-2.017	-1.277	-1.572	-684	-847
04:00-08:00	-50	-2.421	-215	-967	-1.102	-675	-781
08:00-12:00	-129	-152	+386	-1.207	-918	-689	-713
12:00-16:00	-207	-128	+282	-1.161	-908	-705	-740
16:00-20:00	-1.510	-2.393	-134	-1.285	-1.139	-729	-780
20:00-24:00	-1.097	-1780	-877	-1.148	-1.149	-697	-773

Tabelle 6.15: Ergebnis der Einsparpotentiale für negative MRL im Vergleich ohne EE Fehler

	Einsparpotential positive MRL in [MW]						
Zeitscheibe	Theorie-Wi	Theorie-So	Studie	KNN-So	KNN-Wi	GBT-So	GBT-Wi
00:00-04:00	-2.791	-1.915	-1.219	-1.734	-1.859	-1.131	-1.350
04:00-08:00	-2.132	-1.676	-342	-1.376	-1.312	-957	-1.159
08:00-12:00	-1.727	-69	+419	-1.135	-1.059	-979	-979
12:00-16:00	-2.176	-902	+399	-1.109	-1.165	-1.004	-989
16:00-20:00	-746	-1.463	-457	-1.385	-1.214	-950	-1.045
20:00-24:00	-1.290	-2.003	-877	-1.541	-1.555	-1.025	-1.282

Tabelle 6.16: Ergebnis der Einsparpotentiale für positive MRL im Vergleich ohne EE-Fehler

Die folgenden Ergebnisse beziehen sich alle auf den Simulationsfall mit 10 Merkmalen, 12 Trainingsmonaten und unter Berücksichtigung der Korrelation.

	Einsparpotential negative MRL in [MW]						
Zeitscheibe	Theorie-Wi	Theorie-So	Studie	KNN-So	KNN-Wi	GBT-So	GBT-Wi
00:00-04:00	-2.226	-2.634	-2.017	-616	-696	-406	-320
04:00-08:00	-50	-2.421	-215	-476	-554	-392	-306
08:00-12:00	-129	-152	+386	-557	-627	-366	-284
12:00-16:00	-207	-128	+282	-583	-590	-363	-301
16:00-20:00	-1.510	-2.393	-134	-523	-494	-358	-306
20:00-24:00	-1.097	-1780	-877	-407	-405	-372	-265

Tabelle 6.17: Ergebnis der Einsparpotentiale für negative MRL im Vergleich mit Korrelation

	Einsparpotential positive MRL in [MW]						
Zeitscheibe	Theorie-Wi	Theorie-So	Studie	KNN-Wi	KNN-So	GBT-Wi	GBT-So
00:00-04:00	-2.791	-1.915	-1.219	-1.406	-1.418	-1.220	-1.118
04:00-08:00	-2.132	-1.676	-342	-1.177	-1.044	-1.120	-947
08:00-12:00	-1.727	-69	+419	-1.020	-924	-1.095	-955
12:00-16:00	-2.176	-902	+399	-1.055	-970	-1.112	-923
16:00-20:00	-746	-1.463	-457	-1.294	-1.050	-1.092	-913
20:00-24:00	-1.290	-2.003	-877	-1.420	-1.423	-1.162	-1.058

Tabelle 6.18: Ergebnis der Einsparpotentiale für positive MRL im Vergleich mit Korrelation

KNN_500	PU4[]	PL4[]	RSME[MW]	Pos[MW]	Pos[TEUR]	Neg[MW]	Neg[TEUR]
2013-01	0.0	0.1	823	1123.76	156.40	584.49	413.96
2013-02	0.0	0.1	641	1108.58	116.69	276.63	205.32
2013-03	0.0	0.0	751	1270.66	79.87	359.52	442.76
2013-04	0.2	0.0	764	1223.48	515.14	428.80	629.08
2013-05	0.1	0.0	693	1125.57	1548.81	476.22	2045.22
2013-06	0.0	0.0	712	1125.49	770.18	553.84	1561.34
2013-07	0.0	0.0	594	1069.81	905.74	591.25	3930.86
2013-08	0.0	0.0	628	1097.19	1612.63	539.25	2938.54
2013-09	0.0	0.0	649	1141.20	1329.04	625.02	1380.18
2013-10	0.0	0.0	649	1211.40	640.25	661.48	3029.45
2013-11	0.0	0.0	518	1254.32	300.24	723.44	1758.53
2013-12	0.0	0.0	663	1364.56	859.35	719.28	4523.47

Tabelle 6.19: Ergebnis der Einsparungspotentiale für das Jahr 2013 mit KNN-500 auf 4 Stunden Basis

KNN_500	PU[%]	PL[%]	RSME	Pos[MW]	Pos[TSD.EUR]	Neg[MW]	Neg[TSD.EUR]
2013-01	0.0	0.1	823	1464.26	216.32	958.68	765.73
2013-02	0.0	0.2	641	1449.00	160.62	733.41	444.42
2013-03	0.0	0.0	751	1663.87	108.99	859.44	882.65
2013-04	0.2	0.0	764	1609.19	670.83	862.87	1202.11
2013-05	0.2	0.0	693	1551.66	2104.95	887.86	3791.35
2013-06	0.0	0.0	712	1575.14	1073.36	1096.92	3293.86
2013-07	0.0	0.0	594	1549.23	1485.32	1190.01	8254.05
2013-08	0.0	0.0	628	1545.00	2263.10	1209.14	7094.12
2013-09	0.0	0.0	649	1650.45	1982.68	1210.83	2578.04
2013-10	0.0	0.0	649	1694.64	969.08	1302.41	5969.85
2013-11	0.0	0.0	518	1755.96	482.26	1303.71	3573.72
2013-12	0.0	0.1	663	1813.77	1151.45	1288.75	9371.70

Tabelle 6.20: Ergebnis der Einsparpotentiale für das Jahr 2013 mit KNN-500 auf 1 Stunden Basis

KNN_100	PU[%]	PL[%]	RSME	Pos[MW]	Pos[TEUR]	Neg[MW]	Neg[TEUR]
2013-01	0.0	0.2	846	1448.30	222.87	1108.13	853.00
2013-02	0.0	0.2	656	1429.58	158.83	804.59	508.49
2013-03	0.0	0.0	747	1738.23	108.99	1001.49	1021.47
2013-04	0.2	0.0	774	1633.23	663.86	1059.01	1489.67
2013-05	0.2	0.0	707	1525.43	2121.48	988.39	4136.46
2013-06	0.0	0.0	709	1563.37	1045.31	1159.18	3273.25
2013-07	0.0	0.0	605	1600.15	1510.66	1246.78	8942.70
2013-08	0.0	0.0	636	1594.51	2323.13	1107.41	6443.11
2013-09	0.1	0.1	653	1673.02	1999.79	1336.18	3012.38
2013-10	0.1	0.0	652	1695.08	983.63	1384.16	6380.56
2013-11	0.0	0.0	524	1748.80	489.04	1433.85	4328.40
2013-12	0.0	0.0	669	1898.99	1183.48	1406.25	10549.73

Tabelle 6.21: Ergebnis der Einsparpotentiale für das Jahr 2013 mit KNN-100 auf 4 Stunden Basis

Die folgenden Ergebnisse beziehen sich alle auf den letzten Simulationsfall mit 10 Merkmalen, 12 Trainingsmonaten und ohne Berücksichtigung der Korrelation.

KNN_500	PU[%]	PL[%]	RSME	Pos[MW]	Pos[TEUR]	Neg[MW]	Neg[TEUR]
2013-01	0.0	0.5	803	1433.54	194.61	1320.97	1013.07
2013-02	0.0	0.2	632	1568.54	186.38	1227.63	610.83
2013-03	0.0	0.1	737	1719.78	114.58	1288.41	1255.75
2013-04	0.2	0.0	747	1607.88	659.90	1124.65	1369.65
2013-05	0.1	0.0	679	1586.57	2046.67	1212.16	5534.23
2013-06	0.0	0.0	703	1691.44	1087.28	1369.56	4226.28
2013-07	0.0	0.0	596	1524.71	1249.08	1360.45	9405.78
2013-08	0.0	0.0	625	1602.56	2325.23	1276.74	7911.85
2013-09	0.0	0.0	648	1744.37	1981.98	1386.01	3039.10
2013-10	0.0	0.0	642	1805.97	1015.62	1577.41	7659.78
2013-11	0.0	0.0	520	1742.44	477.08	1653.14	4105.02
2013-12	0.0	0.0	660	1971.16	1147.75	1861.35	15204.94

Tabelle 6.22: Ergebnis der Einsparpotentiale für das Jahr 2013 mit KNN-500 auf 4 Stunden Basis ohne Korrelation

KNN_100	PU[%]	PL[%]	RSME	Pos[MW]	Pos[TEUR]	Neg[MW]	Neg[TEUR]
2013-01	0.0	0.7	825	1972.82	284.52	1828.75	2109.01
2013-02	0.0	0.2	661	2128.02	235.36	1843.21	1085.00
2013-03	0.0	0.6	737	2233.69	160.75	1908.50	1963.76
2013-04	0.6	0.1	766	2147.24	819.24	1900.84	2419.23
2013-05	0.2	0.0	689	2240.55	2961.76	1916.27	8660.83
2013-06	0.1	0.0	705	2111.22	1407.58	2004.62	6366.94
2013-07	0.0	0.0	618	2052.43	1815.11	1964.34	13502.11
2013-08	0.0	0.0	639	2107.83	3101.19	1909.86	11638.29
2013-09	0.1	0.2	672	2262.61	2654.15	2071.64	4716.21
2013-10	0.0	0.1	652	2263.63	1280.37	2087.49	10305.57
2013-11	0.0	0.0	538	2210.52	631.18	2230.87	6900.22
2013-12	0.0	0.1	671	2475.22	1429.77	2420.12	22133.32

Tabelle 6.23: Ergebnis der Einsparpotentiale für das Jahr 2013 mit KNN-100 auf 4 Stunden Basis ohne Korrelation

Im Folgenden werden die mittleren Fehler der einzelnen Methoden für die Jahre 2012 und 2013 gegenübergestellt, jeweils für die Simulationsbelegung mit 10 Merkmalen, 12 Trainingsmonaten und ohne Berücksichtigung der Korrelation.

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2012-01	979	1077	1067	1058	1064	1132
2012-02	1100	1221	1214	1217	1213	1102
2012-03	808	816	827	815	831	927
2012-04	831	855	876	867	879	1182
2012-05	1008	1061	1046	1063	1049	1223
2012-06	824	987	990	992	997	1119
2012-07	577	670	699	668	707	808
2012-08	701	783	804	792	808	925
2012-09	613	659	674	662	681	793
2012-10	745	797	825	789	830	950
2012-11	622	704	712	718	714	844
2012-12	960	1009	984	999	984	1106

Tabelle 6.24: mittlerer Testfehler (RMSE) für den NRV für 1-day-ahead für 2012

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2013-01	808	825	818	840	813	851
2013-02	552	661	649	665	646	774
2013-03	779	737	730	743	728	949
2013-04	752	766	762	760	769	1030
2013-05	642	689	692	698	694	887
2013-06	677	705	703	707	700	845
2013-07	579	618	625	624	621	755
2013-08	602	639	637	639	640	759
2013-09	643	672	672	676	679	860
2013-10	662	652	646	663	647	833
2013-11	511	538	538	546	543	703
2013-12	667	671	669	680	674	862

Tabelle 6.25: mittlerer Testfehler (RMSE) für NRV für 1-day-ahead für 2013

Ergebnisse der Regelzonen

50 Hertz

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2012-01	899	1036	1037	1031	1037	675
2012-02	490	602	664	627	652	587
2012-03	421	531	541	517	558	588
2012-04	335	450	472	448	490	575
2012-05	546	532	526	544	536	524
2012-06	390	454	474	467	467	584
2012-07	310	322	327	324	324	531
2012-08	301	313	318	312	326	466
2012-09	300	333	334	333	339	455
2012-10	338	352	349	354	348	539
2012-11	290	299	300	300	300	470
2012-12	443	402	415	402	416	590

Tabelle 6.26: mittlerer Testfehler (RMSE) für 50 Hertz für 1-day-ahead für 2012

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2013-01	348	336	335	337	333	483
2013-02	286	295	291	294	289	477
2013-03	360	357	356	358	358	518
2013-04	379	370	364	370	364	541
2013-05	346	405	406	415	405	481
2013-06	352	374	371	373	375	537
2013-07	290	291	295	291	294	448
2013-08	325	345	342	344	342	500
2013-09	348	362	364	362	362	471
2013-10	356	334	328	333	326	506
2013-11	309	310	302	310	304	478
2013-12	388	380	376	380	374	583

Tabelle 6.27: mittlerer Testfehler (RMSE) für 50 Hertz für 1-day-ahead für 2013

2012	Saldo	PVE	PVER	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.139	0.054	0.065	0.181	0.119	0.122	0.122	0.087	0.107	0.004
Feb.	0.164	0.047	0.032	0.130	0.153	0.115	0.210	0.081	0.061	0.007
März	0.137	0.042	0.040	0.113	0.146	0.121	0.273	0.075	0.050	0.002
Apr.	0.084	0.062	0.086	0.117	0.168	0.190	0.136	0.102	0.049	0.005
Mai	0.071	0.078	0.142	0.154	0.153	0.193	0.062	0.067	0.080	0.001
Juni	0.076	0.111	0.126	0.132	0.120	0.221	0.071	0.075	0.062	0.005
Juli	0.062	0.136	0.145	0.152	0.082	0.216	0.081	0.054	0.071	0.002
Aug.	0.070	0.176	0.156	0.131	0.093	0.225	0.014	0.058	0.078	0.000
Sep.	0.059	0.146	0.164	0.141	0.110	0.215	0.045	0.036	0.080	0.005
Okt.	0.063	0.126	0.139	0.133	0.115	0.241	0.058	0.041	0.076	0.008
Nov.	0.057	0.099	0.112	0.106	0.126	0.300	0.057	0.065	0.066	0.014
Dez.	0.069	0.104	0.087	0.125	0.135	0.324	0.024	0.052	0.074	0.006

