

Ein Beitrag zur systemtechnischen Betrachtung der Windleistungsprognose

Dissertation zur Erlangung des
akademischen Grades Doktor-Ingenieur (Dr.-Ing.)

vorgelegt der Fakultät Informatik und Automatisierung
der Technischen Universität Ilmenau

von Dipl.-Ing. Alexander Arnoldt

1. Gutachter: Univ.-Prof. Dr.-Ing. habil. Pu Li
2. Gutachter: Prof. Dr.-Ing. habil. Thomas Rauschenbach
3. Gutachter: Univ.-Prof. Dr.-Ing. habil. Christoph Ament

Tag der Einreichung: 10.11.2017
Tag der wissenschaftlichen Aussprache: 20.06.2019

Zusammenfassung

Im Rahmen dieser Arbeit wurde der Stand der Wissenschaft aufgearbeitet. Anhand der Analyse konnte festgestellt werden, dass Windleistungsprognosen auf Basis unterschiedlicher Modellkategorien basieren. Ein in über zehn Jahren wenig bis gar nicht veröffentlichtes Thema ist der Einfluss der Datenanalyse insbesondere des Data Minings auf die Prognose. Im Laufe der Bearbeitung des Themas und durch die Erkenntnisse der Literaturrecherche wurde der Fokus auf die Datenanalyse gerichtet. Als Innovation wurden die Daten auf ihre unterschiedliche statistischen Eigenschaften untersucht und diese miteinander kombiniert. Als geeignete Methoden haben sich die multiple Korrelationskoeffizienten- (MKK), die bedingte Entropie-Analyse und die Verwendung des linearen, nichtlinearen Informationsmaßes herausgestellt. Nicht geeignet sind die Methoden Hauptkomponentenanalyse (HKA) und Faktorenanalyse. Die Verwendung des MKK sowie des linearen, nichtlinearen Informationsmaßes wurde in keiner recherchierten Quelle verwendet. Mit Hilfe des BOX-JENKINS-Verfahrens wurde das ARX Modell (autoregressives Modell mit exogenen Größen) als geeignetes Prognosemodell identifiziert und getestet. Nur durch die Verwendung eines RN (rückgekoppelte neuronale Netze) konnte deren Güte verbessert werden. Für die eingesetzten neuronale Netze wurden Experimente durchgeführt, wie Verfahrensweisen zur weiteren Verbesserung führen können. Abschließend wurde die Metaprognose in innovativer Form eingesetzt und konnte zusätzliche Gütesteigerungen erzielen. Weiterhin wurde eine Kennzahl eingeführt, um den Güteanteil der Datenanalyse und des Prognosemodells in der Prognose zu messen. Dieser zeigt, dass die Datenanalyse ca. 80% Güteanteil an der Prognose besitzt. Die Prognosemethodik wurde erfolgreich an zwei Photovoltaik-Anlagen getestet. Neben der Datenanalyse wurde der Einfluss der Datenstruktur auf die Prognosequalität bewertet. Ein verlustfreies Speicherformat für Integration historischer Klimaprognosen ist unabdingbar, damit qualitativ performante Prognosemodelle trainiert werden können. Schließlich wurden die Erkenntnisse dieser Arbeit in einen Prototypen MaProSy integriert, mit Hilfe dessen produktive Prognosen umgesetzt werden können.

Summary

This work processes the latest state of the science. Based on the analysis, it was found that wind power forecasts are based on a wide range of model categories. A topic, which has been heavily neglected over the past ten years, is the impact of data analysis, in particular of data mining, on the prognosis. In the course of working on the topic and the findings of the literature research, the focus was set on data analysis. As an innovation, the data were examined concerning their different statistical characteristics and were combined with each other. Suitable methods have been found to be the multiple correlation coefficient (MKK), the conditional entropy analysis, and the use of the linear, nonlinear information measure. Not suitable are the methods Principal Component Analysis and Factor Analysis. The use of the MKK as well as the linear, nonlinear information measure was not used in any researched source. The BOX-JENKINS method was used to identify and test the ARX model (autoregressive model with exogenous parameters) as a suitable predictive model. Only by using an RN (feedback neural networks) their quality could be improved. For the neural networks used, experiments were carried out on how procedures can lead to further improvement. Finally, the metaprognosis was used in an innovative way which resulted in an additional increases in quality. Furthermore, an indicator was introduced to measure the ratio of quality of the data analysis and the forecasting model on the forecast. This shows that the data analysis has a share of about 80 % in the forecast. The forecasting methodology was successfully tested on two photovoltaic systems. In addition to the data analysis, this work evaluates the influence of the data structure on the forecast quality. An indispensable requirement to implement high-performance forecasting models is the lossless storage format for the integration of historical climate forecasts. Finally, the findings of this work were integrated into a prototype MaProSy which performs productive forecasts.

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Abbildungsverzeichnis	II
Abkürzungsverzeichnis	VII
Einheitenverzeichnis	IX
1 Einleitung	1
1.1 Motivation	1
1.2 Überblick über aktuelle wissenschaftliche Arbeiten	4
1.3 Ziele der Arbeit	11
2 Grundlagen	13
2.1 Physikalische Zusammenhänge	13
2.2 Numerische Wetterprognosemodelle	14
2.3 Modellbildungsprozess	16
2.3.1 Lineare stochastische Signalmodelle	17
2.3.2 Nichtlineare stochastische Signalmodelle	18
2.3.3 Anforderungsanalyse	22
3 Modellierung	24
3.1 Deklarationen für die Validierung	24
3.1.1 Evaluierungskriterien	24
3.1.2 Hilfsmodell	25
3.1.3 Analysemethodik	27
3.2 Experimentelle Randbedingungen	28
3.3 Datenanalyseprozess	29
3.3.1 Analyse Prognoseziel	29
3.3.2 Sensitivitätsanalyse exogener Klimagrößen	31
3.3.3 Multivariate Untersuchungen	33
3.3.4 Untersuchungen zum Datenmanagement	44
3.3.5 Informationsanalyse	53
3.3.6 Zusammenfassung Datenanalyse	58
3.4 Prognosemodellierung	60
3.4.1 Analyse Referenzmodelle	60
3.4.2 Modellierung lineares stochastisches Signalmodell	61
3.4.3 Auswahl Netzwerkarchitektur	64
3.4.4 Strukturoptimierung der Hidden Layer Schicht	70
3.4.5 Optimierung des Trainingszeitraums	72
3.4.6 Analyse Güteanteile zwischen Prognosemodellierung und Datenanalyse	74
3.4.7 Metaprognose	74
3.4.8 Zusammenfassung Prognosemodellierung	77

4	Softwareentwicklung	80
4.1	Prototypenkonzept für AProSy	81
4.2	Softwareprototyp MProSy	84
4.3	Softwareprototyp Klimadatenarchiv	84
5	Ergebnisse	87
5.1	Windpark 2	88
5.2	Windpark 3	90
5.3	Windpark 4	92
5.3.1	Prognose	92
5.3.2	Prozessoptimierung	94
5.4	Übertragbarkeit auf Photovoltaik-Anlagen	96
5.5	Zusammenfassung exemplarischer Untersuchungen	98
6	Diskussion und Zusammenfassung	100
6.1	Diskussion	100
6.2	Zusammenfassung	103
6.3	Ausblick	103
Anhang		i
A	Übersicht der Experimente aus Kapitel 3	i
B	Analyse der Literaturrecherche	iv
C	Validierungsanalysen der Modellierung	xi
D	Auswertungsgrafiken der Ergebnisse	xix
D.1	Windpark 2	xix
D.2	Windpark 3	xxii
D.3	Windpark 4	xxv
D.4	Übertragbarkeit	xxxii
	Literaturverzeichnis	xliv

Abbildungsverzeichnis

1.1	Visualisierung Statistiken für das Jahr 2014, [95, 41]	1
1.2	Szenario 2011 A der Leitstude des BMU [145, S. 12]	3
1.3	Grafische Auswertung der eingesetzten Methoden zur Windleistungsprognose	5
1.4	Auswertung der Arbeiten zur Windleistungs- und Windgeschwindigkeitsprognose	6
1.5	Allgemeine Prognoseprozessbildung	7
1.6	Erfassungsbereich und Ausdehnung der NWP Modelle des DWD [146] für die verwendeten Parameter mit Einflussbereich einiger physikalischer Phänomene	8
2.1	Grafische Darstellung der physikalischen Zusammenhänge	14
2.2	Schematische Skizze der Produktionszyklen der COSMO-DE (braun) und COSMO-EU (blau) Modelle: Darstellung der Produktionsläufe durch dunkle Felder; Quelle: DWD	15
2.3	Modellbildungsprozess nach BOX-JENKINS in [33, S. 17]	16
2.4	Ausschnitt relevanter Modellklassen	17
2.5	Übersicht der KNN Architekturen	19
2.6	Vernetzungsprinzip eines Feed Forward Netzes	20
3.1	Blockschaltbild ARX(1) für Validierungszwecke mit unspezifizierten Eingängen	25
3.2	Erklärungsbeispiel eines Periodogrammtests aus dem Experiment EXP SP1.4 im Kapitel 5	26
3.3	Schematischer Aufbau des Boxplots	27
3.4	Blockschaltbild der Persistenz-Methode	30
3.5	Visualisierung Korrelationsanalyse der WP1 Einspeisung mit 5 % Konfidenzband	30
3.6	Beispiel einer Persistenz-Methode, Gl. (3.7), für eine drei-Stunden-Prognose .	30
3.7	Auswertung Persistenzmethode WP1 (Fehlermaße: NRMSE - blau und NMAE - grün) der Prognose in Abbildung 3.6	31
3.8	Blockschaltbild zur Berechnung der Leistungsentnahme anhand der physikali- schen Zusammenhänge	32
3.9	Luftdichtesensibilität mit der Anwendung der Normparameter einer WKA .	33
3.10	Eigenschaften der Varianz	34
3.11	HKA für WP 1: Die 3D-Grafik (oben) zeigt die HK-Koeffizienten (blau) der Linearkombination als Vektoren und die projizierten Ausgangsdaten (rot) als Streudiagramm. Die PARETO-Darstellung zeigt die Varianzen (Boxen) der Hauptkomponenten und die kumulierte Varianz (Kurve).	35
3.12	Windrichtungsabhängige Ertragskurven der WKAs des WP 1 (Die rechte Legende beschreibt die Windrichtung in [°])	36
3.13	Arbeitsprinzip Größenauswahl MKK	38
3.14	Darstellung der kompletten Beispielrechnung MKK aus Tabelle 3.5 für die Horizonte s_1 , 12 und 24	39
3.15	Darstellung der optimierten MKK mittels Permutation für die Horizonte s_1 , 12 und 24	40