Tabelle 6.28: Relative Merkmalsrelevanz in der 50 Hertz Zone im Jahr 2012

2013	Saldo	PVE	PVER	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.048	0.083	0.061	0.160	0.102	0.322	0.047	0.084	0.092	0.002
Feb.	0.077	0.060	0.035	0.173	0.074	0.294	0.075	0.083	0.130	0.001
März	0.063	0.029	0.027	0.168	0.108	0.345	0.039	0.105	0.116	0.000
Apr.	0.062	0.038	0.115	0.116	0.148	0.319	0.034	0.078	0.091	0.000
Mai	0.071	0.040	0.101	0.128	0.175	0.281	0.055	0.073	0.076	0.000
Juni	0.055	0.056	0.105	0.126	0.154	0.283	0.080	0.079	0.063	0.000
Juli	0.040	0.046	0.085	0.134	0.173	0.296	0.064	0.073	0.090	0.000
Aug.	0.067	0.080	0.116	0.109	0.148	0.295	0.035	0.051	0.099	0.000
Sept.	0.070	0.060	0.103	0.116	0.135	0.284	0.045	0.069	0.118	0.000
Okt.	0.071	0.111	0.103	0.090	0.109	0.255	0.070	0.049	0.139	0.003
Nov.	0.054	0.111	0.096	0.079	0.141	0.252	0.100	0.052	0.111	0.004
Dez.	0.052	0.121	0.099	0.078	0.171	0.255	0.078	0.083	0.063	0.001

Tabelle 6.29: Relative Merkmalsrelevanz in der 50 Hertz Zone im Jahr 2013

Amprion

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2012-01	522	549	543	547	545	609
2012-02	592	607	605	587	584	559
2012-03	438	516	537	512	539	493
2012-04	511	486	486	492	493	548
2012-05	526	552	578	550	577	640
2012-06	453	474	479	485	480	572
2012-07	404	412	412	413	409	479
2012-08	438	490	493	492	490	514
2012-09	389	374	372	374	374	453
2012-10	467	466	468	465	468	591
2012-11	413	428	423	427	425	513
2012-12	503	524	521	523	522	638

Tabelle 6.30: mittlerer Testfehler (RMSE) für Amprion für 1-day-ahead für 2012

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2013-01	456	466	466	468	464	510
2013-02	442	478	471	477	471	538
2013-03	433	435	444	438	442	533
2013-04	426	428	431	432	432	546
2013-05	434	452	453	454	451	584
2013-06	484	466	465	477	460	505
2013-07	364	383	383	396	382	472
2013-08	355	366	371	361	369	431
2013-09	401	446	447	446	447	522
2013-10	417	429	431	430	429	485
2013-11	379	369	373	370	370	456
2013-12	485	505	507	504	507	598

Tabelle 6.31: mittlerer Testfehler (RMSE) für Amprion für 1-day-ahead für 2013

2012	Saldo	PVE	PVEr	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.184	0.029	0.062	0.163	0.114	0.089	0.034	0.120	0.202	0.002
Feb.	0.189	0.022	0.050	0.167	0.101	0.100	0.049	0.096	0.219	0.007
März	0.258	0.028	0.050	0.142	0.104	0.097	0.061	0.090	0.165	0.003
Apr.	0.255	0.044	0.068	0.160	0.115	0.110	0.056	0.057	0.131	0.004
Mai	0.262	0.051	0.082	0.140	0.086	0.081	0.085	0.081	0.128	0.004
Juni	0.180	0.103	0.079	0.145	0.135	0.110	0.067	0.064	0.107	0.010
Juli	0.163	0.110	0.054	0.152	0.145	0.080	0.052	0.094	0.141	0.009
Aug.	0.162	0.070	0.059	0.145	0.166	0.092	0.059	0.086	0.144	0.018
Sep.	0.164	0.090	0.095	0.163	0.114	0.068	0.046	0.099	0.148	0.014
Okt.	0.183	0.078	0.128	0.141	0.082	0.060	0.077	0.092	0.145	0.015
Nov.	0.166	0.081	0.110	0.166	0.091	0.056	0.080	0.095	0.125	0.030
Dez.	0.153	0.104	0.102	0.175	0.062	0.088	0.043	0.105	0.148	0.021

Tabelle 6.32: Relative Merkmalsrelevanz in der Amprion Zone im Jahr 2012

2013	Saldo	PVE	PVEr	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.137	0.087	0.073	0.184	0.128	0.049	0.042	0.123	0.171	0.007
Feb.	0.180	0.060	0.035	0.192	0.090	0.041	0.058	0.126	0.209	0.009
März	0.199	0.048	0.046	0.168	0.114	0.070	0.052	0.107	0.194	0.003
Apr.	0.206	0.062	0.093	0.157	0.092	0.085	0.046	0.079	0.173	0.006
Mai	0.153	0.080	0.146	0.153	0.104	0.103	0.054	0.066	0.137	0.004
Juni	0.082	0.104	0.112	0.186	0.114	0.128	0.062	0.086	0.113	0.015
Juli	0.084	0.145	0.109	0.176	0.059	0.132	0.081	0.069	0.137	0.008
Aug.	0.093	0.143	0.101	0.188	0.073	0.126	0.058	0.085	0.129	0.003
Sep.	0.127	0.147	0.120	0.161	0.089	0.120	0.052	0.082	0.095	0.008
Okt.	0.111	0.147	0.112	0.150	0.117	0.094	0.056	0.094	0.111	0.008
Nov.	0.131	0.103	0.085	0.198	0.155	0.081	0.046	0.057	0.138	0.006
Dez.	0.122	0.097	0.076	0.226	0.136	0.084	0.041	0.090	0.120	0.006

Tabelle 6.33: Relative Merkmalsrelevanz in der Amprion Zone im Jahr 2013

Tennet

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2012-01	447	481	482	484	480	573
2012-02	465	473	473	478	472	531
2012-03	441	440	439	439	436	570
2012-04	415	439	429	437	431	628
2012-05	431	410	416	409	418	571
2012-06	396	396	404	397	402	558
2012-07	322	328	326	328	328	463
2012-08	372	382	385	384	383	542
2012-09	364	347	348	347	347	456
2012-10	381	416	415	416	415	481
2012-11	360	328	329	328	330	461
2012-12	459	463	463	462	461	615

Tabelle 6.34: mittlerer Testfehler (RMSE) für Tennet für 1-day-ahead für 2012

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2013-01	392	359	362	360	361	464
2013-02	326	330	329	334	329	479
2013-03	497	473	461	470	463	647
2013-04	475	448	450	448	447	580
2013-05	388	380	394	381	391	502
2013-06	426	450	439	447	439	545
2013-07	290	288	293	291	291	382
2013-08	317	313	307	313	307	418
2013-09	345	356	355	356	355	488
2013-10	387	392	389	392	390	515
2013-11	312	288	287	288	287	412
2013-12	402	385	387	384	387	506

Tabelle 6.35: mittlerer Testfehler (RMSE) für Tennet für 1-day-ahead für 2013

2012	Saldo	PVE	PVEr	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.169	0.040	0.159	0.113	0.158	0.136	0.092	0.075	0.054	0.003
Feb.	0.179	0.062	0.114	0.121	0.125	0.158	0.085	0.084	0.067	0.004
März	0.182	0.047	0.069	0.124	0.197	0.146	0.084	0.087	0.057	0.005
Apr.	0.147	0.056	0.108	0.126	0.192	0.180	0.038	0.096	0.053	0.004
Mai	0.107	0.081	0.125	0.143	0.134	0.179	0.076	0.087	0.056	0.011
Juni	0.068	0.069	0.139	0.129	0.153	0.231	0.059	0.056	0.085	0.010
Juli	0.074	0.081	0.137	0.147	0.118	0.211	0.092	0.055	0.078	0.007
Aug.	0.076	0.097	0.137	0.145	0.155	0.225	0.037	0.057	0.065	0.005
Sep.	0.098	0.070	0.175	0.107	0.112	0.248	0.058	0.070	0.060	0.001
Okt.	0.091	0.112	0.159	0.123	0.146	0.221	0.054	0.061	0.032	0.002
Nov.	0.104	0.100	0.165	0.109	0.162	0.194	0.061	0.059	0.045	0.001
Dez.	0.110	0.103	0.143	0.101	0.146	0.169	0.063	0.069	0.092	0.005

Tabelle 6.36: Relative Merkmalsrelevanz in der Tennet Zone im Jahr 2012

2013	Saldo	PVE	PVEr	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.135	0.055	0.117	0.108	0.127	0.195	0.068	0.081	0.105	0.008
Feb.	0.111	0.061	0.095	0.117	0.148	0.214	0.056	0.078	0.111	0.011
März	0.094	0.065	0.106	0.125	0.156	0.223	0.032	0.080	0.118	0.000
Apr.	0.072	0.052	0.166	0.121	0.148	0.237	0.050	0.089	0.064	0.001
Mai	0.099	0.068	0.184	0.101	0.122	0.224	0.065	0.092	0.044	0.000
Juni	0.096	0.089	0.152	0.111	0.145	0.226	0.053	0.091	0.038	0.000
Juli	0.104	0.079	0.106	0.161	0.164	0.196	0.054	0.088	0.048	0.000
Aug.	0.106	0.087	0.097	0.155	0.153	0.218	0.042	0.085	0.056	0.000
Sep.	0.113	0.073	0.114	0.105	0.121	0.278	0.081	0.055	0.058	0.002
Okt.	0.087	0.096	0.124	0.148	0.152	0.216	0.074	0.050	0.050	0.003
Nov.	0.083	0.105	0.123	0.126	0.178	0.203	0.047	0.052	0.064	0.018
Dez.	0.067	0.088	0.154	0.110	0.163	0.218	0.052	0.066	0.071	0.011

Tabelle 6.37: Relative Merkmalsrelevanz in der Tennet Zone im Jahr 2013

Transnet

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2012-01	231	247	251	247	245	266
2012-02	249	267	268	268	270	256
2012-03	212	228	224	228	223	271
2012-04	329	316	310	316	307	316
2012-05	480	507	501	507	498	490
2012-06	270	257	284	249	287	232
2012-07	188	224	249	222	255	233
2012-08	212	220	237	218	237	234
2012-09	180	185	185	186	185	231
2012-10	203	201	199	200	200	248
2012-11	171	163	161	163	162	217
2012-12	191	194	194	195	194	234

Tabelle 6.38: mittlerer Testfehler (RMSE) für TransnetBW für 1-day-ahead für 2012

Methode	GBT_0.99	KNN_100	KNN_GBT	KNN_PCA	KNN_RFT	Persistenz
2013-01	253	259	257	260	257	241
2013-02	176	177	178	182	177	225
2013-03	232	226	223	218	224	239
2013-04	216	246	247	251	246	262
2013-05	215	208	208	209	208	250
2013-06	209	215	215	212	214	236
2013-07	173	172	172	171	172	207
2013-08	202	221	219	219	220	228
2013-09	236	224	225	223	225	209
2013-10	194	234	236	234	236	256
2013-11	187	189	187	189	189	228
2013-12	191	191	191	191	191	257

Tabelle 6.39: mittlerer Testfehler (RMSE) für TransnetBW für 1-day-ahead für 2013

2012	Saldo	PVE	PVEr	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.131	0.057	0.135	0.217	0.107	0.066	0.094	0.084	0.108	0.000
Feb.	0.137	0.078	0.103	0.206	0.097	0.058	0.070	0.090	0.161	0.000
März	0.175	0.039	0.109	0.220	0.097	0.048	0.055	0.097	0.159	0.000
Apr.	0.162	0.081	0.087	0.210	0.109	0.054	0.053	0.105	0.134	0.003
Mai	0.220	0.043	0.102	0.170	0.103	0.055	0.071	0.146	0.088	0.001
Juni	0.325	0.056	0.122	0.099	0.057	0.043	0.076	0.158	0.064	0.000
Juli	0.348	0.053	0.121	0.106	0.055	0.044	0.053	0.174	0.046	0.000
Aug.	0.360	0.082	0.089	0.093	0.048	0.024	0.078	0.202	0.025	0.000
Sep.	0.113	0.159	0.149	0.201	0.079	0.037	0.066	0.109	0.087	0.000
Okt.	0.104	0.156	0.194	0.154	0.054	0.031	0.107	0.120	0.079	0.001
Nov.	0.130	0.115	0.190	0.161	0.056	0.088	0.068	0.109	0.082	0.000
Dez.	0.137	0.127	0.191	0.140	0.068	0.090	0.044	0.134	0.068	0.001

Tabelle 6.40: Relative Merkmalsrelevanz in der Transnet Zone im Jahr 2012

2013	Saldo	PVE	PVEr	VNLast	WindE	WindEr	Monat	Tag	TOD	BOH
Jan.	0.111	0.100	0.134	0.171	0.106	0.117	0.079	0.104	0.078	0.000
Feb.	0.101	0.074	0.082	0.176	0.129	0.067	0.164	0.121	0.086	0.001
März	0.113	0.055	0.065	0.175	0.125	0.109	0.117	0.144	0.097	0.000
Apr.	0.107	0.095	0.086	0.156	0.084	0.130	0.154	0.101	0.086	0.001
Mai	0.082	0.089	0.148	0.151	0.102	0.112	0.159	0.059	0.095	0.001
Juni	0.106	0.093	0.150	0.152	0.110	0.095	0.107	0.080	0.108	0.000
Juli	0.130	0.117	0.121	0.167	0.104	0.099	0.084	0.074	0.103	0.000
Aug.	0.149	0.112	0.109	0.174	0.071	0.115	0.089	0.098	0.079	0.003
Sep.	0.145	0.119	0.111	0.158	0.062	0.094	0.139	0.087	0.076	0.007
Okt.	0.144	0.128	0.116	0.141	0.065	0.059	0.185	0.095	0.066	0.001
Nov.	0.085	0.087	0.108	0.132	0.073	0.062	0.280	0.099	0.071	0.002
Dez.	0.097	0.117	0.147	0.198	0.107	0.088	0.086	0.081	0.078	0.001

Tabelle 6.41: Relative Merkmalsrelevanz in der Transnet Zone im Jahr 2013

6.2 Statistische Grundlagen

Kenngößen von Zeitreihen

Die zentrale Lage der Werte einer Zeitreihe $(x_t)_{t=1, \dots, N}$ wird beschrieben durch das arithmetische Mittel und es gilt [SS01]:

$$\bar{x} := \frac{1}{N} \sum_{t=1}^N x_t \quad (6.1)$$

Dieser Mittelwert \bar{x} ist der Wert, um den die Beobachtungen schwanken. Die Höhe dieser Schwankung wird durch die empirische Varianz σ gemessen, bzw. deren Wurzel der Standardabweichung s . Die Standardabweichung s ist definiert als die mittlere Abweichung vom Mittelwert und berechnet sich wie folgt:

$$s := \sqrt{\frac{1}{N} \sum_{p=1}^N (x_t - \bar{x})^2} \quad (6.2)$$

Diese sogenannte empirische Verteilungsfunktion ist wie folgt definiert [Koc12]:

Definition der empirischen Verteilungsfunktion

Der Wert $\hat{F}(x)$ der empirischen Verteilungsfunktion ist die relative Häufigkeit der Elemente, deren Ausprägungen kleiner oder gleich x sind:

$$\hat{F}(x) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(x_i) = \frac{1}{n} \text{card}\{x_i : x_i \leq x\} \quad (6.3)$$

Dabei ist $\text{card}\{M\}$ die Anzahl der Elemente der Menge M und $I_{(-\infty, x]}$ die **Indikatorfunktion** des Intervalls $(-\infty, x]$.

Bei unendlich vielen Messungen erhält man beliebig kleine Stufen und dann die **theoretische Verteilungsfunktion**. Für stetige Zufallsvariablen wird diese Wahrscheinlichkeitsfunktion durch die sogenannte Wahrscheinlichkeitsdichtefunktion (engl. density function for continuous random variables) angegeben. Die Fläche unter dieser Funktion gibt die Wahrscheinlichkeit an, mit der die Ereignisse innerhalb dieses Intervalls eintreten. Es gilt entsprechend $P(a < X < b) = \int_a^b f(x) dx$.

Zur Bestimmung werden sogenannte Quantile verwendet. Spezielle Quantile sind z.B. der Median. Ein p -Quantil entspricht demjenigen x -Wert der Verteilung, der $p \cdot N$ Beobachtungen einschließt. Es gilt:

$$x_\alpha = \min\{x \text{ mit } F(x) \geq \alpha\} \quad (6.4)$$

Ungleichung von Tschebyschev Es seien \bar{x} und s^2 Mittelwert und Varianz einer Stichprobe $x_{i,1}, \dots, x_{i,n}$ und k eine beliebige feste positive Zahl. Dann gilt¹ Der Anteil der Daten x_i , die vom Mittelwert \bar{x} einen Abstand von mindestens k Standardabweichungen haben, ist höchstens $\frac{1}{k^2}$:

$$\frac{\text{card}\{x_i \mid |x_i - \bar{x}| \geq k \cdot s\}}{n} \leq \frac{1}{k^2} \quad (6.5)$$

¹ [Koc12]

Ist es nicht möglich die theoretische Verteilungsfunktion F vorzugeben, besteht die Möglichkeit der Approximation mit Hilfe von sogenannten Kernfunktionen.

Kernfunktionen

Eine Kernfunktion $K(x)$ ist eine symmetrische, nicht negative Funktion mit $\int_{-\infty}^{+\infty} K(x)dx = 1$.

Ein Beispiel für eine Kernfunktion ist der sog. Gauß-Kernel [SS03]:

$$K(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \quad (6.6)$$

Mit einer gewählten Fensterbreite σ der Kernfunktion folgt für jeden Punkt x_i

$$x_i \rightarrow \frac{1}{\sigma} K\left(\frac{x - x_i}{\sigma}\right) \quad (6.7)$$

Die gesamte Häufigkeitsverteilung $\hat{h}(x)$ erhält man durch Addition aller dieser Funktionen im Bereich eines Punkts x [SS03]:

$$\hat{h}(x) = \frac{1}{\sigma} \sum_{i=1}^n K\left(\frac{x - x_i}{\sigma}\right) \quad (6.8)$$

Für die relative Häufigkeit muss noch durch die Anzahl Beobachtungen geteilt werden. Dann erhält man den sog. Kerndichteschätzer [SS03]:

$$\hat{f}(x) = \frac{1}{n\sigma} \sum_{i=1}^n K\left(\frac{x - x_i}{\sigma}\right) \quad (6.9)$$

Kernmethoden bieten die Möglichkeit, dass sich auch nicht lineare Zusammenhänge durch Transformation in andere Merkmalsräume als lineare Probleme beschreiben lassen. So entsprechen positive quadratische Funktionale, Skalarprodukten in Hilberträumen [Smo99].

Korrelation von Zeitreihen

Eine Möglichkeit Muster bzw. die *Ähnlichkeit* zweier Kurvenabschnitt zu erkennen, ist mit Hilfe der Kovarianz bzw. Korrelation. Dazu werden Abhängigkeiten zwischen den Datenpunkten zu verschiedenen Zeitpunkten analysiert, indem die allgemeine lineare Abhängigkeit zwischen zwei Datenpaaren, die mit der Kovarianz bzw. des Korrelationskoeffizienten gemessen wird, auf die Zeitreihe übertragen wird. In diesem Fall ist jedoch möglich, dass die beiden Kurven in der absoluten Höhe der Realisation auseinander bzw. verschoben liegen. Werden in einer Zeitreihe dementsprechend die Kovarianz zwischen zwei um τ Schritte gegeneinander verschobenen Zeitreihen, so erhält man [SS01]:

Kovarianz bei Zeitreihen

$$cov_{\tau} = \frac{1}{N} \sum_{t=1}^{N-\tau} (y_t - \bar{y})(y_{t+\tau} - \bar{y}) \text{ mit } \tau = 0, 1, 2, \dots, N - \tau. \quad (6.10)$$

Dabei kann vereinfacht der Mittelwert \bar{x} für beide Zeitreihen angenommen werden. Des Weiteren kann für genügend kleine Freiheitsgrade τ vereinfacht durch N anstelle $N - \tau$ geteilt werden. Für ein $\tau = 0$ erhält man die Varianz der Zeitreihe $c_0 = \sigma_{t,N}$. Dementsprechend ist der Korrelationskoeffizient zweier verschobener Zeitreihen der Quotient aus der Kovarianz der Zeitreihen und der Varianz der Zeitreihe selbst. Er gibt Auskunft über eine mögliche „Autokorrelation“ zum Lag τ .

Korrelation bei Zeitreihen

$$C(\tau) = r_{\tau} = \frac{cov_{\tau}}{cov_0} = \frac{\sigma_{t,t+\tau}}{\sigma_t^2} = \frac{\sum_{t=1}^{N-|\tau|} (y_t - \bar{y})(y_{t+|\tau|} - \bar{y})}{\sum_{t=1}^N (y_t - \bar{y})^2} \quad (6.11)$$

Fehlermaße

Es werden zur Fehlerermittlung die Residuen ermittelt.

$$e_t = y_t - \hat{y}_t \quad (6.12)$$

Mit den Residuen ergeben sich die folgenden Fehlermaße:

Mittlerer Prognosefehler (ME):

$$ME = \frac{1}{l} \sum_{t=T+1}^{T+l} e_t \quad (6.13)$$

Summe der quadratischen Prognosefehler (SEE):

$$SSE = \sum_{t=T+1}^{T+l} e_t^2 \quad (6.14)$$

Mittlerer quadratischer Prognosefehler (MSE):

$$MSE = \frac{1}{l} \sum_{t=T+1}^{T+l} e_t^2 \quad (6.15)$$

Wurzel des mittlerer quadratischer Prognosefehlers (RMSE):

$$RMSE = \sqrt{MSE} \quad (6.16)$$

Glossar

Nachfolgend sind noch einmal wesentliche Begriffe dieser Arbeit zusammengefasst und erläutert. Eine ausführliche Erklärung findet sich jeweils in den einführenden Abschnitten sowie der jeweils darin angegebenen Literatur. Das im Folgenden im Rahmen der Erläuterung verwendete Symbol \sim bezieht sich jeweils auf den im Einzelnen vorgestellten Begriff, das Symbol \uparrow verweist auf einen ebenfalls innerhalb dieses Glossars erklärten Begriff. Der Glossar entstand innerhalb des Projekts Smart Nord [Smart Nord].

Agent Ein \sim ist ein autonomes Computersystem, das in einer Umgebung lokalisiert ist und diese durch Sensoren wahrnehmen und durch Aktoren beeinflussen kann, um seine Zielvorgabe zu erreichen.

Anlage Eine \sim bezeichnet eine \uparrow energie bereitstellende \uparrow Einheit.

Arbeit \uparrow Energie

Arbeitspreis Der \sim , ausgedrückt in ct/kWh oder ct/kvarh, ist das Entgelt pro Einheit elektrischer \uparrow Arbeit bzw. Blindarbeit.

Ausgleichsenergie Die \sim bezeichnet die Differenz zwischen der in einem vereinbarten Zeitintervall prognostizierten und tatsächlichen Entnahme oder Einspeisung von elektrischer \uparrow Energie in einem \uparrow Bilanzkreis. Im Gegensatz zur \uparrow Regelenergie dient sie im Rahmen der Bilanzkreisabrechnung ausschließlich zur ökonomischen Bilanzierung.

Bilanzkreis Ein \sim ist ein bilanzielles Gebilde, das sich aus einer beliebigen Anzahl von Einspeise- und Entnahmestellen zusammensetzt und zum Zweck des Ausgleichs zwischen Einspeisung und Entnahme gegenüber dem jeweiligen \uparrow Uebertragungsnetzbetreiber eingerichtet wird. Ein \sim kann lediglich innerhalb von \uparrow Regelzone gebildet werden und wird zwischen dem \uparrow Bilanzkreisverantwortlicher und dem \uparrow Bilanzkreiskoordinator vertraglich vereinbart.

Bilanzkreiskoordinator Der \sim verwaltet die Bilanzierungsgebiete für die eigene \uparrow Regelzone. Die Rolle des \sim wird in Deutschland durch die \uparrow Uebertragungsnetzbetreiber wahrgenommen.

Bilanzkreisverantwortlicher Ein \sim ist gegenüber dem \uparrow Bilanzkreiskoordinator für die Ausgeglichenheit der Leistungsbilanz eines \uparrow Bilanzkreises in ökonomischer und administrativer Hinsicht verantwortlich.

Biogasanlage Eine \sim produziert aus Biomasse durch Vergärung Biogas. Dieses kann im Weiteren durch BHKW in elektrische und thermische \uparrow Energie umgewandelt werden.

Blindleistung \sim ist der Teil der \uparrow Scheinleistung, der zum Aufbau von magnetischen (z.B. in Motoren und \uparrow Transformator) oder elektrischen Feldern (z.B. Kondensatoren) benötigt wird und nicht zur nutzbaren \uparrow Arbeit beiträgt. Bei überwiegend magnetischem Feld ist die \sim induktiv, bei überwiegend elektrischem Feld kapazitiv. Es gibt blindleistungsliefernde und -beziehende Verbraucher und Erzeuger. In manchen Bereichen des elektrischen Netzes hat die \sim erheblichen Einfluss auf die Spannung.

Blindleistungskompensation Bei der \sim wird die Phasenverschiebung von Spannung und Strom reduziert, so dass in Stromnetzen die zu übertragende \uparrow Scheinleistung verringert und die vorhandenen Leitungskapazitäten besser ausgenutzt werden können. Kompensationen können kapazitiv oder induktiv vorgenommen werden.

Blockheizkraftwerk Ein \sim ist eine \uparrow Anlage, die einen \uparrow Primärenergieträger wie etwa Erdgas mit Hilfe eines Verbrennungsmotors, einer \uparrow Brennstoffzelle oder einer kleinen Gasturbine direkt oder über mechanische \uparrow Energie in elektrische \uparrow Energie wandelt. Die dabei entstehende Wärme kann zur Erhöhung des primärenergetischen Wirkungsgrades für die lokale Wärmeversorgung genutzt werden.

Brennstoffzelle Eine \sim ist eine batterieähnlich aufgebaute \uparrow Anlage, die einen zugeführten Brennstoff und ein Oxidationsmittel auf der Grundlage einer chemischen Reaktion in elektrische \uparrow Energie und das entsprechende Oxidationsprodukt wandelt.

Einheit Eine \sim (engl.: unit) bezeichnet eine technische Komponente, die über einen \uparrow Netzknoten mit dem elektrischen Versorgungsnetz verbunden ist und Einfluss auf Strom und Spannung im Stromnetz nehmen kann. Wenn die \sim über eine informationstechnische Verbindung verfügt, kann sie über einen Einheiten-Agenten nach außen repräsentiert werden.

Einheiten-Agent Ein \sim (engl.: unit-agent) ist ein \uparrow Agent, welcher physisch auf einem eingebetteten System oder einer externen Recheneinheit betrieben wird und über eine IKT-Verbindung mit anderen \uparrow Agent Nachrichten austauschen kann.