3.16	Vergleich der maximalen Gradienten- und Anstiegsoptimierung über alle Prognosehorizonte	41
3.17	Modellaufbau für Horizont 1 des Experiments EXP3 auf Basis der Analyseergebnisse in Tabelle 3.6	42
3.18	Modellaufbau für Horizont 1 des Experiments EXP4	42
3.19	NRMSE Analyse der EXP 1 bis EXP 4	43
3.20	Detailvergleich EXP 1 mit EXP 4	43
3.21	Validierung EXP 1 mit EXP 4 mit Boxplot und Periodogrammanalyse . . .	44
3.22	Vergleich Speichersystematik zwischen VDS und OZM	45
3.23	Datenzusammenhänge EXP 4 für ein VDS System	46
3.24	EXP6 - Darstellung Transformierung VDS zu OZM mit festhalten der Trainingsdatenpunkte	47
3.25	EXP 7 - OZM Prognose mit ununterbrochenen Trainingszeitraum	47
3.26	Horizont scharfe Auswertung zwischen EXP 4 und EXP 5	48
3.27	Horizont scharfe Auswertung zwischen EXP 4 und EXP 6	49
3.28	Horizont scharfe Auswertung zwischen EXP 4 und EXP 7	50
3.29	Validierung EXP 7 mit Boxplot und Periodogramm gegen EXP 4	50
3.30	Validierung EXP 6 mit Boxplot und Periodogramm gegen EXP 4	51
3.31	Fehleranalyse Windgeschwindigkeitsmessung mit Klimaprognose	52
3.32	Wechselseitige Information	53
3.33	Darstellung Information und Entropie im Zusammenhang	54
3.34	EXP 8 im Vergleich zu EXP 4	55
3.35	Blockschaltbild des Modellaufbaus für EXP 9 im Prognosehorizont H 1 . . .	56
3.36	EXP 9 im Vergleich zu EXP 4	56
3.37	Blockschaltbild des Modellaufbaus für EXP 10 im Prognosehorizont H 1 . .	57
3.38	EXP 10 im Vergleich zu EXP 4	57
3.39	Validierung EXP 9 im Vergleich zu EXP 4	58
3.40	Vergleich Referenzmodelle	61
3.41	Blockschaltbild des Modellaufbaus für EXP 13 im Prognosehorizont H 1 . .	62
3.42	Vergleich ARX(3) in EXP 13 mit EXP 4	63
3.43	Ertragskennlinie des WP 1 in unterschiedlichen zeitlichen Mittlungen; kleines Bild im Bezug auf nächstgelegene Messstation	64
3.44	Blockschaltbild des Modellaufbaus für EXP 14 im Prognosehorizont H 1 . .	66
3.45	Vergleich Referenzmodell ARX in EXP 4 mit FF in EXP 14	66
3.46	Blockschaltbild des Modellaufbaus für EXP 15 im Prognosehorizont H 1 . .	67
3.47	Vergleich Referenzmodell ARX in EXP 4 mit FF in EXP 15	67
3.48	Validierung EXP 15 im Vergleich zu EXP 4	68
3.49	Vergleich der Ein- und Ausgänge der Modelle ARX und RN für den Prognosehorizont + 1 h	69
3.50	Vergleich EXP15 bis 21: Einfluss der Optimierung der Neuronenanzahl . . .	71
3.51	Blockschaltbild des Modellaufbaus für EXP 22 im Prognosehorizont H 1 . .	72
3.52	Vergleich Fehlerauswertung EXP 22 mit EXP 15	73
3.53	Validierung EXP 22 im Vergleich zu EXP 15	73
3.54	Arbeitsprinzip der Metaprognose	75
3.55	Vergleich Fehlerauswertung EXP 24 mit EXP 15 und EXP 23	76
3.56	Validierung EXP 24 im Vergleich zu EXP 15	77
3.57	Vergleich Fehlerauswertung EXP 26 mit EXP 15 und EXP 25	78
3.58	Validierung EXP 26 im Vergleich zu EXP 15	79
4.1	Zusammenhänge der Diagramme in der Softwareentwicklung	80

4.2	Funktionsdiagramm AProSy („include“ bedeutet, dass eine Funktion andere Funktionen als Unterfunktionen benötigt.)	82
4.3	Sequenzdiagramm AProSy	83
4.4	Module MProSy	84
4.5	Beispiel Inhaltsdarstellung einer GRIB Datei für die u-Komponente der Windgeschwindigkeit	85
4.6	Klimaarchiv UI	86
4.7	Nutzeranwendung zum Exportieren der Daten in Folgeprozesse	86
5.1	Vergleich Fehlerauswertung EXP WP 2.2 mit EXP WP 2.1	88
5.2	Vergleich Fehlerauswertung EXP WP 2.5 mit EXP WP 2.1 und WP 2.3	89
5.3	Validierung EXP WP 2.5 mit EXP WP 2.1	89
5.4	Vergleich Fehlerauswertung EXP WP 3.3 mit EXP WP 3.1	90
5.5	Vergleich Fehlerauswertung EXP WP 3.5 mit EXP WP 3.1 und WP 3.3	90
5.6	Validierung EXP WP 3.5 mit EXP WP 3.1	91
5.7	Vergleich Fehlerauswertung EXP WP 4.2 mit EXP WP 4.1	92
5.8	Vergleich Fehlerauswertung EXP WP 4.5 mit EXP WP 4.1 und WP 4.3	93
5.9	Validierung EXP WP 4.5 mit EXP WP 4.1	93
5.10	Vergleich Fehlerauswertung EXP WP 4.6 mit EXP WP 4.1	94
5.11	Vergleich Fehlerauswertung EXP WP 4.10 mit EXP WP 4.6 und WP 4.8	95
5.12	Validierung EXP WP 4.10 mit EXP WP 4.6	95
5.13	Vergleich Fehlerauswertung EXP SP1.3 gegenüber EXP SP1.4	96
5.14	Validierung EXP SP1.3 mit EXP SP1.4	97
5.15	Vergleich Fehlerauswertung EXP SP2.3 gegenüber EXP SP2.1	97
5.16	Validierung EXP SP2.3 mit EXP SP2.1	98
C.1	Validierung EXP 5 mit Boxplot und Periodogramm gegen EXP 4	xi
C.2	Validierung EXP 8 im Vergleich zu EXP 4	xi
C.3	Validierung EXP 10 im Vergleich zu EXP 4	xii
C.4	Validierung EXP 11 im Vergleich zu EXP 4	xii
C.5	Validierung EXP 12 im Vergleich zu EXP 4	xiii
C.6	Validierung EXP 13 im Vergleich zu EXP 4	xiii
C.7	Validierung EXP 14 im Vergleich zu EXP 4	xiv
C.8	Validierung EXP 16 im Vergleich zu EXP 15	xiv
C.9	Validierung EXP 17 im Vergleich zu EXP 15	xv
C.10	Validierung EXP 18 im Vergleich zu EXP 15	xv
C.11	Validierung EXP 19 im Vergleich zu EXP 15	xvi
C.12	Validierung EXP 20 im Vergleich zu EXP 15	xvi
C.13	Validierung EXP 21 im Vergleich zu EXP 15	xvii
C.14	Validierung EXP 23 im Vergleich zu EXP 15	xvii
C.15	Validierung EXP 25 im Vergleich zu EXP 15	xviii
D.16	Boxplot zu EXP WP 2.1	xix
D.17	Validierung EXP WP 2.2 im Vergleich zu EXP WP 2.1	xix
D.18	Vergleich Fehlerauswertung EXP WP 2.3 mit EXP WP 2.1	xx
D.19	Validierung EXP WP 2.3 im Vergleich zu EXP WP 2.1	xx
D.20	Vergleich Fehlerauswertung EXP WP 2.4 mit EXP WP 2.1 und WP 2.2	xxi
D.21	Validierung EXP WP 2.4 mit EXP WP 2.1	xxi
D.22	Boxplot zu EXP WP 3.1	xxii
D.23	Vergleich Fehlerauswertung EXP WP 3.2 mit EXP WP 3.1	xxii
D.24	Validierung EXP WP 3.2 im Vergleich zu EXP WP 3.1	xxiii
D.25	Validierung EXP WP 3.3 im Vergleich zu EXP WP 3.1	xxiii

D.26 Vergleich Fehlerauswertung EXP WP 3.4 mit EXP WP 3.1 und WP 3.2 . . .	xxiv
D.27 Validierung EXP WP 3.4 mit EXP WP 3.1	xxiv
D.28 Boxplot zu EXP WP 4.1	xxv
D.29 Validierung EXP WP 4.2 im Vergleich zu EXP WP 4.1	xxv
D.30 Vergleich Fehlerauswertung EXP WP 4.3 mit EXP WP 4.1	xxvi
D.31 Validierung EXP WP 4.3 im Vergleich zu EXP WP 4.1	xxvi
D.32 Vergleich Fehlerauswertung EXP WP 4.4 mit EXP WP 4.1 und WP 4.2 . . .	xxvii
D.33 Validierung EXP WP 4.4 mit EXP WP 4.1	xxvii
D.34 Boxplot zu EXP WP 4.6	xxviii
D.35 Validierung EXP WP 4.6 im Vergleich zu EXP WP 4.1	xxviii
D.36 Vergleich Fehlerauswertung EXP WP 4.7 mit EXP WP 4.6	xxix
D.37 Validierung EXP WP 4.7 im Vergleich zu EXP WP 4.6	xxix
D.38 Vergleich Fehlerauswertung EXP WP 4.8 mit EXP WP 4.6	xxx
D.39 Validierung EXP WP 4.8 im Vergleich zu EXP WP 4.6	xxx
D.40 Vergleich Fehlerauswertung EXP WP 4.9 mit EXP WP 4.6 und WP 4.7 . . .	xxx
D.41 Validierung EXP WP 4.9 mit EXP WP 4.6	xxx
D.42 NRMSE des EXP SP 1.1	xxxii
D.43 Boxplot der Residuen des EXP SP 1.1	xxxii
D.44 Periodogrammtest des EXP SP 1.1	xxxiii
D.45 NRMSE des EXP SP 1.2	xxxiii
D.46 Boxplot der Residuen des EXP SP 1.2	xxxiv
D.47 Periodogrammtest des EXP SP 1.2	xxxiv
D.48 NRMSE des EXP SP 1.3	xxxv
D.49 Boxplot der Residuen des EXP SP 1.3	xxxv
D.50 Periodogrammtest des EXP SP 1.3	xxxvi
D.51 NRMSE des EXP SP 1.4	xxxvi
D.52 Boxplot der Residuen des EXP SP 1.4	xxxvii
D.53 Periodogrammtest des EXP SP 1.4	xxxvii
D.54 NRMSE des EXP SP 2.1	xxxviii
D.55 Boxplot der Residuen des EXP SP 2.1	xxxviii
D.56 Periodogrammtest des EXP SP 2.1	xxxix
D.57 NRMSE des EXP SP 2.2	xxxix
D.58 Boxplot der Residuen des EXP SP 2.2	xl
D.59 Periodogrammtest des EXP SP 2.2	xl
D.60 NRMSE des EXP SP 2.3	xli
D.61 Boxplot der Residuen des EXP SP 2.3	xli
D.62 Periodogrammtest des EXP SP 2.3	xlii
D.63 NRMSE des EXP SP 2.4	xlii
D.64 Boxplot der Residuen des EXP SP 2.4	xliii
D.65 Periodogrammtest des EXP SP 2.4	xliii