Einsatzplan Ein \sim ordnet den \uparrow Einheit einer \uparrow Koalitionen einen jeweils für einen bestimmten Zeitraum gültigen \uparrow Fahrplan zu.

elektrische Leistung Die \sim im physikalischen Sinne als Produkt von Strom und Spannung ist ein Momentanwert. Bei Angabe von Momentanwerten ist der Zeitpunkt anzugeben. In der Elektrizitätswirtschaft werden neben Momentanwerten auch mittlere Leistungen für definierte Zeitspannen verwendet. Leistung ist dann der Quotient aus in einer Zeitspanne geleisteten \uparrow Arbeit W und derselben Zeitspanne T : $P = W/T$.

elektrisches Energieversorgungsnetz Ein \sim auch Stromnetz, ist ein Netzwerk aus Entnahme- und Einspeisestellen, die über Stromleitungen in verschiedenen Spannungsebenen miteinander verbunden sind. Das \sim dient der Versorgung von Endverbrauchern mit elektrischer \uparrow Energie.

Energie Als \sim bezeichnet man die in einem System oder Körper gespeicherte \uparrow Arbeit sowie das Vermögen, \uparrow Arbeit zu verrichten oder Wärme abzugeben. Elektrische Energie ist das Integral der \uparrow elektrische Leistung über ein Zeitintervall.

Energiemanagement Das \sim bezeichnet die vorausschauende, organisierte und systematisierte Koordinierung von Beschaffung, Wandlung, Verteilung und Nutzung von \uparrow Energie zur Deckung der Anforderungen unter Berücksichtigung ökologischer, ökonomischer und sicherheitsbezogener Zielsetzungen.

Erneuerbare Energien Unter \sim werden \uparrow Energieträger verstanden, die praktisch unbegrenzt zur Verfügung stehen (solare Einstrahlung, Wind und Erdwärme) bzw. durch biologische Prozesse in anderer Form verfügbar gemacht werden können (\uparrow Biomasse).

EEG Das Erneuerbare-Energien-Gesetz (\sim) regelt den vorrangigen Anschluss von \uparrow Anlage zur Erzeugung von Strom aus \uparrow Erneuerbaren Energien und aus Grubengas im Bundesgebiet einschließlich der deutschen ausschließlichen Wirtschaftszone an die Netze für die allgemeine Versorgung mit Elektrizität, die vorrangige Abnahme, Übertragung, Verteilung und Vergütung dieses Stroms durch die \uparrow Netzbetreiber einschließlich des Verhältnisses zu Strom aus KWK (Kraft-Wärme-Kopplung) sowie einschließlich Prämien für die Integration dieses Stroms in das Elektrizitätsversorgungssystem sowie den bundesweiten Ausgleich des abgenommenen Stroms, für den eine Vergütung oder eine Prämie gezahlt worden ist.

Fahrplan Ein \sim legt für einen in Intervalle unterteilten Zeitraum die mittlere Leistungsabgabe oder -aufnahme einer \uparrow Einheit fest.

Frequenzhaltung Die \sim ist eine \uparrow Systemdienstleistung und bezeichnet die Ausregelung von Frequenzabweichungen infolge von Ungleichgewichten zwischen Einspeisung und Entnahme (Wirkleistungsregelung) und erfolgt im europäischen Verbundnetz durch Primär- und Sekundärregelung sowie \uparrow MRL.

Kapazitätsmarkt Ein \sim ist eine konkrete Umsetzung von Kapazitätsmechanismen im Strommarkt, die zum Ziel haben Investitionen in Kraftwerke zu befördern, um langfristig dem \uparrow missing-money-problem zu begegnen. Ein \sim stellt eine Ergänzung zu den auf Energiehandel beschränkten Märkten im europäischen Raum dar.

Koalition Eine \sim ist eine organisatorische Aggregation von \uparrow Einheiten-Agent mit dem Ziel, ein \uparrow Produkt bereitzustellen und damit einen Mehrwert zu erwirtschaften.

Kraft-Wärme-Kopplung Mit \sim wird eine Methode bezeichnet, bei der durch Wandlung eines \uparrow Primärenergieträgers sowohl elektrische als auch thermische \uparrow Energie für eine weitere Nutzung verfügbar gemacht wird. Typische \uparrow Anlage auf Grundlage der \sim sind \uparrow BhkW oder \uparrow Brennstoffzelle.

KWK-Anlage Eine \sim ist eine \uparrow Anlage auf Basis der \uparrow KWK-Technologie. \sim variieren in ihrer Größe von Kleinstanlagen zur Haushaltswärmeversorgung hin zu Großanlagen zur Fernwärmeversorgung.

Lastprofil Ein \sim gibt den Verlauf des elektrischen oder thermischen Verbrauchs einer \uparrow Einheit innerhalb eines definierten Zeitraumes an. Für bestimmte Verbrauchergruppen gibt es sogenannte Standardlastprofile, die einen repräsentativen Verbrauch dieser Gruppen darstellen.

Markt Ein elektronischer \sim ist eine informationstechnische Organisationsform, die im Allgemeinen einen Handel zwischen unterschiedlichen Akteuren ermöglicht. In Abhängigkeit der konkreten Ausgestaltung des \sim kann etwa ein Koordinator eingesetzt werden, um Angebot und Nachfrage zu vermitteln und preisoptimal aufeinander abzubilden.

Market Clearing Preis (MCP) Der \sim ist der Preis, zu dem beim Auktionshandel an einer Börse der Ausgleich zwischen Angebot und Nachfrage erfolgt. Dieser Preis wird kurz auch als Marktpreis bezeichnet.

Merit-Order Die \sim stellt die preislich sortierte Reihenfolge von Geboten auf einem Energiemarkt dar.

- Merit-Order-Effekt** Mit \sim werden die Auswirkungen der Stromerzeugung aus Erneuerbaren Energien auf die Strompreise bezeichnet. Da die Teilnahme entsprechender \uparrow Einheit eine Verschiebung der Merit-Order-Kurve bewirkt, werden die Einnahmen von Stromerzeugern und damit die Kosten von Stromverbrauchern reduziert. Durch diesen preisdämpfenden Effekt kommt es unter anderem zu dem \uparrow Missing-Money-Problem.
- Missing-Money-Problem** Das \sim beschreibt die finanziellen Auswirkungen der sinkenden Energy-Only Marktpreise. Die sinkenden Marktpreise, sorgen dafür, dass Kraftwerksprojekte nicht mehr durch Geschäftsmodelle abbildbar sind. In Deutschland baut auf dieser Problematik die Diskussion rund um Kapazitätsmärkte auf.
- Minutenregelleistung** \sim (auch Minutenreserve oder Tertiärreserve) ist \uparrow Regelleistung, die die zuvor aktivierte \uparrow Sekundärreserve ablöst, so dass diese für einen neuen Abruf zur Verfügung steht. Die \sim muss innerhalb von 15 Minuten nach Anforderung durch den \uparrow Uebertragungsnetzbetreiber aktiviert oder deaktiviert sein. (Siehe auch \uparrow Praequalifikation).
- Monopson** Ein \sim beschreibt eine Marktform, in der nur ein Nachfrager vielen Anbietern gegenübersteht. Ein häufig gebrauchtes Synonym ist das Nachfragemonopol.
- n-1-Prinzip** Das \sim stellt sicher, dass bei Ausfall eines Betriebsmittels des \uparrow elektrisches Energieversorgungsnetz die Versorgungssicherheit weiter gewährleistet ist.
- Netzbetreiber** Ein \sim ist für den sicheren und zuverlässigen Betrieb, d.h. Netzführung und Netzbereitstellung, eines \uparrow elektrisches Energieversorgungsnetz in einem bestimmten Gebiet verantwortlich. Entsprechend der betriebenen Spannungsebene wird grundsätzlich zwischen \uparrow Uebertragungsnetzbetreiber und \uparrow Verteilnetzbetreiber unterschieden.
- Präqualifikation** Eine \sim beschreibt einen technischen Prüfungsprozess, den sich eine \uparrow Einheit unterziehen muss, um an einem \uparrow Markt zugelassen zu werden. Dabei werden technische Mindeststandards gefordert, die sicherstellen, dass die \uparrow Einheit in der Lage ist die Systemdienstleistungen zu erbringen.
- Photovoltaik** \sim (PV) bezeichnet den direkten Umwandlungsprozess von solarer Strahlungsenergie in elektrische \uparrow Energie mittels Solarzellen (photovoltaische Zellen).
- Primärenergieträger** Ein \sim ist ein natürlich vorkommendes Medium, dessen gespeicherte \uparrow Energie in nutzbare \uparrow Energie gewandelt werden kann.
- Primärregelleistung** \sim (PRL) ist \uparrow Regelleistung, die innerhalb von 30 Sekunden nach einem Störfall aktiviert sein muss und automatisch durch Kraftwerke bereitgestellt wird, die für diesen Zweck einen Anteil ihrer Erzeugungsleistung als Reserve vorhalten. Die \sim hat zum Ziel Änderungen der Netzfrequenz entgegen zu wirken (keine Rückführung auf den Sollwert).
- Produkt** Ein \sim repräsentiert im Kontext der Elektrizitätswirtschaft ein \uparrow Wirkleistungs-, \uparrow Systemdienstleistungs- oder \uparrow Regelleistungsprodukt.
- Produkt Handelszeitraum** Ein \sim ist der Zeitraum, in dem ein \uparrow Produkt gehandelt wird oder beschrieben ist.
- Produktlieferzeitraum** Ein \sim beschreibt den Zeitraum, über den ein \uparrow Produkt entsprechend zuvor vereinbarter Bedingungen erbracht werden muss.

PV-Anlage Eine ~ ist eine ↑anlage auf Basis der ↑Photovoltaik.

Re-Dispatch Bei einem ~ nehmen ↑Netzbetreiber Einfluss auf ↑Einheit (historisch: lediglich Kraftwerksleistungen) mit dem Ziel Netzengpässe aufzulösen.

Regelenergie Die ~ bezeichnet die Energiemenge, welche durch Aktivierung von ↑Regelleistung abgerufen wurde.

Regelleistung ~ ist für den Abruf vorgehaltene Leistung für die Frequenzregelung im ↑elektrisches Energieversorgungsnetz. Im Fall einer Unterspeisung des ↑elektrisches Energieversorgungsnetzes erfolgt ein Abruf von positiver Regelleistung in Form von Leistungssteigerungen von Erzeugungseinheiten oder Leistungssenkungen von Verbrauchseinheiten. Im Fall einer Überspeisung erfolgt der Abruf von negativer Regelleistung analog. Darüber hinaus wird ~ zeitlich gestaffelt eingesetzt (siehe ↑Primärregelleistung, ↑Sekundärregelleistung, ↑Minutenreserveleistung).

Regelleistungsprodukt Ein ~ dient der marktbasierter Umsetzung der Frequenzhaltung über Regelleistung. Gebote enthalten einen Leistungs- und Arbeitspreis für die getrennte Vergütung von vorzuhaltender Regelleistung bzw. gelieferter Regelenergie.

Regelzone Eine ~ ist ein geografisch abgegrenzter Raum, in dem einem ↑Uebertragungsnetzbetreiber der zuverlässige Betrieb seines ↑Uebertragungsnetzes obliegt.

Scheinleistung ~ ist die Gesamtleistung, die einem elektrischen Verbraucher zugeführt wird. Sie setzt sich zusammen aus ↑Wirkleistung und ↑Blindleistung.

Sekundärregelleistung Die ~ (oder auch Sekundärreserve) ist ↑Regelleistung, die unmittelbar nach einem Störfall durch den zuständigen ↑Uebertragungsnetzbetreiber automatisch aktiviert wird und innerhalb von fünf Minuten vollständig zur Verfügung stehen muss. Die ~ löst die ↑Primärregelleistung ab und hat zum Ziel, die Netzfrequenz wieder auf ihren Sollwert zurückzuführen.

Skalierbarkeit ~ bezeichnet die Eigenschaft eines Systems, bei Erweiterung seiner Ressourcen einen im Idealfall linearen Leistungsanstieg bereitzustellen.

Smart Grid Ein ~ repräsentiert ein ↑elektrisches Energieversorgungsnetz, dessen Komponenten auf intelligente Weise, d.h. mittels Informations- und Kommunikationstechnologie miteinander vernetzt sind, um eine energie- und kosteneffiziente sowie sichere und zuverlässige Versorgung zu gewährleisten.

Spannungshaltung Die ~ ist als ↑Systemdienstleistung eine Aufgabe der Netzbetreiber. Ziel ist es, die lokale Spannung innerhalb definierter Grenzen (sogenannte Spannungsbänder) zu halten. Die ~ kann über Wirk- oder Blindleistungseinspeisung gesteuert werden.

Spannungsebene Der Transport und die Verteilung von elektrischer Energie findet über verschiedene ~ statt. Für den Transport elektrischer Energie über längere Strecken werden hohe Spannungen genutzt, da so Leitungsverluste verringert werden können. Für die Verteilung und Nutzung beim Endverbraucher werden hingegen niedrigere Spannungen verwendet.