Abkürzungsverzeichnis

Abkürzung	Langfassung
A_{rot}	Rotor durchzogene Kreisfläche
alpha	Windrichtung
ANFIS	Adaptive-network-based fuzzy inference system
AProSy	Adaptives Prognosesystem
AR	Autoregressive Modelle
ARIMA	Autoregressives integriertes Mittelwertmodell
ARMA	Autoregressives Mittelwertmodell
ARX	Autoregressives Modell mit exogenen Größen
AST	Angewandte Systemtechnik
BMU	Bundesamt für Umwelt, Naturschutz und Reaktorsicherheit
BRD	Bundesrepublik Deutschland
c_p	Leistungsbeiwert
cp	Leistungsbeiwert
CPID	Koordinatenpunktidentifizierung
CSM	Conventional Statistical Model - konventionelle statistische Modelle
D	Tagesdosis in Prozent
DR	Demand Response
DSM	Demand Side Management
DWD	Deutscher Wetterdienst
e	Fehlers
EE	Erneuerbare Energien
EEG	Erneuerbares Energie Gesetz
EEX	European Exchange AG
EnWG	Energiewirtschaftsgesetz
EU	Europäische Union
EXP	Experiment
FD	Klimaprognosedaten
FhG	Fraunhofer Gesellschaft e.V.
FF	Feed Forward Netz
HKA	Hauptkomponentenanalyse
HK	Hauptkomponenten
I	Information nach Schannon
KM	Kalman
KNN	Künstliche Neuronale Netze
LM	Levenberg-Marquardt Algorithmus
NN	Artificial Neural Network - Künstliche Neuronale Netze
MA	Mittelwert Modelle, Englisch: Moving Average
MAE	Mean absolute error - mittlerer absoluter Fehler
$MAPE$	Mittlerer absoluter prozentualer Fehler
MAProSy	Matalb basiertes adaptives Prognosesystem
MD	Messdaten
MKK	multivariater Korrelationskoeffizient
MOS	Model output statistics
MRE	Mittlerer relativer Fehler
MSE	Mean square error - mittlerer quadratischer Fehler
$NMAE$	Normalisierter mittlerer absoluter Fehler
$NMSE$	Normierter mittlerer quadratischer Fehler
$NRMSE$	Normalisierte Wurzel des mittleren quadratischen Fehlers
NWP	Numerical Weather Prediction model - numerische Wetterprognose

Abkürzung	Langfassung
OZM	Offenes Zeitreihenmanagement
p	Luftdruck
$P(\dots)$	Wahrscheinlichkeitsfunktion
P_{el}	Elektrische Leistung
P_{inst}	Installierte Leistung
PROP	Resilient Propagation
PV	Photovoltaik
PSP	Parametrische stationäre Prozesse
ϕ	Luftfeuchtigkeit
R	Korrelationskoeffizient
RN	Rückgekoppeltes Netz
ρ	Luftdichte
r	Korrelationskoeffizient
SCADA	Supervisory Control and Data Acquisition - Überwachungskontrolle und Datenakquirierung
SCM	Spatial Correlation Model - räumliche Korrelationsmodelle
sMobiliTy	smart MobiliTy Thüringen
SOM	Self organizing map
SVM	Support vector machine
T	Lufttemperatur
v	Windgeschwindigkeit
VDS	Verlustfreie Datenspeicherung
WKA	Windkraftanlage
WLP	Windleistungsprognose
WP	Windpark
z_0	Bodenrauigkeit

Einheitenverzeichnis

Einheit	Beschreibung
d	Tag
GW	Giga Watt
h	Stunde
K	Kelvin
km	Kilometer
m/s	Meter je Sekunde
Pa	Pascall
%	Prozent
TWh	Thera Wattstunde/-n

1 Einleitung

1.1 Motivation

Seit den neunziger Jahren vollzieht sich im gesellschaftlichen Umweltbewusstsein der nationalen und internationalen Politik ein Umdenkprozess. Ein Aspekt ist die Umgestaltung der Energieversorgung hin zu einer auf erneuerbaren Energien basierenden Versorgung. Diese Aufgaben werden unter anderem in den 20-20-20 Zielen der Europäischen Union (EU) festgehalten und durch Gesetze wie das erneuerbare Energie Gesetz (EEG) [5] der Bundesrepublik Deutschland (BRD) gefördert. Die erneuerbaren Energien (EE) hatten 2014 in ihrer Gesamtheit mit 87,0 GW mehr installierte Erzeugungsleistung als der größte konventionelle Energieträger Erdgas mit 28,4 GW, vgl. [95, S. 37]. Die EE erzeugten mit 161 TWh mehr Energie als der Beitrag des konventionellen Erzeugers Braunkohle mit 156 TWh. Die Windenergie nimmt mit ihrer installierten Kapazität von 35,7 GW die zweite Position der EE Kraftwerkskapazitäten hinter solarer Strahlungsenergie mit 38,1 GW ein. Mit einer Gesamtproduktion von 56 TWh ist sie der größte EE Stromproduzent.

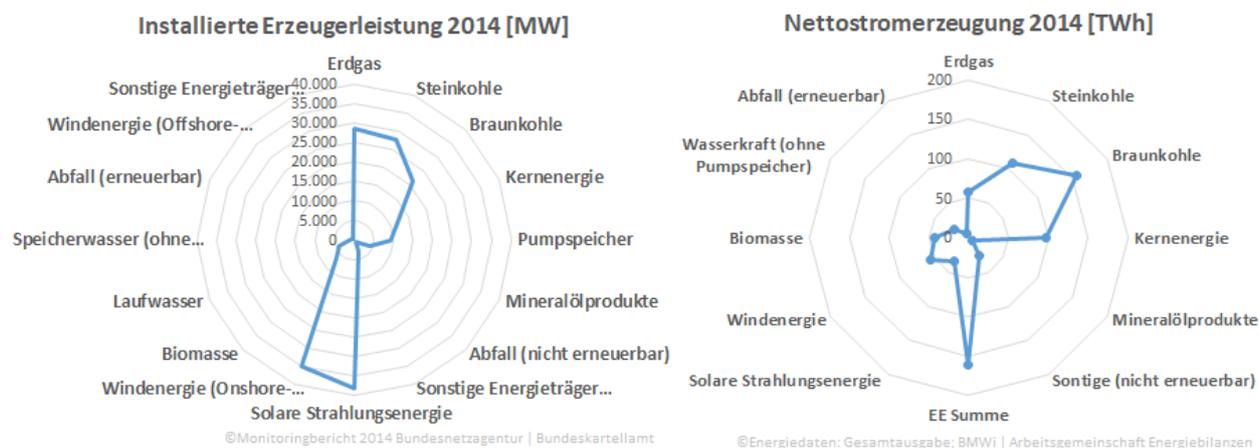


Abbildung 1.1: Visualisierung Statistiken für das Jahr 2014, [95, 41]

Das Szenario 2011 A der Leitstudie des BMU (Bundesamt für Umwelt, Naturschutz und Reaktorsicherheit) [145, S. 12-13] geht davon aus, dass perspektivisch im Jahr 2050 ca. 150 GW an Wind- und solarer Strahlungsenergie im deutschen Stromnetz installiert werden. Damit würde im Jahr 2050 über 50 % der installierten Kraftwerksbruttoleistung aus fluktuierenden Energieträgern bestehen. Andere Zukunftsszenarien [72, 189] gehen von einer 100 %'igen Stromversorgung durch EE im Jahr 2050 aus. Die Bundesregierung Deutschlands hat sich als konzeptionelles Ziel eine Bruttostromerzeugung von 80 % EE gesetzt, vgl. [42, S. 14].

In allen Szenarien werden Wind- und solare Strahlungsenergie eine immer größere Rolle im Energieversorgungssystem einnehmen. Da sie klimaabhängige, fluktuierende Energiequellen sind, stellen sie den Netzbetrieb vor neue Herausforderungen. Dieser Wandel der elektrischen Energieversorgung ist gekennzeichnet durch den Erhalt des Erzeuger-Last-Gleichgewichts. Das bedeutet, dass unter Berücksichtigung der Verluste im Stromübertragungsnetz der produzierte Strom den aktuellen Verbrauch deckt. Dieses Vorgehen ist aufgrund fehlender großer elektrischer Speichertechnologien notwendig. Durch die Zunahme der fluktuierenden Stromerzeugung nimmt die Anzahl der Systemstörungen zu, wenn Klimaänderungen und somit das Energiedargebot fehlerhaft prognostiziert wurden. In so einem Fall liegt eine Störung nach § 13 Abs. 1 EnWG (Energiewirtschaftsgesetz) vor, so dass der Netzbetreiber steuernd in das Energiesystem eingreifen muss. Das EnWG Gesetz ist besonders relevant für die erneuerbare Energieeinspeisung. Gemäß § 2 Satz 2 des EE Gesetzes (EEG) haben erneuerbare Energien einen Einspeisevorrang. In der Praxis bedeutet das, dass alle EE Anlagen in das Energienetz einspeisen können, ohne vorher die genaue Einspeisung anzumelden. Die konventionellen Kraftwerke dürfen das nur für angemeldete Fahrpläne, die am Vortag dem Netzbetreiber mitzuteilen sind. Mit den aktuell hohen installierten und wachsenden Leistungskapazitäten der EE nehmen die netzkritischen Situationen immer mehr zu. So wurden in einigen Netzabschnitten in Deutschland Zuwachsraten der Situationen nach § 13 Abs. 1 EnWG von mehr als 1.000 % oder Störungen von bis zu 1.727, 20 h im Jahr 2012 ermittelt, vgl. MONITORINGBERICHT 2012 [65, S. 55-60]. Im Jahr 2013 nahm die Anzahl der Maßnahmen insgesamt zu, vgl. MONITORINGBERICHT 2014 [95, S. 72-79]. Dem gegenüber werden Windleistungsprognosefehler von unter 5 % NRMSE (die normalisierte Wurzel des mittleren quadratischen Fehlers) für Gesamtdeutschland angegeben, vgl. [81, S. 25]. Das Verhalten lässt sich mit der Betrachtung der absolut installierten Menge von Windenergieleistung und deren Zuwachsraten begründen. Sie verursacht trotz sinkender relativer Fehlerzahlen größere absolute Fehler.

Mit der kontinuierlichen Zunahme der EE im Stromversorgungssystem verringert sich die installierte Leistung konventioneller Kraftwerke zunehmend, die regelnd gegenüber den fluktuierenden EE eingesetzt werden kann. Die anderen EE Kraftwerke können mit ihren installierten Leistungen nicht im gleichen Maße zugebaut werden, weil Ausbaupotentiale beschränkt sind oder sie in Konkurrenz zu anderen Ressourcen stehen, z.B. Biomasse mit Nahrungsanbau. Derzeit wird geplant, insgesamt 5.224 GW an konventioneller Kraftwerksleistung zurückzubauen, vgl. [95, S. 43]. Die Netzentwicklungsplanszenarien [73, S. 43] gehen in Abstimmung mit der Bundesnetzagentur von einer Leistungsreduzierung der installierten, konventionellen Kraftwerke von 107 GW in 2014 auf einen Bereich von 82 GW bis 85 GW für das Jahr 2024 aus. Gleichzeitig wird eine Jahresmaximallast von 84 GW angenommen. Weiterblickende Szenarien reduzieren die gesicherte Kraftwerksleistung soweit, dass diese durch Wind- und solare Strahlungsenergie nicht mehr ausgeglichen werden kann, vgl. mit erwarteten Stromerzeugungsmengen Abbildung 1.2.

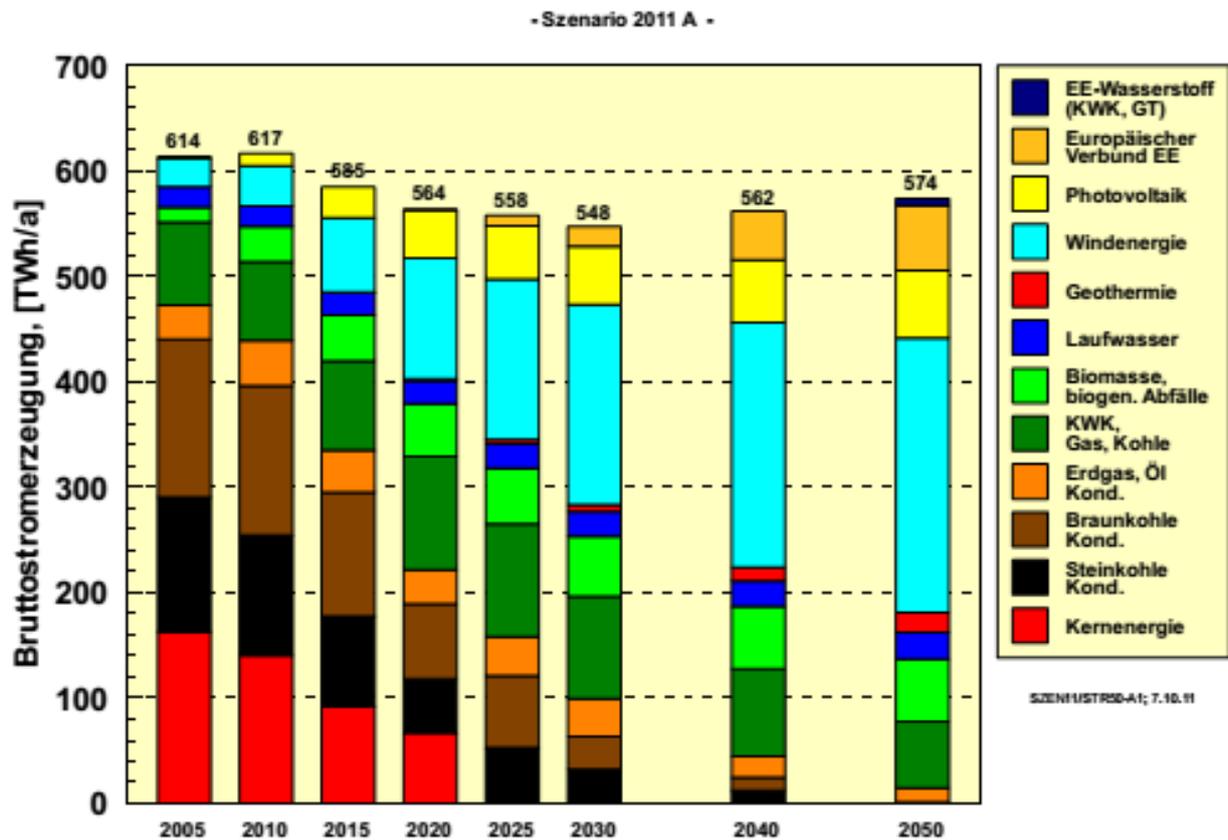


Abbildung 1.2: Szenario 2011 A der Leitstudie des BMU [145, S. 12]

Neben dem Zuwachs der installierten Leistungen wirkt sich auch der Standort der Windkraftanlagen auf die Netzstabilität aus. Konventionelle Kraftwerke wurden in der Nähe von Lastzentren errichtet, um Übertragungsnetzverluste möglichst klein zu halten. Windparks werden standortoptimiert und unter Berücksichtigung von lokalen und regionalen Regularien errichtet. Ein optimierter Standort für Windkraftanlagen zeichnet sich durch möglichst häufig hohe Windgeschwindigkeiten aus, die über das Jahr verteilt sind. Die Regularien bestimmen die Mindestabstände zu Wohnraum und umwelttechnischen Auflagen. Dadurch wird die Erzeugung von den Lastzentren immer weiter entfernt. Dem entsprechend müssen immer größere dezentrale EE Einspeisungen zu den Lastzentren transportiert werden. Dieser Sachverhalt und das immer kleiner werdende Verhältnis zwischen gesicherter und fluktuierender Energieerzeugung machen lokale Prognosen notwendig, die die Einspeisepunkte des Energienetzes berücksichtigen können. Damit ist das Ausnutzen von Ausgleichseffekten obsolet, in denen Regionen aggregiert betrachtet werden, vgl. [117].

Diese Arbeit konzentriert sich auf die lokale Windleistungsprognose. Dazu werden neben Messdaten der Leistungseinspeisung, Klimaprognosedaten des Deutschen Wetterdienstes (DWD) verwendet. Die Klimaprognosen stellen neben der Windgeschwindigkeit weitere Klimaparameter zur Verfügung. Damit bilden sie multivariate Datensätze, bei deren Analysen unter anderem Data Mining Verfahren zum Einsatz kommen werden. Der wissenschaftliche Beitrag der Arbeit zeigt sich in der Betrachtung der Windleistungsprognose als Data-Mining-Aufgabe, der Kombination unterschiedlicher statistischer Eigenschaften sowie der Einführung einer Kenngröße zur Bewertung des Güteanteils zwischen Datenanalyse und Prognose. Im Rahmen dieser Arbeit wurden die Arbeiten [20, 21, 19, 22, 18, 16] und [17] veröffentlicht.

Folgend wird im Abschnitt 1.2 der Stand der Wissenschaft und Technik und im Abschnitt 1.3 die Ziele dieser Arbeit erläutert. Anschließend werden die notwendigen Grundlagen im Kapitel 2 vorgestellt und die Anforderungen eines Windleistungsprognosesystems im Kapitel 2.3.3 ermittelt. Unter Berücksichtigung der Anforderungen wird die Modellierung im Kapitel 3 und die Softwareumsetzung im Kapitel 4 erläutert. Abschließend werden empirische Ergebnisse im Kapitel 5 inklusive deren Analysen vorgestellt und mit der Zusammenfassung im Kapitel 6 beendet.

1.2 Überblick über aktuelle wissenschaftliche Arbeiten

Zunächst werden die wissenschaftlichen Arbeiten der Literaturrecherche analysiert. Abschließend wird ein Überblick über kommerziell verfügbare Windleistungsprognosesysteme gegeben. Die Prognosesysteme werden in Anlehnung an [79] in drei Kategorien unterteilt:

- **Systemmodell:** Entspricht allen auf physikalischen Gesetzen beruhenden Berechnungsparametrierten Methoden,
- **Signalmodell:** Entspricht allen mit deterministischen oder statistischen Kennwerten parametrisierten Methoden und
- **Hybrid:** Entspricht allen Kombinationen aus Systemmodell und Signalmodell Berechnungsmethoden.

Weiterhin werden die Methoden entsprechend [136] ihrer zeitlichen Prognose- oder Horizontlänge untergliedert:

- **Ultra-Kurzzeit:** Entspricht Prognosehorizonten von 0 h bis zu einem Bereich von 4 h bis 6 h,
- **Kurzzeit:** Entspricht Prognosehorizonten in einem Bereich von 48 h bis 72 h und
- **Mittelzeit:** Entspricht Prognosehorizonten bis zu 7 d.

Entgegen der mathematisch üblichen Definition reeller Fehlerangaben in Bezug zum Ist-Wert wird in der Windleistungsprognose der relative Fehler häufig in Bezug zur installierten Leistung angegeben, vgl. 3.1. Einige Arbeiten geben relative Fehler in Bezug zur mittleren erzeugten Leistung über den gemessenen Zeitraum an. Diese Angabe ist nicht konstant und ändert sich in Abhängigkeit des gemessenen Zeitraums. Für die Vergleichbarkeit mit anderen Arbeiten werden in dieser Arbeit alle relativen Fehlermaße in Bezug zur installierten Leistung des jeweiligen Windparks angegeben. Sie entsprechen den vorgeschlagenen Definitionen in [128]. In den wissenschaftlichen Arbeiten werden häufig folgende Fehlermaße verwendet:

- **MRE:** Mittlere relative Fehler,
- **NMAE:** Normalisierte mittlere absolute Fehler,
- **MAPE:** Mittlere absolute prozentuale Fehler,
- **NMSE:** Normalisiert mittlere quadratische Fehler und
- **NRMSE:** Die Wurzel des normalisierten mittleren quadratischen Fehlers.