Strommarkt siehe ↑Markt

Stromnetz siehe ↑elektrisches Energieversorgungsnetz

- Supply-Demand-Matching** \sim ist ein Ansatz zur Koordination dezentraler \uparrow Einheit, der auf einen optimalen, netztopologisch lokalen Ausgleich von Erzeugung und Verbrauch von elektrischer \uparrow Energie abzielt.
- Transformator** Ein \sim ist ein Betriebsmittel der \uparrow elektrische Energieversorgung, das die Transformation von Spannungen zwischen verschiedenen Spannungsebenen erlaubt.
- Übertragungsnetz** Ein \sim ist ein Teil des \uparrow elektrisches Energieversorgungsnetz und dient der verlustarmen Übertragung elektrischer \uparrow Energie über große Distanzen.
- Übertragungsnetzbetreiber** Ein \sim ist ein \uparrow Netzbetreiber eines \uparrow Übertragungsnetzes, der zusätzlich zum Netzbetrieb systemsichernde Aufgaben wahrnimmt.
- Versorgungsqualität** \sim ist ein Oberbegriff zur Bewertung der öffentlichen Energieversorgung, der die Begriffe Versorgungszuverlässigkeit, Spannungsqualität, operative Versorgungssicherheit und Servicequalität (mit Vertrags-, Abrechnungs- und Störungsmanagement) zusammenfasst.
- Versorgungszuverlässigkeit** \sim definiert die Fähigkeit eines elektrischen Systems, seine Versorgungsaufgaben unter vorgegebenen Bedingungen während einer bestimmten Zeitspanne zu erfüllen.
- Verteilnetz** Ein \sim ist ein Teil des \uparrow elektrischen Energieversorgungsnetzes und dient der lokalen Verteilung elektrischer Energie.
- Verteilnetzbetreiber** Ein \sim ist ein \uparrow Netzbetreiber, dessen Verantwortung sich auf seinen Teil des \uparrow Verteilnetzes beschränkt.
- Virtuelles Kraftwerk** Ein \sim ist eine informationstechnische sowie organisatorische Aggregation vornehmlich dezentraler \uparrow Einheiten geringerer Leistung. Dabei dient typischerweise ein zentrales \uparrow Energiemanagementsystem zur Planung, Steuerung und Überwachung des Anlagenverhaltens.
- Windenergieanlage** Eine \sim ist eine \uparrow Anlage, die die kinetische \uparrow Energie des Windes in elektrische \uparrow Energie wandelt.
- Wirkleistung** \sim ist im Gegensatz zur \uparrow Blindleistung der Teil der \uparrow Scheinleistung, der von elektrischen Verbrauchern nutzbar ist, d.h. in andere Energieformen umgewandelt werden kann.
- Wirkungsgrad** Der \sim einer Energiewandlungsanlage ist das Verhältnis zwischen abgegebener und zugeführter Leistung bzw. \uparrow Energie.
- Wirkleistungsprodukt** Ein \sim definiert für einen (ggf. in Intervalle unterteilten) Zeitraum die durchschnittliche \uparrow elektrische Leistung, die zu definierten Kosten nachgefragt oder angeboten wird. Die gehandelte Energiemenge ist durch Leistung mal Zeit definiert.
- Zuverlässigkeit** Die \sim einer \uparrow Einheit oder einer Menge von Einheiten trifft eine Aussage über die Wahrscheinlichkeit, mit der diese ein \uparrow Produkt erbringen kann.

Abkürzungen

BNetzA	Bundesnetzagentur
BOH	Begin Of Hour - Anfangsverteilstunde
CI	Computational Intelligence
COR	Korrelation
COT	Cut-Off-Time
CRISP	Cross-Industry Standard Process for Data
CV	cross validation - Kreuzvalidierung
d	day - Tag
DEA	Dezentrale Energieerzeugungsanlage
DW	douple weight - quadriert
EEX	European Energy Ex-Change (Leipzig)
ENTSO-E	European Network of Transmission System Operators for Electricity
EnWG	Energiewirtschaftsgesetz
FASMI	Fast Analysis of Shared Multidimensional Information
FI	Feature Importance - Merkmalsrelevanz
FSS	Feature Subset Selection - Merkmalsauswahl
GBT	Gradient Boosting Tree
GCT	Gate-Closure-Time
h	hour - Stunde
HoBa	Horizontaler Belastungsausgleich
HT	Hochtarif
Int-Max	Maximale Anzahl Überschreitungsintervalle (positiv)
Int-Min	Maximale Anzahl Überschreitungsintervalle (negativ)
KI	Künstliche Intelligenz
KNN	k-Nächste-Nachbarn
Lag	Verzögerungswert
MAD	mean absolute deviation - mittlere absolute Abweichung vom Mittelwert
MCP	Market Clearing Preis
ML	Maschinelles Lernen
mo	month - Monat
MRL	Minutenreserveleistung
MW	Megawatt
Neg	Negativ
NRV	Netzregelverbund
NT	Niedrigtarif
OLAP	Online Analytical Processing
OTC	Over-the-Counter
PCA	Principial Component Analysis
PHB	Phelix Base Preis
PL	Probability lower - Überschreitungswahrscheinlichkeit
PL4	PL4 vierstündliche Zeitscheibe
Pos	Positiv
pred-hor	Prognosehorizont
PRL	Primärregelleistung

PU	Probability upper - Defizitwahrscheinlichkeit
PU4	PU vierstündliche Zeitscheibe
PV	Photovoltaik
PVE	Erzeugung aus Photovoltaik
PVP	Prognose der PV-Erzeugung
RFT	Random Forest Tree
RL	Regelleistung
RSME	root mean squared error - Wurzel des mittleren quadrierten Fehlers
SRL	Sekundärregelleistung
StromNEV	Stromnetzentgelteverordnung
StromNZV	Stromnetzzugangsverordnung
SVM	Support Vector Machine
TBE	Toleranzbandfehler
TOD	time of day - Tageszeit
TSD.EUR	Tausend Euro
TSO	Transmission System Operator (ÜNB)
UENB	Uebertragungsnetzbetreiber
ÜNB	Übertragungsnetzbetreiber
VaR	Value at Risk
VNB	Verteilnetzbetreiber
VNL/VNetzlast	Vertikale Netzlast
WDF	Wahrscheinlichkeitsdichtefunktion
week	weekday - Wochentag
windE	Winderzeugung
windP	Windprognose

Abbildungen

1.1	Übersicht der Kapitel	7
2.1	Geographische Lage der Regelzonen und deren Betreiber in Deutschland	10
2.2	Überblick Begriffsfeld Versorgungssicherheit	11
2.3	Verfahren zur Berechnung des Regelbedarfs	12
2.4	Rückführung der Netzfrequenz bei Kraftwerksausfall	14
2.5	Regelleistungsarten und ihre Einflussfaktoren	16
2.6	Zeitliche Einordnung der Strommarktprodukte	19
2.7	Fahrplansprünge	20
2.8	Verlauf der Preise für Viertelstundenprodukte am Intraday-Markt	22
2.9	Berechnung des Regelzonensaldos	22
2.10	Abruf von Regelleistung am Samstag, den 1.12.2012 im Netzregelverbund	24
2.11	Abruf von Regelleistung am Samstag, den 1.12.2012 in den Regelzonen	24
2.12	Beschriftung ohne Fußnote	28
2.13	Datenaufbereitung als Panel-Daten	30
2.14	Menge und Anzahl Aktivierungen von Minutenreserve	33
2.15	Minutenreserve in den Regelzonen in den Jahren 2004 bis 2013	33
2.16	Abruf von Minutenreserve im Jahr 2012	34
2.17	Analyse des Februar 2012 - RL-Bedarf und EEX-Preis	35
2.18	Menge und Anzahl Aktivierungen von Sekundär- und Tertiärregelleistung	36
2.19	Häufigkeitsverteilung des Regelsaldos im Netzregelverbund	38
2.20	Häufigkeitsverteilung des Regelsaldos in den Regelzonen im Jahr 2012	39
2.21	Monatliche Verteilung des Regelzonensaldos im Netzregelverbund	40
2.22	Stündliche Verteilung des Regelsaldos im NRV im Jahr 2012	40
2.23	Stündliche Verteilung des Regelsaldos im NRV im Jahr 2013	41
2.24	Verteilung des Regelsaldos im NRV im Dezember 2012	41
2.25	Stündliche Mittelwerte des Regelzonensaldos	42
2.26	Stündlicher MAD des Regelsaldos und stündlicher Abruf von MRL	42
2.27	Regelsaldo im NRV in den Auktionszeitscheiben im Jahr 2012	43
2.28	Regelsaldo im NRV in den Auktionszeitscheiben im Jahr 2013	44
2.29	Berechnung des Hurst Exponenten für den NRV in 2012	46
2.30	Autokorrelation des Regelsaldo im Netzregelverbund	46
2.31	Mittlere Wind- und PV-Einspeisung im NRV 2012	48
2.32	Korrelation der Wind- und der PV-Einspeisung mit dem Regelsaldo	48
2.33	MAD des Regelsaldos im NRV in 2012	49
2.34	MAD des Regelsaldos im NRV in 2012	50
2.35	Korrelation des PHB und der vertikalen Netzlast mit dem Regelsaldo	50
2.36	Korrelation der Windeinspeisung mit der vertikalen Netzlast	51

2.37	Vorgehen zur Regelleistungsbemessung nach Graf/Haubrich	54
2.38	Berechnung der Gesamtwahrscheinlichkeitsverteilung ²	57
2.39	Prognosemodelle	63
3.1	Deduktive und Induktive Prognosemodelle	66
3.2	Prognosemodelle in Hinblick auf ihre Komplexität	68
3.3	KNN mit unterschiedlichen Kernfunktionen	70
3.4	Entscheidungsbaum für die Regression	71
3.5	Beispiel Gradient Boosting Tree	74
3.6	Vorgehensmodell für das Maschinelle Lernen	76
3.7	Vorgehen bei der Suche nach ähnlichen Systemzuständen	78
3.8	Euklidisches Distanzmass und Mahalanobis Distanz	81
3.9	Distanzmaß und Merkmalsgewichtung	82
3.10	Saisonale und regionale Relevanz der Merkmale	85
3.11	Wechselwirkung zwischen der Netzlast und dem Windfehler auf den Saldo	86
3.12	Partielle Abhängigkeit des Regelzonensaldos	87
3.13	Transformation auf die zwei Hauptachsen mit PCA aus SKLearn	88
3.14	Merkmalsauswahl	89
3.15	Zusammenhang zwischen Unsicherheit und Information [Kne04]	91
3.16	Verteilung der Residuen für KNN-500 im NRV 02/2012 und 04/2012	93
3.17	Toleranzbandfehler	94
3.18	Berechnung der minimalen DTW-Distanz	95
3.19	Berechnung des Keogh-Bandes	96
3.20	Programmablauf	99
4.1	Parameterfestlegung für einen Simulationsfall SIM-CASE für die Evaluation	104
4.2	Beispiel Simulationscase	105
4.3	Beispielergebnisse für KNN-100 mit 7 Merkmalen und 3 Trainingsmonaten	107
4.4	MAD des Saldos und der Vertikalen Netzlast bzw. des PV-Fehlers	108
4.5	Partielle Abhängigkeit des Regelsaldos von den Prognosefehlern (NRV)	109
4.6	Änderung der Merkmalsauswahl: Ergebnisse für KNN-100 mit 11 Merkmalen und 3 Trainingsmonaten	109
4.7	Änderung der Trainingsmonate: Ergebnisse für KNN-100 mit 7 Merkmalen und 12 Trainingsmonaten	110
4.8	Änderung der Anzahl Nachbarn: Ergebnisse für den 01.03.2012 für KNN mit 7 Merkmalen und unterschiedlicher Anzahl Nachbarn (100,200,500)	111
4.9	Nachbarn bei KNN-100 mit 10 Merkmalen ohne Korrelation	113
4.10	Änderung der Merkmalsgewichtung: Ergebnisse für KNN-100 mit 7 Merkmalen und 3 Trainingsmonaten sowie unterschiedlichen Merkmalsgewichtungen	114
4.11	Änderung der Merkmalsvorverarbeitung: Ergebnisse für KNN-100 mit 10 Merkmalen mit/ohne Korrelation und 3/12 Trainingsmonaten	115

4.12	Ergebnisse für KNN-100 mit 6 Merkmalen mit/ohne Korrelation und 12 Trainingsmonaten	116
4.13	Änderung der Merkmalsauswahl: Ergebnisse für KNN-100 mit 8 Merkmalen ohne Berücksichtigung des EE-Fehlers und 3/12 Trainingsmonaten	117
4.14	Änderung der Merkmalsgenerierung: Ergebnisse für KNN-100 mit 6 Merkmalen und Lag[0,1] und 3/12 Trainingsmonaten	118
4.15	Änderung des Prognosehorizonts: Ergebnisse für KNN-100 mit 7 Merkmalen und 11 Trainingsmonaten	118
4.16	Beispielsergebnisse für GBT mit $\alpha = 0.99$ mit 7 Merkmalen und 3 Trainingsmonaten	119
4.17	Änderung der Merkmalsauswahl: Ergebnisse für GBT mit $\alpha = 0.99$ mit 11 Merkmalen und 3 Trainingsmonaten	119
4.18	Änderung der Trainingsmonate: Ergebnisse für GBT mit $\alpha = 0.99$ mit 7 Merkmalen und 12 Trainingsmonaten	120
4.19	Änderung der Parametereinstellung: Ergebnisse für GBT mit 7 Merkmalen, 3/12 Trainingsmonaten und unterschiedlicher Werte α (0,99;0,9975;0,9999)	121
4.20	Änderung der Merkmalsvorverarbeitung: Ergebnisse für GBT-0.99 mit 10 Merkmalen mit/ohne Korrelation und 3/12 Trainingsmonaten	122
4.21	Änderung der Merkmalsauswahl: Ergebnisse für GBT-0.99 mit 8 Merkmalen ohne Berücksichtigung des Prognosefehlers	123
4.22	RMSE für den NRV 2012 und 2013 1-Day-Ahead	123
4.23	Feature Importance im Jahr 2012 Winter-Sommer im Vergleich	124
4.24	Verteilung der Residuen für KNN-500 im NRV 01/2013 und 08/2013	125
4.25	RMSE für den NRV in 2012 und 2013 1-Hour-Ahead-Prognose	125
4.26	Ergebnis der Sicherheitsniveaus für das Jahr 2012 mit 1-h-Blöcken	126
4.27	Ergebnis der Sicherheitsniveaus für das Jahr 2013 mit 1-h-Blöcken	127
4.28	Sicherheitsniveaus für das Jahr 2013 mit 1-h-Blöcken	128
4.29	Sicherheitsniveaus für das Jahr 2013 mit 1h/4h-Blöcken	129
4.30	Sicherheitsniveaus für das Jahr 2013 mit 4h-Blöcken ohne Kenntnis des EE-Fehlers .	130
4.31	Anpassung an die 1h/4h Blöcke aus den Ergebnissen der KNN	131
4.32	Anpassung an die 1h/4h Blöcke für die Werte aus den GBT	133
4.33	Einsparungspotentiale für das Jahr 2013 für 4 Stunden Blöcke	134
4.34	Preise MRL	135
4.35	Einsparungspotentiale für das Jahr 2013 für 1 Stunden Blöcke	137
4.36	Ergebnis der Einsparungspotentiale für das Jahr 2013 DESIRE[BET2014]	139
4.37	Tatsächlich realisierte Potentiale 2013 in verschiedenen Zeitblöcken	141
4.38	Leistungspreis für Minutenreserve nach Monaten und Uhrzeiten	141
4.39	Ergebnisse für 50 Hertz im Februar 2012 - Vergleich 10/100 Nachbarn	144
4.40	Ergebnisse für 50 Hertz im Juli 2012 - Vergleich KNN_GBT mit GBT	145
4.41	Beispieltag Dienstag, der 01.07.2012 in der Regelzone 50 Hertz	145
4.42	Partielle Abhängigkeit zwischen dem Regelzonensaldo und dem Windfehler im Winter 2013	146
4.43	RMSE der einzelnen Methoden für 50 Hertz in den Jahren 2012 und 2013	146

4.44	Verteilung des Regelzonensaldos für 50 Hertz jeweils im Januar in den Jahren 2012 und 2013	147
4.45	Relative Merkmalsrelevanz für 50 Hertz jeweils im Januar in den Jahren 2012 und 2013	147
4.46	Ergebnisse für Amprion im Juli 2013 - Vergleich KNN_100 / GBT_0.99	148
4.47	RMSE der einzelnen Methoden für Amprion in den Jahren 2012 und 2013	148
4.48	Relative Merkmalsrelevanz für Amprion im Januar 2012 und im Juli 2013	149
4.49	Partielle Abhängigkeit zwischen dem Regelzonensaldo und der vertikalen Netzlast in der Amprion Regelzone im Winter 2013	149
4.50	Ergebnisse für Tennet im Januar/Juni 2012 - Vergleich KNN-GBT mit GBT	150
4.51	RMSE der einzelnen Methoden für Tennet in den Jahren 2012 und 2013	151
4.52	Partielle Abhängigkeit des Regelsaldos von dem Windfehler und der Netzlast in der Tennet Zone im Vergleich Sommer - Winter 2012	151
4.53	Ergebnisse für den GBT in der Regelzone TransnetBW im Jahr 2012 Winter-Sommer-Vergleich	152
4.54	Merkmalsrelevanz im Bereich der Regelzone TransnetBW im Winter Sommer 2012 im Vergleich	152
4.55	Partielle Abhängigkeit des Regelzonensaldos von der vertikalen Netzlast und dem PV-Fehler in der Regelzone von TransnetBW	153
4.56	Mittlerer Fehler (RMSE) im Bereich der Regelzone TransnetBW in den Jahren 2012 und 2013	153
5.1	Prozessverlauf Erstellung flexibles Prognosemodell	157

Literatur

- [AGN] ABBASIFARD, Mohammad R. ; GHAREMANI, Bijan ; NADERI, Hassan: A Survey on Nearest Neighbor Search Methods. <http://research.ijcaonline.org/volume95/number25/pxc3897073.pdf>. In: *International Journal of Computer Applications* Bd. 95, 39–52
- [Alp08] ALPAYDIN, Ethem: *Maschinelles Lernen*. München : Oldenbourg, 2008. – ISBN 3486581147
- [And10] ANDREW C. HARVEY AND VITALIY ORYSHCHENKO: *Kernel density estimation for time series data*. <http://www.econ.cam.ac.uk/people/faculty/ach34/pubs10/TVDahvo9.pdf.pagespeed.ce.AhI2Uj0wII.pdf>. Version: 17.02.2010
- [BBLB11] BROWN, Matthew ; BARRINGTON-LEIGH, Chris ; BROWN, Zosia: *Kernel Regression for Real-Time Building Energy Analysis*. http://www.cs.bath.ac.uk/brown/papers/jbps2011_preprint.pdf. Version: 30.09.2011
- [Bac11] BACKHAUS, Klaus: *Multivariate Analysemethoden*. 13. Berlin : Springer-Verlag, 2011 <http://link.springer.com/book/10.1007/978-3-662-08893-7>. – ISBN 3642164919
- [bde12] BDEW: *Smart Grids – auf dem Weg zu einem zukunftsfähigen Markt- und Regulierungsdesign: Diskussionspapier*. [http://www.bdew.de/internet.nsf/id/18D2FD039FC0004CC1257880003D4F22/\\$file/2011-03-22%20Langfassung%20Smart%20Grids%20clean.pdf](http://www.bdew.de/internet.nsf/id/18D2FD039FC0004CC1257880003D4F22/$file/2011-03-22%20Langfassung%20Smart%20Grids%20clean.pdf). Version: 24.03.2012
- [Bel61] BELLMAN, Richard E.: *Adaptive Control Processes*. 5. s.l : Princeton University Press, 1961
- [Ber08] BERK, Richard A.: *Statistical Learning from a Regression Perspective*. 1. s.l : Springer-Verlag, 2008 http://ebooks.ciando.com/book/index.cfm/bok_id/27947. – ISBN 0387775005
- [BGr99] BEYER, K. ; GOLDSTEIN, J. ; RAMAKRISHNAN, U.: When is Nearest Neighbor Meaningful. In: *7th International Conference, Jerusalem, Israel, January 10-12, 1999 : proceedings* Bd. 1540
- [Bis06] BISHOP, Christopher M.: *Pattern recognition and machine learning*. New York : Springer, ©2006 (Information science and statistics). – ISBN 9780387310732
- [BK96] BORGELT, Christian; KRUSE, Rudolf : *Attributauswahlmaße für die Induktion von Entscheidungsbäumen; Eine Einführung*. http://www.borgelt.net/papers/mldmd_96.pdf – Universität Magdeburg : 1996.
- [Bre93] BREIMAN, Leo: *Classification and regression trees*. New York : Chapman & Hall, 1993. – ISBN 0-412-04841-8
- [Bre11] BREYER, Friedrich: *Mikroökonomik: Eine Einführung*. 5., verb. Aufl. Berlin : Springer, 2011 (Springer-Lehrbuch). – ISBN 978-3642115998

- [Bro77] BROCKHOFF, Klaus: *Die Wirtschaftswissenschaften*. Bd. Bd. 1: *Prognoseverfahren für die Unternehmensplanung*. Wiesbaden : Gabler, 1977. – ISBN 978–3409680141
- [Brü08] BRÜCKL, Oliver: *Wahrscheinlichkeitstheoretische Bestimmung des Regel- und Reserveleistungsbedarfs in der Elektrizitätswirtschaft: Dissertation*. <http://d-nb.info/991830261/34>. Version: 04.12.2008
- [Buc14] BUCKSTEEG, Michael: *DESIRE Endbericht*. http://www.bet-aachen.de/fileadmin/redaktion/PDF/Studien_und_Gutachten/DESIRE_Endbericht__141024_FINAL_Lang.pdf
- [Bun12] BUNDESMINISTERIUM FÜR WIRTSCHAFT UND TECHNOLOGIE: *Ein Strommarkt für die Energiewende*. <http://www.bmwi.de/BMWi/Redaktion/PDF/G/gruenbuch-gesamt,property=pdf,bereich=bmwi2012,sprache=de,rwb=true.pdf>
- [Bun10] BUNDESNETZAGENTUR: *BK8-09-003: Verwaltungsverfahren wegen der Festlegung einer wirksamen Verfahrensregulierung bezüglich eines verbindlichen Anzeizsystems für Systemdienstleistungen*. http://www.bundesnetzagentur.de/DE/DieBundesnetzagentur/Beschlusskammern/1BK-Geschaeftszeichen-Datenbank/BK8-GZ/2009/2009_001bis100/BK8-09-003_BKV/BK8-09-003_Ampron_SDL_Beschluss_mit_Anlagen.pdf?__blob=publicationFile. Version: 27.01.2010
- [Bun11] BUNDESNETZAGENTUR: *Smart Grid und Smart Market: Eckpunktepapier der Bundesnetzagentur zu den Aspekten des sich verändernden Energieversorgungssystems*. http://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/BNetza/Sachgebiete/Energie/Sonderthemen/SmartGridEckpunktepapier/SmartGridPapierpdf.pdf?__blob=publicationFile. Version: 20.12.2011
- [Bun14] BUNDESNETZAGENTUR: *Monitoringbericht 2013*. http://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2013/131217_Monitoringbericht2013.pdf?__blob=publicationFile&v=15. Version: 06.2014
- [Bur11] BURGER, Andreas et a.: *Zusammenschluss von dezentralen erzeugern zur netzregelung: Das Konzept des tertiärregelpoolings*. In: *Bulletin* (2011), Nr. 12, 12–15. http://www.bulletin-online.ch/uploads/media/1112_Seite_012-015.pdf
- [CH67] COVER, T. ; HART, P.: *Nearest neighbor pattern classification*. In: *Information Theory, IEEE Transactions* Bd. 13/1967
- [Cha00] CHAPMAN, Pete ; SPSS (Hrsg.): *CRISP-DM 1.0 Step-by-step data mining guide*. <http://www.the-modeling-agency.com/crisp-dm.pdf>. Version: 2000

- [Che14] CHEN, Tianqi: *Introduction to Boosted Trees*. 23.10.2014
- [GL14] © GILLES LOUPPE, University of Liege Faculty of Applied S.: *Understanding Random Forests*. <http://www.montefiore.ulg.ac.be/~glouppe/pdf/phd-thesis.pdf>. Version: 09.07.2014
- [Con14a] CONSENTEC: *Beschreibung von Regelleistungskonzepten und Regelleistungsmarkt: Studie im Auftrag der deutschen Übertragungsnetzbetreiber*. http://www.consentec.de/wp-content/uploads/2014/08/Consentec_50Hertz_Regelleistungsmarkt_de_201402271.pdf
- [Con08] CONSENTEC: *Gutachten zur Höhe des Regelennergiebedarfs: im Auftrag der Bundesnetzagentur*. <http://www.bundesnetzagentur.de/cae/servlet/contentblob/102556/publicationFile/5861/Gutachten%20zur%20H%C3%B6he%20des%20Regelennergiebedarfes.pdf>. Version: 10.12.2008
- [Con10] CONSENTEC: *Gutachten zur Dimensionierung des Regelleistungsbedarfs unter dem NRV*. http://www.bundesnetzagentur.de/DE/DieBundesnetzagentur/Beschlusskammern/BK6/Sonstige%20Ver%20ffentlichungen/Regelennergiebedarf/Gutachten_zur_Hoehe_des_Regelennergiebedarfes_2010.pdf?__blob=publicationFile. Version: 17.12.2010
- [Con14b] CONSENTEC: *Beschreibung von Regelleistungskonzepten und Regelleistungsmarkt*. http://www.consentec.de/wp-content/uploads/2014/08/Consentec_50Hertz_Regelleistungsmarkt_de_201402271.pdf. Version: 2014
- [Coo71] COOK, S.: The complexity of theorem-proving procedures. In: *ACM Proceedings*, S. 151–158
- [Cor10] CORMEN, Thomas H.: *Algorithmen - eine Einführung*. 3., überarb. und erw. Aufl. München [u.a.] : Oldenbourg, 2010. – ISBN 9783486590029
- [Cr10] CONSENTEC ; R2B: *Voraussetzungen einer optimalen Integration erneuerbarer Energien in das Stromversorgungssystem*. <http://www.bmwi.de/BMWi/Redaktion/PDF/Publikationen/Studien/endbericht-optimale-intergration-erneuerbare-energie,property=pdf,bereich=bmwi,sprache=de,rwb=true.pdf>. Version: 07.07.2010
- [Cra12] CRASTAN, Valentin: *Elektrische Energieversorgung - Teil I: Netzelemente, Modellierung, stationäres Verhalten, Bemessung, Schalt- und Schutztechnik*. 3. Heidelberg and Germany : Springer, 2012
- [Cro10] CRONE, Sven F.: *Neuronale Netze zur Prognose und Disposition im Handel*. 1. Wiesbaden : Gabler, 2010. – ISBN 3834986313

- [CS93] COST, S. ; SALZBERG, S.: A Weighted Nearest Neighbor Algorithm for Learning with Symbolic Features. (1993). <http://www.cs.utsa.edu/~bylander/cs6243/cost93weighted.pdf>
- [CW12] CRASTAN, Valentin ; WESTERMANN, Dirk: *Elektrische Energieversorgung III: Dynamik, Regelung und Stabilität*. 3. Berlin [u.a.] : Springer, 2012. – ISBN 3642201008
- [Dan00] DANY, Gundolf: *Kraftwerksreserve in elektrischen Verbundsystemen mit hohem Windenergieanteil: Dissertation*. Print Production M. Wolff, 2000. – ISBN ISBN–10:3–934318–10–X
- [DEN10] DENA ; DENA (Hrsg.): *DENA Netzstudie II: Integration erneuerbarer Energien in die deutsche Stromversorgung im Zeitraum 2015 – 2020 mit Ausblick 2025*. http://www.dena.de/fileadmin/user_upload/Publikationen/Sonstiges/Dokumente/Endbericht_dena-Netzstudie_II.PDF. Version: 26.11.2010
- [Die02] DIETTERICH, Thomas: *Machine Learning for Sequential Data: A Review*. <http://web.engr.oregonstate.edu/~tgd/publications/mlsd-ssspr.pdf>. Version: 2002
- [Dix02] DIXON, Philip: *Nearest Neighbor Methods*. <http://www.stat.iastate.edu/preprint/articles/2001-19.pdf>. Version: 28.02.2002
- [DPG01] DOMENICONI, Carlotta ; PENG, Jing ; GUNOPULUS, Dimitrios: Locally adaptive metric nearest-neighbor classification - Pattern Analysis and Machine Intelligence, IEEE Transactions on. <http://cs.gmu.edu/~carlotta/publications/pami.pdf>. In: *IEEE Transactions on patterns analysis and machine intelligence* Bd. 24/9
- [Dra14] DRAFT: *Wiederholung Statistik*. <http://www.uibk.ac.at/econometrics/einf/app1.pdf>. Version: 2014
- [DSH00] DUDA, Richard O. ; STORK, David G. ; HART, Peter E.: *Pattern classification and scene analysis*. 2nd ed. New York and Chichester : Wiley, 2000. – ISBN 978–0471056690
- [Dud10] DUDEK, Grzegorz: *Similarity-based Approaches to Short-term Load Forecasting*. 18.03.2010
- [DVG97] DVG: *Zuverlässigkeit elektrischer Versorgungssysteme: Leistungsreserve im Verbundbetrieb*. Heidelberg, 1997
- [eco03] ECOPLAN: *Versorgungssicherheit im Bereich der Elektrizität - Vorstudie: im Auftrag des Bundesamtes für Energie BFE Schweiz*. <http://www.news.admin.ch/NSBSubscriber/message/attachments/947.pdf>. Version: 2003
- [EG04] ELISSEEFF, André ; GUYON, Isabelle: *An Introduction to Variable and Feature Selection*. http://machinelearning.wustl.edu/mlpapers/paper_files/GuyonE03.pdf. Version: 11.10.2004