Das Ergebnis der Literaturrecherche wurde grafisch in den Abbildungen 1.3 und 1.4 ausgewertet und basiert auf den Analysen in Tabellen B.2 und B.3 im Anhang B. Zuerst werden die Arbeiten zur Windleistungsprognose hinsichtlich des Erscheinungsjahres und der eingesetzten Prognosemethodik in Abbildung 1.3 ausgewertet. Die Prognosemethodik wird unterschieden in:

- Signalmodelle:
 - Künstliche neuronale Netze (KNN),
 - Autoregressive Modelle der gleitenden Mittel inklusive Modifikationen (ARMAiM),
 - Fuzzy Modelle,
 - Neuro-Fuzzy Modelle,
- Systemmodelle basierend auf physikalischen Gesetzmäßigkeiten und
- Hybrid-Modelle.

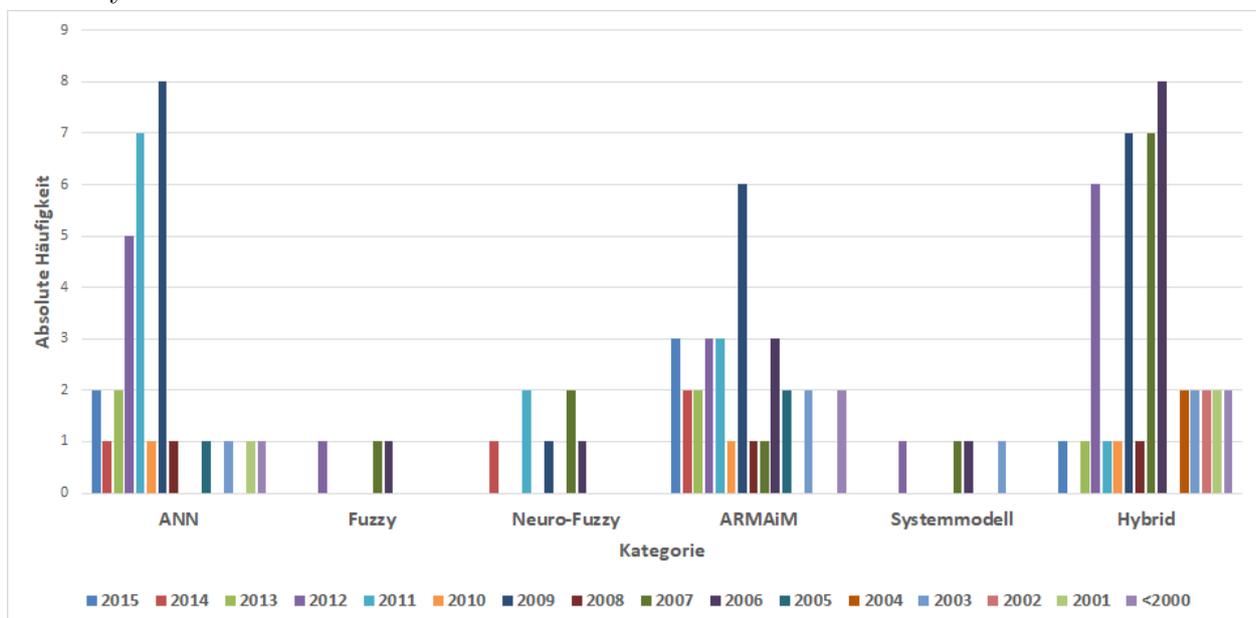


Abbildung 1.3: Grafische Auswertung der eingesetzten Methoden zur Windleistungsprognose

Die Arbeiten zur Windleistungsprognose und eigenständigen Windgeschwindigkeitsprognose werden in Abbildung 1.4 ausgewertet. Diese fasst die Klassen KNN, ARMAiM, Fuzzy und Neuro-Fuzzy Modelle zu Signalmodellen zusammen, weil sie auf einem stochastischen Prozessverhalten basieren und mit Hilfe statistischer Kennwerte parametrisiert werden können. Zusätzlich wird in Systemmodell und Hybrid-Modell unterschieden. Weiterhin wird die Datenbasis der Arbeiten untersucht, auf denen die Prognose beruht. Hier wird zwischen Messungen und Klimamodellen unterschieden. Die Windgeschwindigkeitsprognose wurde neben der Windleistungsprognose untersucht, weil sie mit der dritten Potenz die wichtigste exogene Einflussgröße der umgesetzten Windleistung ist, vgl. Formel (1.1). Die Rechercheergebnisse lassen sich nur bedingt miteinander vergleichen. Ursache ist das Fehlen eines einheitlichen Vergleichsmaßes. MADSEN et.al. hat ein Protokoll zur Standardisierung der Fehleranalyse in [128] vorgeschlagen. Dieses hat sich jedoch nicht als einheitlicher Standard durchgesetzt. Es berücksichtigt unter anderem die Fehlerdefinitionen der zuvor genannten Fehlermaße.

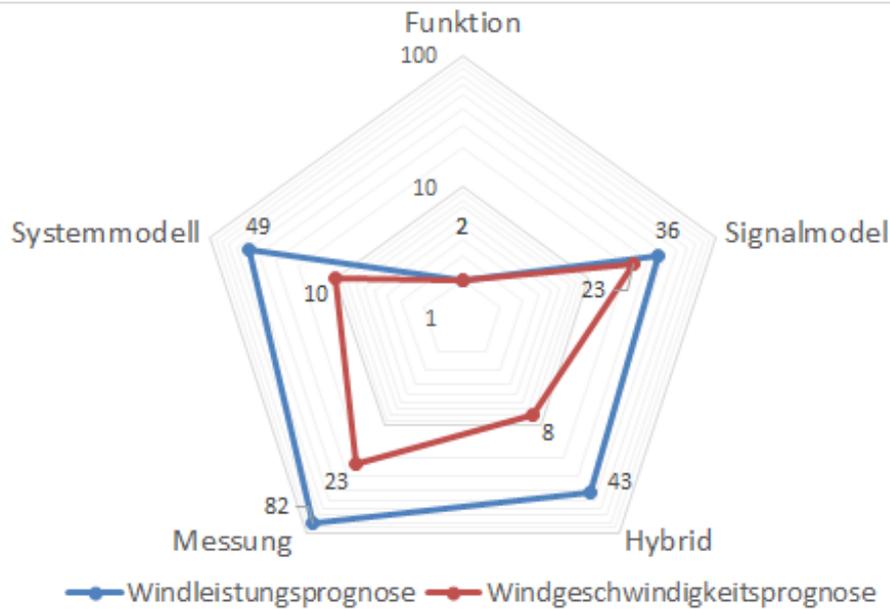


Abbildung 1.4: Auswertung der Arbeiten zur Windleistungs- und Windgeschwindigkeitsprognose

Folgend wird die Gleichung zur Berechnung der Windleistung [43, S. 45] vorgestellt. Diese und andere referenzierte Gleichungen wurden zum Zweck einer einheitlichen Syntax angepasst.

$$P_{el} = c_p \cdot \frac{1}{2} \cdot \rho \cdot v^3 \cdot A_{rot} \quad (1.1)$$

P_{el} ist die elektrische Leistung, c_p der Leistungsbeiwert, ρ die Luftdichte, v die Windgeschwindigkeit und A_{rot} die vom Rotor durchzogene Kreisfläche. Auf die Eigenschaften der Gleichung wird in Abschnitt 2.1 näher eingegangen.

Neben der eignen wurden weitere Literaturrecherchen in [78, 2012], [57, 2012], [193, 2011], [209, 2011], [81, 2011], [120, 2009], [136, 2009], [59, 2008], [115, 2008], [197, 2008], [79, 2003] und [112, 2003] veröffentlicht. In der Gesamtbetrachtung der Abbildung 1.4 wurden die Signalmodelle mit 59 Arbeiten am häufigsten untersucht. Bei der Betrachtung direkter Windleistungsprognoseansätze 1.3 ändert sich das Mehrheitsverhältnis zu Gunsten der hybriden Modelle mit 43 Arbeiten zu 36 Signalmodell-Ansätzen. Mit vier Arbeiten wurden die reine Systemmodelle am wenigsten untersucht. Die Analyse zeigt, dass rein stochastische Methoden im Ultra-Kurzzeitbereich eingesetzt werden. In den größeren Zeitbereichen dominieren vor allem die hybriden Modelle.

Zusammenfassend wird festgestellt, dass in der groben Struktur die Windleistungsprognose verschiedene Eingangsdatenquellen, bestehend aus SCADA-Systemen (Supervisory Control and Data Acquisition), nationalen bzw. kommerziellen Wetterdiensten und orographischen Daten, hat. Orographische Daten sind Bestandteil der Parametrierung der Klimamodelle. Diese werden u.a. durch das Bundesamt für Kartographie bereitgestellt. Die recherchierten Modelle prognostizieren entweder die Windleistung oder die Windgeschwindigkeit. Im letzteren Fall muss die Leistung über ein nachgelagertes Modell berechnet werden. Das erfolgt häufig durch die Anwendung der Gleichung (1.1) und der hinterlegten bzw. ermittelten

Leistungsbeiwertkurve der Windturbine oder eines Windparks.

Der Modellierungsprozess wird entsprechend Abbildung 1.5 unabhängig von Modellklassen für die Windleistungsprognose verallgemeinert. Jedes Modell $f(\hat{x})$ abstrahiert die Zusammenhänge eines Windparks $f(x)$ und abhängige Einflussgrößen $x_{1..n}$ werden bestimmt. Je nach Möglichkeit werden für das operative Modell die Einflussgrößen durch Prognosewerte $x_{1..m}$ einer oder mehrerer Klimaprognosen ergänzt oder ersetzt. Durch Auswertung der Residuen e werden die Modellparameter geschätzt. Es ist nicht möglich die Einflussgrößen bei allen Windparks zu messen. Daher stellt die Verwendung von Klimaprognosedaten den Regelfall dar. Diese Daten werden aus Wettermodellen gewonnen.