- [EKT79] EDWIN, Kurt W. ; KOCHS, Hans-Dieter ; TRAEGER, Günter: *Untersuchung der Kraftwerkreserve im Verbundsystem*. Opladen [Germany] : Westdeutscher Verlag, 1979. – ISBN 9783531028163
- [EL06] E-BRIDGE CONSULTING GMBH ; LEHRSTUHL FÜR ENERGIESYSTEME UND ENERGIEWIRTSCHAFT: *Gutachten "Bestimmung des regelzoneninternen Regelleistungsbedarfs für Sekundärregelung und Minutenreserve"*. http://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/BNetzA/Sachgebiete/Energie/Konsultationen/ArchivKonsultationen/GutachtenRegelenergie/GutachtenregelzoneninternerRIId8224pdf.pdf?__blob=publicationFile. Version: September 2006
- [ELH08] ELITH, J. ; LEATHWICK, J. R. ; HASTIE, T.: A working guide to boosted regression trees. <http://dx.doi.org/10.1111/j.1365-2656.2008.01390.x>. In: *Journal of Animal Ecology* Bd. 77. – DOI 10.1111/j.1365-2656.2008.01390.x, 802–813
- [Ert09] ERTEL, Wolfgang: *Grundkurs künstliche Intelligenz: Eine praxisorientierte Einführung*. 2. Wiesbaden : Vieweg + Teubner, 2009 (Studium). – ISBN 3834807834
- [FNE10] FACHAUSSCHUSS "NACHHALTIGES ENERGIESYSTEM 2050": *Eine Vision für ein nachhaltiges Energiekonzept auf Basis von Energieeffizienz und 100% erneuerbaren Energien*. http://www.fvee.de/fileadmin/politik/10.06.vision_fuer_nachhaltiges_energiekonzept.pdf. Version: Juni 2010
- [FAC14] FILHO, Reston ; AFFONSO, Carolina ; CELIO L. DE OLIVEIRA: *Short-Term Energy Price Prediction Multi-Step-Ahead in the Brazilian Market Using Data Mining*. <http://www.intechopen.com/download/get/type/pdfs/id/39025>. Version: 23.01.2014
- [FK08] FEINDT, Michael ; KERZEL, Ulrich: *Prognosen bewerten: Statistische Grundlagen und praktische Tipps*. – ISBN 978-3662446829
- [FPSS96] FAYYAD, Usame ; PIETETSKY-SHAPIRO, Gregory ; SMYTH, Padhraic: From Data Mining to Knowledge Discovery in Databases. In: *AI Magazine* FALL (1996). <http://www.csd.uwo.ca/faculty/ling/cs435/fayyad.pdf>
- [FSM14] FUJIMOTO, Yu ; SUGIURA, Taiki ; MURATA, Noboru: *K-Nearest Neighbor Approach for Forecasting Energy Demands Based on Metric Learning: Poster auf der ITISE International Conference on Time Series Analysis*. <http://www.murata.elec.waseda.ac.jp/taiki.sugiura/slide/abstract.pdf>. Version: 18.06.2014
- [Geu06] GEURTS, Pierre: *Extremely randomized trees*. http://download.springer.com/static/pdf/156/art%253A10.1007%252Fs10994-006-6226-1.pdf?auth66=1417443302_6898b1e1dcea692739c843c483321b34&ext=.pdf. Version: 31.03.2006

- [GEW06] GEURTS, Pierre ; ERNST, Damien ; WEHENKEL, Louis: *Extremely randomized trees*. <http://dx.doi.org/10.1007/s10994-006-6226-1>. Version: 2006
- [GL15] GILLES LOUPPE, Louis Wehenkel Antonio Sutera Pierre G.: *Understanding variable importances in forests of randomized trees*.
- [GO11] GUTIERREZ-OSUNA: *Nearest Neighbors*. http://research.cs.tamu.edu/prism/lectures/pr/pr_l8.pdf. Version: 15.11.2011
- [GP10] GARCÍA-PEDRAJAS, Nicolás (Hrsg.): *Boosting k-Nearest Neighbor Classifier by Means of Input Space Projection*. Zürich : Verl. Neue Zürcher Zeitung, 2010. – ISBN 978-3-03-823649-8
- [Gra80] GRANGER, Richard : *When expextations fails. Toward a self-correcting inference system*. In: *AAAI-80*, 301–305
- [Gru05] GRUNERT, Harald: *Faktorenanalyse*. (2005). http://mws-bbg.com/Down/Script_b.pdf
- [Gue00] GUERRE, E.: *Design Adaptive Neares Neighbor Regression Estimation*. http://ac.els-cdn.com/S0047259X00919018/1-s2.0-S0047259X00919018-main.pdf?_tid=bbf9e598-ab9e-11e4-becc-00000aab0f27&acdnat=1422966077_fa324383d1d64c94cfc584efa66b59f6. In: *Journal of Multivariate Analysis* Bd. 75, 219–244
- [Hal99] HALL, Mark: *Correlation-based Feature Selection for Machine Learning*. <http://www.cs.waikato.ac.nz/~mhall/thesis.pdf>. Version: 1999
- [Har96] HARTMANN, Matthias: *DYNAPRO*. Bd. erfolgreich produzieren in turbulenten Märkten / Hrsg.: Matthias Hartmann ; Bd. 1: *Anforderungen und industrielle Lösungsansätze*. Stuttgart : LOGIS-Verl. für Wissenstransfer, 1996. – ISBN 3932298004
- [HatT14] 50HERTZ ; AMPRION ; TENNET ; TRANSNETBW: *Auswirkungen reduzierter Schwungmasse auf einen stabilen Netzbetrieb: Netzentwicklungsplan*. (2014). <http://www.netzentwicklungsplan.de/sites/default/files/attachments/Minimale%20Schwungmasse.pdf>
- [Her11] HERRMANN, Hauke: *Ökonomische Betrachtung der Speichermedien: Arbeitspaket im Forschungsvorhaben OPTUM*. <http://www.oeko.de/oekodoc/1339/2011-452-de.pdf>. Version: 2011
- [HJ08] HEUTERKES, Michael ; JANSSEN, Matthias ; WESTFÄLISCHE WILHELMS-UNIVERSITÄT MÜNSTER (Hrsg.): *Die Regulierung von Gas- und Strommärkten in Deutschland: Beiträge aus der angewandten Wirtschaftsforschung Nr. 29*. http://www.wiwi.uni-muenster.de/cawm/forschen/Download/Diskussionsbeitrag_nr29.pdf. Version: 2008
- [HLC07] HÄRDLE, Wolfgang ; LÜTKEPOHL, Helmut ; CHEN, Rong: *A Review of Nonparametric Time Series Analysis*. http://stat.rutgers.edu/home/rongchen/publications/97ISR_review.pdf. In: *International Statistical Review* Bd. 65/1999, 49–72

-
- [HMNP09] HAHN, Heiko ; MEYER-NIEBERG, Silja ; PICKL, Stefan: Electric load forecasting methods: Tools for decision making. <http://dx.doi.org/10.1016/j.ejor.2009.01.062>. In: *European Journal of Operational Research* Bd. 199. – DOI 10.1016/j.ejor.2009.01.062, 902–907
- [Höf04] HÖFT, Christoph: *Bewertung von Verfahren zur Prognose der elektrischen Last - eine empirische Analyse*. http://tu-dresden.de/die_tu_dresden/fakultaeten/fakultaet_wirtschaftswissenschaften/bwl/ee2/dateien/ordner_publicationen/wp_ge_03_hoeft_lastprognose_elektrizitaet_empirisch.pdf. Version: 2004
- [Hol04] HOLTINEN, Hannele: *The impact of large scale wind power production on the Nordic electricity system: Dissertation*. <http://lib.tkk.fi/Diss/2004/isbn9513864278/isbn9513864278.pdf>. Version: 2004
- [HS13] HEMACHANDRA, S. ; SATYANARAYANA, S.: Computational Intelligence for Prediction of Electrical Load. (2013). http://searchdl.org/public/book_series/AETS/7/568.pdf
- [HT04] HASTIE, Trevor ; TIBSHIRANI, Robert: Discriminant Adaptive Nearest Neighbor Classification - Pattern Analysis and Machine Intelligence, *IEEE Transactions on*. http://web.stanford.edu/~hastie/Papers/dann_IEEE.pdf. In: *IEEE Transactions on patterns analysis and machine intelligence* Bd. 18, 607–616
- [HTF11] HASTIE, Trevor J. ; TIBSHIRANI, Robert ; FRIEDMAN, Jerome: *The elements of statistical learning: Data mining, inference, and prediction*. 2nd ed. [corrected at 5th printing]. New York and N.Y : Springer, 2011 (Springer series in statistics). – ISBN 0387848584
- [HZ15] HIRTH, Lion ; ZIEGENHAGEN, Inka: Balancing power and variable renewables: Three links. In: *Renewable and Sustainable Energy Reviews* 50 (2015), S. 1035–1051
- [IEE04] IEEE: *A generalized knowledge-based short-term load-forecasting technique - Power Systems, IEEE Transactions on*. http://www.ceage.org/sites/default/files/ieee_pow1993_v8_no2_508-514.pdf. Version: 13.04.2004
- [KB11] KALE, Malhar ; BUTAR, Ferry: Fractal Analysis of Time Series and Distribution Properties of Hurst Exponent. In: *Journal of Mathematical Sciences and Mathematics Education* Bd. 5/1, S. 8–19
- [KD09] KÜHN ; DORMAN: Angewandte Statistik für die biologischen Wissenschaften. (2009). http://cran.r-project.org/doc/contrib/Dormann+Kuehn_AngewandteStatistik.pdf
- [Keo05] KEOGH, Eamonn: *Fast and Exact Warping of Time Series Using Adaptive Segmental Approximations*. <http://i.cs.hku.hk/~nikos/FastExactWarping.pdf>. Version: 27.01.2005

- [Kle13] KLEPPMANN, Wilhelm: *Versuchsplanung: Produkte und Prozesse optimieren*. 1. s.l : Carl Hanser Fachbuchverlag, 2013 http://ebooks.ciando.com/book/index.cfm/bok_id/902242. – ISBN 978–3446437524
- [Klo07] KLOBOSA, Marian: *Dynamische Simulation eines Lastmanagements und Integration von Windenergie in ein Elektrizitätsnetz auf Landesebene unter regelungstechnischen und Kostengesichtspunkten: Dissertation ETH Zürich*. 22.11.2007
- [KN06] KREISS, Jens-Peter ; NEUHAUS, Georg: *Einführung in die Zeitreihenanalyse*. Berlin, New York : Springer, 2006. – ISBN 3540335714
- [Kne04] KNETSCH, Thomas: *Unsicherheiten in Ingenieurberechnungen*. http://edoc.bibliothek.uni-halle.de/servlets/MCRFileNodeServlet/HALCoRe_derivate_00002885/thoknetsch.pdf. Version: 24.08.2004
- [Koc12] KOCKELKORN, Ulrich: *Statistik für Anwender*. Berlin Heidelberg : Springer Spektrum, 2012. – ISBN 3827422949
- [Kon09] KONSTANTIN, Panos: *Praxisbuch Energiewirtschaft: Energieumwandlung, -transport und -beschaffung im liberalisierten Markt*. 2. Berlin and Heidelberg : Springer, 2009. – ISBN 3540785922
- [KR05] KEOGH, Eamonn ; RATANAMAHATANA, Chotirat A.: *Exact indexing of dynamic time warping*. <http://dx.doi.org/10.1007/s10115-004-0154-9>. Version: 2005
- [Kra09] KRAMER, Oliver: *Computational intelligence: Eine Einführung*. Dordrecht, New York : Springer, 2009 (Informatik im fokus). – ISBN 3540797394
- [Kra10] KRAHL, Simon C.: *Berechnung der Wahrscheinlichkeitsverteilungen von Zuverlässigkeitskenngrößen in elektrischen Verteilungsnetzen*. 1. Aachen : Klinkenberg, 2010. – ISBN 3934318487
- [KS09] KAKADE, S. ; SHAKHAROVICH, G.: Locally Weighted Regression. (2009), Nr. CM-SC35900 Large Scale Learning. <http://ttic.uchicago.edu/~gregory/courses/LargeScaleLearning/lectures/lwr.pdf>
- [KS12] KIPPELT, Stefan ; SCHLÜTER, Thorsten ; IE3-INSTITUT FÜR ENERGIEWIRTSCHAFT, Energiesysteme und E. (Hrsg.): *Ausgestaltung eines adaptiven Regelleistungsmarktes mit Kapazitätsreserve*. 2012
- [KSWR10] KAYS, Jan ; SCHWIPPE, Johannes ; WANIEK, Daniel ; REHTANZ, Christian: *Multidimensionales Verfahren zur Bestimmung des Regelleistungsbedarfes unter Berücksichtigung von Unsicherheiten*. <http://dx.doi.org/10.1007/s12398-010-0031-z>. Version: 2010
- [Kun08] KUNST, Robert M.: *Ökonomische Zeitreihenanalyse - Teil 3*. <http://homepage.univie.ac.at/robert.kunst/ts3.pdf>. Version: 17.01.2008

- [Kur09] KURSCHEID, Eva M.: *Zur Bereitstellung positiver Minutenreserve durch dezentrale Klein-KWK-Anlagen: Dissertation.* http://www.qucosa.de/fileadmin/data/qucosa/documents/5912/data/Dissertation_Kurscheid.pdf. Version: 24.11.2009
- [Ley06] LEYDOLD, Josef: *Einfache Regression: Vorlesung - Universität Wien.* http://statmath.wu-wien.ac.at/courses/mmwi-finmath/Aufbaukurs/handouts/handout-8-Einfache_Regression.pdf. Version: 2006
- [Lie12] LIEBAU, Björn: *Der deutsche Strommarkt: Marktdesign und Anbieterverhalten.* http://miami.uni-muenster.de/servlets/DerivateServlet/Derivate-6492/diss_liebau_buchblock.pdf. Version: 04.06.2012
- [LY13] LIN, Yi ; YONGHO, Jeon: *Random Forests and Adaptive Nearest Neighbors.* <http://www.stat.wisc.edu/sites/default/files/tr1055.pdf>. Version: 30.05.2013
- [MA14] MANGALOVA, E. ; AGAFONOV, E.: *Wind power forecasting using the k-nearest-neighbors algorithm.* <http://dx.doi.org/10.1016/j.ijforecast.2013.07.008>. In: *International Journal of Forecasting* Bd. 30. – DOI 10.1016/j.ijforecast.2013.07.008, 402–406
- [Ma10] DR. THOMAS MAZZONI ; FERNUNIVERSITÄT HAGEN (Hrsg.): *Zeitreihenanalyse ... Einstieg und Aufgaben.* https://www.fernuni-hagen.de/imperia/md/content/ls_statistik/zeitreihenerg_nzungsskript_12_10.pdf. Version: 13.12.2010
- [Mah] MAHALANOBIS, P. C.: On the generalised distance in statistics. In: *Proceedings of the National Institute of Science of India* Bd. 1/1936, S. 49–55
- [McK14] MCKINSEY ; MCKINSEY (Hrsg.): *Studie - Energiewende-Index.* 02.09.2014
- [Mer11] MERTENS, Peter: *Prognoserechnung.* 7. Heidelberg : Physica-Verl., 2011. – ISBN 3790802166
- [Mic92] MICHELS, Paul: *Arbeiten zur angewandten Statistik.* Bd. 36: *Nichtparametrische Analyse und Prognose von Zeitreihen.* Heidelberg : Physica-Verlag, 1992. – ISBN 9783790805819
- [MKS94] MURTHY, S. ; KASIF, S. ; SALZBERG, S.: A System for Induction of Oblique Decision Trees. In: *Journal of Artificial Intelligence Research* (1994), Nr. 2, S. 1–32
- [ML13] MÜLLER, Roland M. ; LENZ, Hans-Joachim: *Business Intelligence.* Berlin, Heidelberg : Imprint: Springer Vieweg, 2013 (eXamen.press). – ISBN 9783642355592
- [MLR11] MUCHE, Rainer ; LANZINGER, Stefanie ; RAU, Michael: *Medizinische Statistik mit R und Excel: Einführung in die RExcel- und R-Commander-Oberflächen zur statistischen Auswertung.* Berlin and Heidelberg : Springer-Verlag Berlin Heidelberg, 2011 (Springer-Lehrbuch). <http://dx.doi.org/10.1007/978-3-642-19484-9>. <http://dx.doi.org/10.1007/978-3-642-19484-9>. – ISBN 978-3-642-19484-9

- [Noa07] NOACK, Marcel: *Faktorenanalyse*. <http://www.uni-due.de/imperia/md/content/soziologie/stein/faktorenanalyse.pdf>. Version: 13.12.2007
- [OKL15] OHSENBRÜEGGE, Anja ; KLINGENBERG, Thole ; LEHNHOFF, Sebastian: Dynamic Data Driven Dimensioning of Balancing Power with k-nearest Neighbors. In: *Proceedings PESS Dortmund 2015*, S. S04.3
- [PC95] PENDSE, Nigel ; CREETH, Richard: *The OLAP report: Succeeding with on-line analytical processing: volume 1: OLAP planning, design and development*. Business Intelligence Ltd, 1995. – ISBN 9781898085218
- [PS13] PAPARODITIS, Efstathios ; SAPATINAS, Theofanis: *Short-Term Load Forecasting: The Similar Shape Functional Time-Series Predictor*. <http://dx.doi.org/10.1109/TPWRS.2013.2272326>. Version: 2013
- [Pol20] POLYA, George: *Über den zentralen Grenzwertsatz der Wahrscheinlichkeitsrechnung und das Momentumproblem*. In: *Mathematische Zeitschrift* Bd. 8, 1920, 171–181
- [Ri10] RINGELSTEIN, Jan: *Betrieb eines übergeordneten dezentral entscheidenden Energiemanagements im elektrischen Verteilnetz*. Dissertation Kassel : university press GmbH, 2010 – ISBN 978-3-86219-008-9
- [Rol11] ROLLI, Felix T.: *Marktstrukturanalyse der Stromwirtschaft: Der Regelleistungsmarkt und seine Bedeutung für die ordnungspolitische Gestaltung hinsichtlich Entflechtung, Wettbewerb und Regulierung*. 1. Baden-Baden : Nomos, 2011, 2011. – ISBN 3832967028
- [Ros12] ROSEN, Michael ; RWE DEUTSCHLAND (Hrsg.): *Die Energiewende - Daten und Fakten: Erzeugung, Netze, Smart Grids, Stromspeicher, Regelleistung, Elektromobilität*. <http://www.rwe.com/web/cms/mediablob/de/1297634/data/497964/5/rwe-deutschland-ag/presse/Die-Energiewende-Daten-und-Fakten.pdf>. Version: 10.02.2012
- [Run10] RUNKLER, Thomas A.: *Data-Mining: Methoden und Algorithmen intelligenter Datenanalyse ; mit 7 Tabellen*. 1. Wiesbaden : Vieweg + Teubner, 2010 (Studium). – ISBN 383480858X
- [SB13] SHRIVASTAVA, Ankita ; BHANDAKKAR, Arti: Short-Term Load Forecasting Using Artificial Neural Network Techniques. http://www.ijera.com/papers/Vol13_issue5/IV3515241527.pdf. In: *International Journal of Engineering Research and Applications* Bd. 3, 1524–1527
- [Sch04] SCHULZE, Peter M.: *Granger-Kausalitätsprüfung: Eine anwendungsorientierte Darstellung*. http://www.statoek.vwl.uni-mainz.de/Arbeitspapier_Nr_28_Granger-Kausalitaetspruefung.pdf. Version: 2004
- [Sch09] SCHWAB, Adolf J.: *Elektroenergiesysteme: Erzeugung, Transport, Übertragung und Verteilung elektrischer Energie*. 2. Berlin : Springer Berlin, 2009. – ISBN 3642219586

-
- [Sch11] SCHMID, Matthias: *Introduction to Gradient Boosting*. http://www.imbe.med.uni-erlangen.de/ma/M.Schmid/Tutorial/01_Introduction.pdf. Version: 20.05.2011
- [Sha11] SHAIENDRA, Kumar S.: *ACO Based Feature Subset Selection for Multiple k-Nearest Neighbour Classifiers*. <http://www.enggjournals.com/ijcse/doc/IJCSE11-03-05-127.pdf>. Version: 2011
- [Shr09] SHRESTHA, Durga L.: *Uncertainty Analysis in Rainfall-Runoff Modelling: Application of Machine Learning Techniques: Dissertation*. Delft, 2009
- [SK12] SCHÜTT, Kristina ; KRAUSS, Clemens: Untersuchung zur Dimensionierung der aus-
geschriebenen Regelleistung des Netzregelverbundes. In: *Energiewirtschaftliche Ta-
gesfragen* Bd. 62(2012), S. 59–62
- [Smo99] SMOLA, Alexander J.: *Lernen mit Kernen*. [http://alex.smola.org/
papers/1999/Smola99.pdf](http://alex.smola.org/papers/1999/Smola99.pdf). Version: 1999
- [Spa08] SPATH, Dieter: *Organisatorische Wandlungsfähigkeit produzierender Unternehmen:
Unternehmenserfahrungen, Forschungs- und Transferbedarfe*. Stuttgart : Fraunhofer
IRB Verl., 2008. – ISBN 978-3816775300
- [Spe11] SPECKMANN, Markus ; IWES (Hrsg.): *Regelleistung durch erneuerbare Energien
- Herausforderungen und Lösungsansätze: ETP Konferenz "Virtuelle Kraftwerke und
Regelenergie"*. Version: 2011
- [Spe12] SPECKAMP, Christoph: Bundesweit einheitliches Management von Minutenreserve-
leistung: Merit-Order-List-Server. In: *ew* 111 (2012), Nr. 22, S. 32–34
- [SS89] SIEDLECKI W. ; SKLANSKY, J.: A Note on genetic algorithms for large scale feature
selection. In: *Journal for Pattern Recognition* Bd. 10/1989, S. 335–347
- [SS01] SCHLITGEN, Rainer ; STREITBERG, Bernd: *Zeitreihenanalyse*. 9. München and and
Wien : Oldenbourg, 2001. – ISBN 9783486257250
- [SS03] SCHÖLKOPF, Bernhard ; SMOLA, Alexander: *A Short Introduction to Learning
with Kernels*. [http://www.bradblock.com/A_Short_Introduction_
to_Learning_with_Kernels.pdf](http://www.bradblock.com/A_Short_Introduction_to_Learning_with_Kernels.pdf). Version: Springer Heidelberg, 2003
- [ST14] SCHUKAT-TALAMAZZINI: *MASCHINELLES LERNEN & DATAMINING: Vorle-
sung Universität Jena*. [http://www.minet.uni-jena.de/fakultaet/
schukat/ML/Scriptum/lect01-intro.pdf](http://www.minet.uni-jena.de/fakultaet/schukat/ML/Scriptum/lect01-intro.pdf). Version: 2014
- [Stü03] STÜTZLE, Eric A.: *Entwicklung eines Prognosekonzepts mit bedingten multivariaten
Wahrscheinlichkeitsverteilungen: Anwendungen aus der Automobilindustrie*. [http://
d-nb.info/1013934636/34](http://d-nb.info/1013934636/34). Version: 2003
- [Swi06] SWIDER, Derk Jan : *Handel an Regelenergie und Spotmärkten*. 1. Wiesbaden: Deut-
scher Universitätsverlag, 2006. – ISBN 9783835004597

- [Tak81] TAKENS, Floris: Detecting strange attractions in turbulence. In: RAND, David (Hrsg.) ; YOUNG, Lai-Sang (Hrsg.): *Dynamical Systems and Turbulence, Warwick 1980* Bd. 898. Berlin and Heidelberg : Springer, 1981 (Lecture Notes in Mathematics). – ISBN 978-3-540-11171-9, S. 366–381
- [Vap08] VAPNIC, Vladimir: *The nature of statistical learning theory*. 2. ed., 6. print. New York : Springer, 2008 (Statistics for engineering and information science). <http://www.loc.gov/catdir/enhancements/fy0816/99039803-d.html>. – ISBN 0387987800
- [VDE06] VDEW/VDN: *Eigenerzeugungsanlagen am Niederspannungsnetz, 4. Ausgabe 2001 mit VDN-Ergänzungen September 2005*. http://www.sw-netz.de/wp-content/uploads/tv-n_eigen-nsvdn_2005-09-nl.pdf. Version: 20.01.2006
- [Wei99] WEIGEND, Andreas S. (Hrsg.): *Santa Fe Institute studies in the sciences of complexity*. Bd. 15: *Time series prediction: Forecasting the future and understanding the past*. [Nachdr.]. Reading, MA : Perseus Books, 1999. – ISBN 978-0201626025
- [Wei09a] WEISSBACH, Tobias ; UNIVERSITÄT STUTTGART, INFORMATIK (Hrsg.): *Verbesserung des Kraftwerks- und Netzregelverhaltens bezüglich handelsseitiger Fahrplanänderungen: Dissertation*. http://elib.uni-stuttgart.de/opus/volltexte/2009/4647/pdf/Diss_Weissbach.pdf. Version: 2009
- [Wei09b] WEISSBACH, Tobias: *Netzdynamikverhalten und die Rolle des Netzselbstregeleffekts: Workshop zur dezentralen Netzstützung*. http://www.iee.tu-clausthal.de/fileadmin/downloads/07-Tobias_Weissbach.pdf. Version: 23.10.2009
- [WM97] WOLPERT, D. ; MACREADY, W.: No Free Lunch Theorems for Optimization. In: *IEEE Transactions on evolutionary computation* Bd. 1/1997, S. 67–82
- [WM14] WANG, Xiao-Xia ; MA, Liang-Yu: *A Compact K Nearest Neighbor Classification for Power Plant Fault Diagnosis*. <http://bit.kuas.edu.tw/~jihmsp/2014/vol15/JIH-MSP-2014-03-017.pdf>. Version: 03.05.2014
- [YDK06] YANKOV, Dragomir ; DECOSTE, Dennis ; KEOGH, Eamonn: *Ensembles of Nearest Neighbor Forecasts*. http://alumni.cs.ucr.edu/~dyankov/publications/ECML06_EnsemblesNNForecasts.pdf. Version: 2006

Danksagung

Diese Arbeit entstand im Rahmen des SEE Promotionsprogramms „System Integration Erneuerbare Energien“ gefördert vom Niedersächsischen Ministerium für Wissenschaft und Kultur und der Carl-von-Ossietzky Universität Oldenburg. Mein Dank gilt den Förderern und meinen Betreuern für ihre Unterstützung.