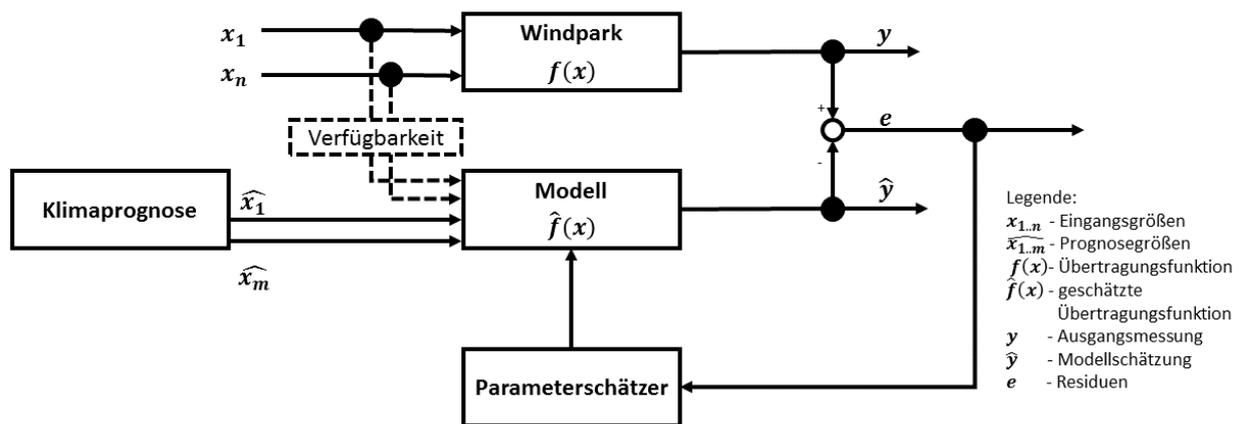


Abbildung 1.5: Allgemeine Prognoseprozessbildung

Von 115 Arbeiten beschäftigen sich fünf mit Data Mining Ansätzen, vgl. [203, 210, 82, 109, 110]. Überwiegend werden die Ansätze verwendet, um gemeinschaftliche Klassen für die musterbasierte Prognose [38] zu bilden. In einer Arbeit [110] wird Data Mining in der Form eingesetzt, dass relevante Eingangsgrößen aus der Datenbasis der NWP-Modelle (numerische Wetterprognose) verwendet werden. Unter Data Mining wird das Extrahieren von Informationen aus großen Datenbasen verstanden, vgl. [68, S. 3-4], [92, S. 1] und [101, S. XV]. NWP-Modelle abstrahieren die Prozesse der Atmosphäre, vgl. [146] und [114, S. 8-10], durch ein Referenzmodell, welches auf den dynamischen Vorgängen physikalischer und chemischer Gesetzmäßigkeiten basiert, vgl. [107]. Dabei werden auf ein Gitternetzmodell die komplexen Prozesse des Gasgemisches der Atmosphäre übertragen. Auf Grund der Größe und der Dynamik der Atmosphäre unterliegen die NWP-Modelle Einschränkungen in ihrer Abbildungsgenauigkeit, vgl. Abbildung 1.6. Die dargestellten NWP sind das COSMO-DE und COSMO-EU Modell des DWD. Ihre Auflösung inkl. der flächenmäßigen Modellgröße wurden skizziert. Für das COSMO-DE beträgt sie ca. 2,8 km und für das COSMO-EU ca. 7 km. Die kleinste Abtastzeit der verfügbaren Daten ist der Stundenmittelwert. Weiterhin wird deutlich, dass Effekte der Konvektion oder andere mesoskalige Prozesse, z.B. örtliche Windturbulenzen, unzureichend abgebildet werden. Aus dem Grund wurde frühzeitig eine statistische Nachbearbeitung, MOS (Model Output Statistic) genannt, der Modellergebnisse eingeführt, um Gitternetzvariablen auf in einem lokalen, geographischen Punkt zu korrigieren, vgl. [83].

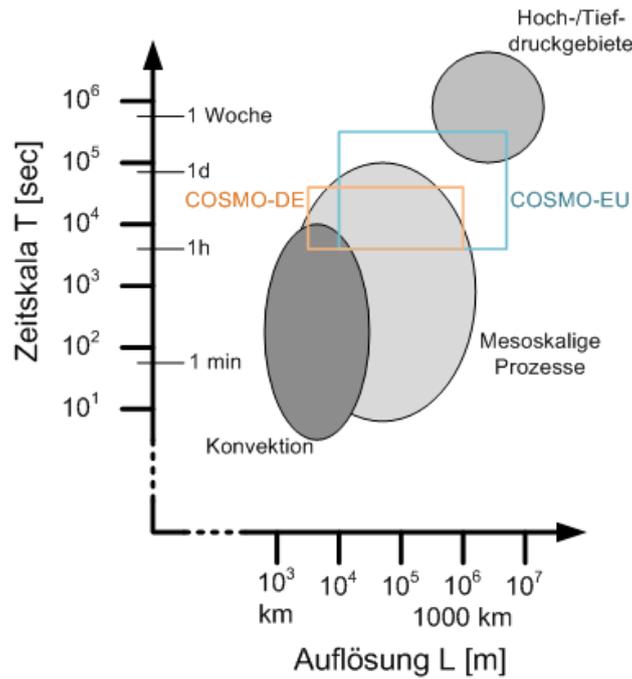


Abbildung 1.6: Erfassungsbereich und Ausdehnung der NWP Modelle des DWD [146] für die verwendeten Parameter mit Einflussbereich einiger physikalischer Phänomene

Alle hybriden Modelle können den MOS-Prozessen zugeordnet werden. Sowohl die MOS als auch die stochastischen Prozesse verwenden folgende Prognosemodelle:

- Parametrische stationäre Prozesse (PSP) [39, 195],
- Künstliche Neuronale Netze (KNN) [106],
- Support Vector Machines (SVM) [90] und
- Fuzzy Modelle [133].

PSP und KNN werden in der Literatur am häufigsten verwendet. In einigen Arbeiten werden neben den reinen Modellen auch kombinierte Modelle wie z.B. adaptive-network-based fuzzy inference system (ANFIS) [131] verwendet. In Kapitel 2 werden die für diese Arbeit relevanten Prognosemodelle näher vorgestellt.

In den recherchierten Arbeiten werden verschiedene Strategien zur Minimierung der Prognosefehler angewendet. Ein methodischer Ansatz kombiniert verschiedene Prognosemodelle, vgl. [70, 130, 169], aber auch die Eingangsdaten verschiedener Wettermodelle, vgl. [115, 142]. Die Kombination wird als Metaprognose bezeichnet. In diesem Fall werden die unterschiedlichen Klimaprognosen als berechnete Varianten des Klimas behandelt. Durch entsprechende Gewichtung können Fehler eines Modells durch andere ausgeglichen werden. Eine andere Methode modelliert die Prognose für ein Gebiet, vgl. [74, 75, 113, 36]. Dadurch gleichen sich lokale Fehler aus und minimieren den Gesamtfehler des Gebietes. Der Ausgleich erfolgt durch die Bestimmung des mittleren Summenverhaltens aller Windparks. Somit löschen sich Fehler einzelner Anlagen im Mittel aus. Der Nachteil ist jedoch, dass sie nicht die zugrundeliegende Energienetzarchitektur berücksichtigt, sondern indem sie das Energienetz als eine zusammenhängende Fläche anstatt als Übertragungsnetz betrachtet. Somit ist die Leistungsprognose nicht für den Einspeisepunkt im Energienetz angepasst, sondern wird abstrahiert zugeteilt.

Das könnte zur Folge haben, dass die Lastmengen fehlerhaft in einer Leistungsflussrechnung aufgeteilt werden und somit einen anderen Netzzustand darstellen.

Die Auswertung der Recherche zeigt, dass insbesondere für Folgetagsprozesse die Prognosen basierend auf Klimaprognosen unerlässlich sind. Gemäß der getroffenen Klassifizierung fallen alle diese Ansätze in die Klasse der hybriden Methoden. Gleichzeitig zeigen diese Prognoseansätze die besten Ergebnisse. Weitere Leistungssteigerungen wurden durch die Flächenmodelle erreicht. In den letzten Jahren wurde das Thema der probabilistischen Methoden vermehrt aufgegriffen. Dadurch konnten Prognosefehler besser berücksichtigt werden, in dem die Wertebereiche mit ihren Eintrittswahrscheinlichkeiten identifiziert werden. Die stärksten Ansätze dieser Methodik verwenden die Ensemble Prognosemethode.

Gegenüber dem recherchierten Stand der Wissenschaft wird diese Arbeit auf fünf neue Aspekte eingehen:

- Keine Literaturquelle beschäftigt sich mit dem Thema der Datenanalyse in der Form, dass sie eingesetzt wird, um aus den Klimaprognosen der Wetterdienste relevante Datensätze zu identifizieren. Die ermittelten Arbeiten, die sich mit dem Thema des Data Mining beschäftigen, identifizieren mit den eingesetzten Methoden keine Eingangsdatenbelegung von Prognosemodellen.
- Keine Literaturquelle beschäftigt sich mit der Frage, welche Datenanalysemethoden für die Prognosemodellbildung geeignet sind oder nicht.
- Es wurde in den Literaturquellen Hybridmodelle basierend aus der Kombination unterschiedlicher Klimaprognosesysteme oder Prognosesysteme vorgestellt. Keine Arbeit beschäftigte sich mit der Kombination von Datenanalysemethoden, um auf Basis derer Kombination Metaprognosen zu erstellen.
- Keine Literaturquelle prüfte ihre entwickelten Ansätze hinsichtlich der Übertragbarkeit auf andere Prognoseaufgaben, wie z.B. die Prognose der Leistungserzeugung von Photovoltaikanlagen.

Die aufgelisteten Punkte werden im Rahmen dieser Arbeit untersucht und Lösungsvorschläge präsentiert.

Verschiedenste Arbeiten geben einen Überblick über den aktuellen Stand der Wissenschaft, vgl. [79, 81, 136]. Diese informieren jedoch unzureichend über die Leistungsfähigkeit der vorgestellten Systeme. Zu diesem Zweck wurde anhand öffentlich verfügbarer Informationen eine Liste kommerzieller Windleistungsprognosesysteme erstellt, vgl. Tabelle 1.1. Anhand der angegebenen Fehlermaße wird ersichtlich, dass eine Vergleichbarkeit nur unzureichend möglich ist.

Tabelle 1.1: Leistungsübersicht kommerzieller Windleistungsprognosesysteme, Stand: 03.2011

Prognosesystem	Leistungsangabe {Horizont} (Fehlerart Jahr)	URL
Prediktor/ Zephyr	10% {24 h} (MAE k.A.)	http://www.prediktor.dk/ ; http://130.226.56.153/zephyr/publ.htm
Preventio	12 % {6 h} -17 % {36 h} (Unsicherheit 2003)	http://www.energiemeteorologie.de/projects/previento_em.html
LocalPred/RegioPred	2-2,7% {k.A.} (RMSE auf Windgeschwindigkeit 2005)	http://www.reoltec.net/recursos/CENER.pdf
WPPT	5,3% {day-a-head} (MAE 2008)	http://www.bpa.gov/corporate/business/innovation/docs/2008/BPA_California%20ISO%20ENFOR%20Presentation.pdf
Casandra	9; 9,8; 58,7; 12,6; 10 % für Klassen <-20; -20 - -10; -10 - 10; 10 - 20; >20 % {24-48h} (normalisierter Fehler 2003)	http://www.casandraenergy.com/pdf/Proceedings_EWEC03.pdf
AWPPS	2-5% {1 h} 8-10% {24 h} 10-15% {48 h} (normalisierte Windleistung 2004)	http://www-cenerg.cma.fr/prediction/
WPMS	2-3% {2 h} 5-7% {day-a-head} (RMSE 2008)	http://powwow.risoe.dk/publ/BLange_%28ISET%29-ExperiencesFrDevel0WindPow_ForecastsF6EuTSOs_BestPracticeSTP-2_2008.pdf
WEPROG	5,1-6,1% {? h} (RMSE 2009)	http://download.weprog.com/weprog_tech_doc_DEWEPS_200908.pdf
Sipreólico	4-24% {1-48 h} (Absolute Fehler/inst. Leistung 2007)	http://powwow.risoe.dk/publ/GGonzalez_%28REE%29-WindPowPredInSpanishSystemOp_BestPractice-2_2008.pdf
GH Forecaster	2-3,5 m/s {1-60h} (RMSE 2004)	http://www.2004ewec.info/files/23_1400_jeremyparkes_01.pdf
SOWIE	96% {day-a-head} (accuracy 2008)	http://www.windprognose.de/english/Loesungen/sowie.php#ergebnisse
eWind	8,28-10,73% {day-a-head} (MAE 2009)	http://www.uwig.org/WindForecastingbyTSOs.pdf
PowerSight	5-20% {1-48h} (MAE 2009)	http://www.3tier.com/static/ttcms/us/documents/publications/Energy_Central_Role_Wind_Forecasting.pdf
Precise Stream	2,5% {6h} (? 2008)	http://www.alternative-energy-news.info/press/market-value-wind-energy/

1.3 Ziele der Arbeit

Der Abschnitt 1.2 gab einen Überblick über die aktuellen Forschungen sowie angewandten Windleistungsprognosen. Anhand der Historie kann eine kontinuierliche Reduzierung der angegebenen Prognosefehler verzeichnet werden. Diese Angaben stehen im Widerspruch zu dem verzeichneten Anstieg der Netzbetreibereingriffe auf Übertragungs- und Verteilnetzebene, vgl. [65, 172]. Zu der genannten Reduzierung haben Untersuchungen diverser Prognosealgorithmen sowie die Ausnutzung von regionalen Ausgleichseffekten beigetragen. Dennoch ist in dem Monitoringbericht ein Anstieg der netzkritischen Situationen in 2012 und ein Verharren auf diesem Niveau zu verzeichnen, vgl. [65, 95].

Die recherchierten Arbeiten lassen eine Reihe von Fragen unbeantwortet. Es werden häufig entweder klimatische Messgrößen oder Prognosewerte aus NWP Modellen bzw. beides verwendet. Die Auswahl und Aufbereitung der geeigneten Parameter werden selten thematisch behandelt. Weiterführende Untersuchungen des Abstrahierungsfehlers der Wettermodelle in Bezug zur Windleistungsprognose werden unzureichend veröffentlicht. Die Wettermodelle für die Windleistungsprognose können als große zustandsbeschreibende Datenbanken betrachtet und mittels Data Mining Verfahren analysiert werden. Derzeit existieren wenige Data Mining Arbeiten im Zusammenhang mit dem Thema Windleistungsprognose, vgl. [82, 109, 155, 190]. Diese werden hauptsächlich eingesetzt, um die erforschten Ansätze zu analysieren und zu gruppieren. Anhand dieser offenen Punkte werden folgende Fragen gestellt, die in dieser Arbeit untersucht werden sollen:

1. Welche Methoden des Data Mining sind geeignet?
2. Welche Modellklassen eignen sich für diese Arbeit?
3. Mit welchen Mitteln kann eine optimale Prognose erreicht werden?
4. Inwiefern beeinflussen Fehler der vorgelagerten Klimaprognose die Windleistungsprognose?
5. Kann die zu entwickelnde Methodik auf andere Prognoseaufgaben übertragen werden?
6. Wie ordnet sich die Arbeit in den bestehenden Stand der Wissenschaft ein?

1. Welche Methoden des Data Mining sind geeignet?

Bisher wurden in wissenschaftlichen Arbeiten Data Mining Verfahren für die Wissensextraktion der Methoden verwendet. Data Mining Verfahren eignen sich besonders zur effizienten Analyse großer Datensätze, wie z.B. den Klimaprognoseergebnissen. Weiterhin beinhalten sie das Potential Methoden zu automatisieren. Geeignete Verfahren sind zu identifizieren und einzusetzen. Ziel ist es, die Methoden gezielt zu untersuchen und ihren Beitrag zur Verbesserung der Windleistungsprognose, zu prüfen.

2. Welche Modellklassen eignen sich für diese Arbeit?

Für Prognosen stehen eine Vielzahl unterschiedlicher Modellklassen, wie lineare und nicht-lineare stochastische Signalmodelle oder Systemmodelle, zur Auswahl. Für diese Arbeit

stehen Leistungsmessungen verschiedener Windparks und Klimaprognosen des DWD zur Verfügung. Unter Berücksichtigung dieser Informationen sowie zugänglicher Windkraftanlageninformationen ist eine geeignete Modellklasse zu wählen und gezielt geeignete Methoden zu untersuchen.

3. Mit welchen Mitteln kann eine optimale Prognose erreicht werden?

Klassische Modellbildungsverfahren nutzen diverse Berechnungsmethoden, um optimale Parameter für die Prognosemethode zu identifizieren. Nach dem Stand der Wissenschaft werden unter anderem Metaprognosen eingesetzt. Dabei werden Prognosen verschiedener Anbieter miteinander durch Folgemodelle verknüpft. Es ist zu untersuchen welche weiteren Möglichkeiten zur Verfügung stehen die optimale Prognosemethode zu identifizieren.

4. Inwiefern beeinflussen Fehler der vorgelagerten Klimaprognose die Windleistungsprognose?

Für Prognosen bis zu 48 h und mehr werden unter anderem exogene klimatische Größen wie die Windgeschwindigkeit benötigt. Diese Größen werden in NWP-Modellen berechnet und bilden ein abstrahiertes Modell der klimatischen Prozesse der Atmosphäre nach. Aufgrund der Abstraktionen können Fehler entstehen und somit die Aussagefähigkeit des Modells geschwächt werden. Daher ist es notwendig, als nachgelagertes Prognosesystem die Fehler des vorgelagerten Systems zu analysieren und wenn möglich im Folgeprozess zu korrigieren.

5. Kann die zu entwickelnde Methodik auf andere Prognoseaufgaben übertragen werden?

In der Energiewirtschaft gibt es noch andere Prozesse die von multiplen, exogenen Größen beeinflusst werden. Ein Beispiel ist die Prognose der Photovoltaikeinspeisung oder das Lastverhalten von Industriekomplexen. Die hier zu entwickelnden Methoden beschreiben ein algorithmisches Vorgehen. Dieses soll exemplarisch, anhand zur Verfügung stehender Datensätze geprüft werden, damit eine empirische Aussage über weitere Verwendungsmöglichkeiten getroffen werden kann.

6. Wie ordnet sich die Arbeit in den bestehenden Stand der Wissenschaft ein?

Der Innovationscharakter der Arbeit ist herauszuarbeiten und dem Stand der Wissenschaften gegenüberzustellen.

2 Grundlagen

Das Kapitel ist folgendermaßen strukturiert. Zuerst werden die physikalischen Zusammenhänge in Abschnitt 2.1 vorgestellt. Darauf aufbauend wird kompakt die numerische Wetterprognose in Abschnitt 2.2 erklärt. Anschließend werden in Abschnitt 2.3 die relevanten Grundlagen der Modellbildung eingeführt. Das Kapitel wird mit einer Anforderungsanalyse 2.3.3 abgeschlossen.

2.1 Physikalische Zusammenhänge

Die für die Windleistungsprognose grundlegenden Zusammenhänge lassen sich anhand der Formel für die Leistungsentnahme P_{el} darstellen. Diese wurde zum besseren Verständnis der Literaturrecherche in Abschnitt als Gleichung (1.1) eingeführt und hier nochmals aufgeführt:

$$P_{el} = c_p \cdot \frac{1}{2} \cdot \rho \cdot v^3 \cdot A_{rot} \quad (2.1)$$

P_{el} ist die elektrische Leistung, c_p der Leistungsbeiwert, ρ die Luftdichte, v die Windgeschwindigkeit und A_{rot} die vom Rotor durchzogene Kreisfläche. Für die folgenden Betrachtungen werden die Abhängigkeiten der Luftdichte berücksichtigt. Sie ist abhängig von der Lufttemperatur T , dem Luftdruck p und der Luftfeuchtigkeit ϕ , vgl. [3, S. 35 ff.]. Weiterhin ist der Leistungsbeiwert abhängig von der Windgeschwindigkeit und kann nach den Untersuchungen von Betz ein Maximum von 59 % erreichen. Die Windgeschwindigkeit hängt in ihrer Ausprägung von der Höhe über dem Erdboden ab, vgl. Grenzschichten [43, S. 160 ff.]. Als Grenzschicht wird die planetare Schicht der Atmosphäre bezeichnet. Sie ist unterteilt in mehrere Teilschichten, die die Reibungsverhältnisse zwischen Erdoberfläche und unbeeinflusster Atmosphäre berücksichtigt. Vereinfacht drückt sie aus, dass die Windgeschwindigkeiten von der freien Atmosphäre hin zur Erdoberfläche abnehmen und an der Erdoberfläche null m/s beträgt. Ein Umfassendes Zahlenbeispiel wird durch eine Sensitivitätsanalyse in Abschnitt 3.3.1 gegeben und ist in Abbildung 3.9 visualisiert.

Die klimatischen Größen der Windleistung (v, ρ, T, p und ϕ) werden durch Wetterstationen gemessen oder durch NWP Modelle prognostiziert. Das NWP stellt mit seiner Funktion die relevanten Klimagrößen zu prognostizieren ein vorgelagertes Prognosesystem dar, vgl. Abbildung 1.5.

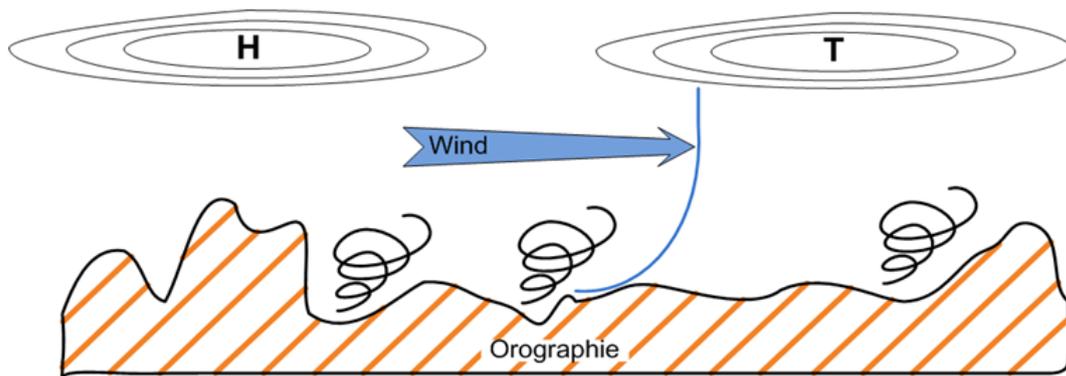


Abbildung 2.1: Grafische Darstellung der physikalischen Zusammenhänge

2.2 Numerische Wetterprognosemodelle

Numerische Wetterprognosemodelle werden seit 1950 eingesetzt, vgl. [107]. Aufgrund der zu berücksichtigenden atmosphärischen Zusammenhänge müssen für längerfristige Klimaprognosen immer größere Gebiete betrachtet werden, vgl. [24]. Die Abhängigkeiten werden unter anderem durch globale Hoch- und Tiefdruckgebiete beschrieben. Diese sind nicht stationär und beeinflussen durch ihre globale Bewegung das Wetter in Deutschland. Auf Grund ihrer Größe kann ihr Verhalten nur in globalen Modellen berücksichtigt werden. Für kürzere Prognosezeiträume ist die Bewegung nicht so stark und daher reichen kleinere Flächenmodelle für die Betrachtung aus. Folgende Flächenmodelle sind entsprechenden Prognosehorizonten zugeordnet:

- Eintagesprognose für Deutschland: Abbildung ganz Europas,
- Zwei- bis Viertagesprognose für Deutschland: Abbildung vom Nordpol bis Äquator und von den amerikanischen großen Seen bis Mittelasien und
- Fünf- bis Siebtagesprognose für Deutschland: Abbildung des globalen Wetters.

Dem Top Down Ansatz entsprechend werden die kleineren Modelle mit den Ergebnisdaten der übergeordneten Modelle als Randparameter ausgeführt. Beim DWD wurde die zeitliche Staffelung der Prognoseläufe entsprechend Abbildung 2.2 organisiert.

Zur Bestimmung der Abbildungsfähigkeit der Wettermodelle ist es notwendig, deren Abhängigkeit von Messdaten zu berücksichtigen. Wettermodelle werden durch stationäre Messungen, Ballonmessungen sowie Satellitenmessungen mit Ausgangsdaten befüllt, vgl. [23, 107, 24]. Die stationären Messungen sowie die Ballonmessungen können mehrere Klimaparameter direkt messen, z.B. Windgeschwindigkeit, Windrichtung oder Druck. Satelliten messen die direkte Strahlung im:

- Sichtbaren Spektrum,
- Infrarot Spektrum und
- Spektrum für Wasserdampfabsorption.

Aus diesen Messungen können neben Bildern, Vertikalprofile für Windgeschwindigkeit, Lufttemperatur und Luftfeuchtigkeit berechnet werden. Weitere Berechnungsgrößen sind unter anderem horizontale Windfelder, Oberflächentemperaturen, Niederschlagsindex.

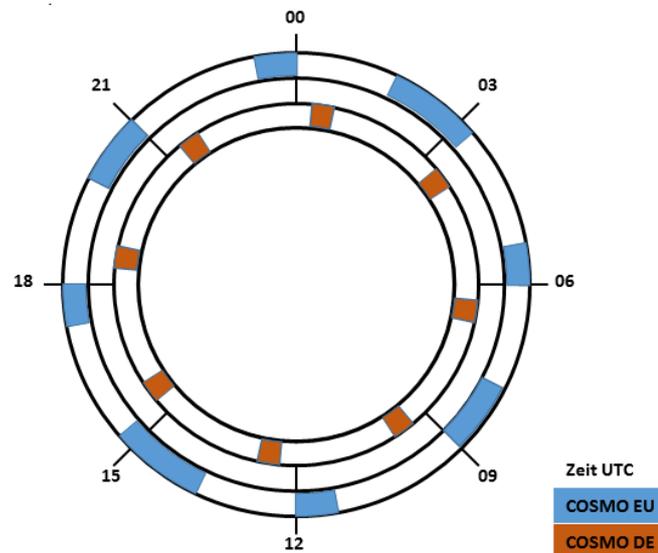


Abbildung 2.2: Schematische Skizze der Produktionszyklen der COSMO-DE (braun) und COSMO-EU (blau) Modelle: Darstellung der Produktionsläufe durch dunkle Felder; Quelle: DWD

Aufgrund der Messtechniken kommt es zu Einschränkungen in der Genauigkeit. So nehmen stationäre Messungen und Ballonmessungen punktuelle Beobachtungen auf. Satelliten hingegen können großflächige Messungen durchführen, die durch die Auflösung der Messtechnik eingeschränkt sind. Laut [107] wird eine Auflösung für den infraroten Bereich von vier bis acht Kilometer angegeben. Aufgrund dieser Mittelung können lokale Effekte schon bei der Messung nicht durch die Wettermodelle berücksichtigt werden. Die Wettermodelle unterliegen aufgrund ihrer Auflösung ebenso Einschränkungen in ihrer Abbildbarkeit. Dadurch ist die Größe der Raster bedingt, welche mit Längen von mehr als 20 Kilometern für Globalwettermodelle bis zu wenigen 100 Metern für Regionalmodelle, lokale Effekte nur bedingt abbilden können. Weitere Fehlerquellen sind Modellfehler, z.B. durch Runden der Naturkonstanten oder Berechnungsfehler, durch Runden der Berechnungsergebnisse, vgl. [23]. Die aufgezählten Fehlerquellen beeinflussen die Prognosequalität der Windleistungsprognose und müssen daher im Prozess, wenn möglich, berücksichtigt werden.

Für diese Arbeit werden Prognosedaten der Wettermodelle COSMO-EU und COSMO-DE des Deutschen Wetterdienstes (DWD) verwendet. Das COSMO-DE hatte im Zeitraum der Bearbeitung eine Auflösung von 2,8 km mit einem Prognosehorizont von bis zu 21 h und das COSMO-EU 7,0 km mit bis zu 78 h. Beide Modelle werden alle drei Stunden versetzt gestartet, entsprechend der Skizze in Abbildung 2.2. Das EU-Modell hat dabei nicht gleichlange Prognosehorizonte. Alle 12 h wird eine 78 h Prognose, alle 6 h eine 48 h und alle 3 h eine 24 h Prognose durchgeführt. Historische Prognosedaten werden für die Validierungsrechnungen über das PAMORE-Webinterface aus der Datenbank des DWD heruntergeladen.

2.3 Modellbildungsprozess

Der Modellbildungsprozess für Regelungen und Prognosen wird in seinen prinzipiellen Komponenten durch BOX-JENKINS in [33, S. 16-18] definiert. Dieser besteht aus den in Abbildung 2.3 dargestellten iterativen vier Teilprozessen:

1. Dem Postulat der Modellklasse,
2. Der Modellidentifikation,
3. Der Parameterschätzung und
4. Der Validierung.

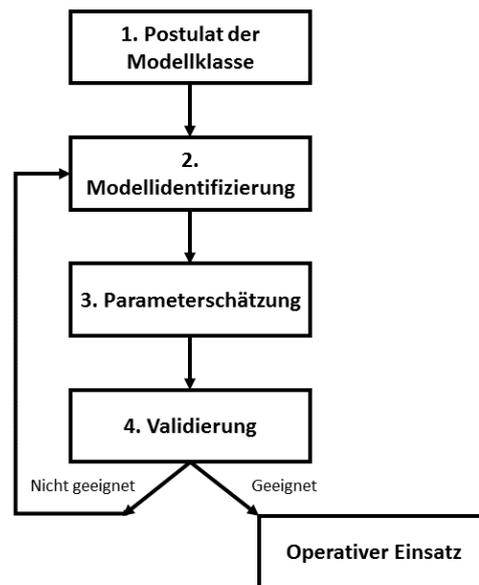


Abbildung 2.3: Modellbildungsprozess nach BOX-JENKINS in [33, S. 17]

Zuerst wird auf Basis von theoretischen Betrachtungen und Erfahrungswissen eine Modellklasse ausgewählt. Zweitens wird mit Hilfe von Datenanalyseverfahren ein geeignetes Modell identifiziert. Vorgegeben durch die Methode werden anschließend die abhängigen Parameter geschätzt. Im Validierungsschritt wird über die Eignung des Modells befunden. Wird ein Modell als nicht geeignet befunden, muss ein neues Modell bestimmt werden. Entsprechend sind die nachfolgenden Abschnitte gegliedert. Folgend wird ein grober Überblick über die möglichen Modellklassen gegeben. Die Parameterschätzverfahren sind abhängig von dem berücksichtigten Modell und werden daher nicht in den Grundlagen aufgeführt. Die Auswahl der eingesetzten Validierungsmethoden werden im Kontext der Arbeit in Abschnitt Evaluierung 3.1 berücksichtigt.

Für die Untersuchungen in dieser Arbeit sind zwei allgemeine Modellklassen relevant: die Systemmodelle und die stochastischen Signalmodelle. Sie werden in Abbildung 2.4 systematisiert. Die Auswahl, welche Modelle als relevant betrachtet werden oder nicht, basiert auf den Rechercheergebnissen in Abschnitt 1.2. Aufgrund der Vielfalt an Modellen erhebt die Abbildung keinen Anspruch auf Vollständigkeit. Für diese Arbeit ist die Systematik der Kategorien von Bedeutung.

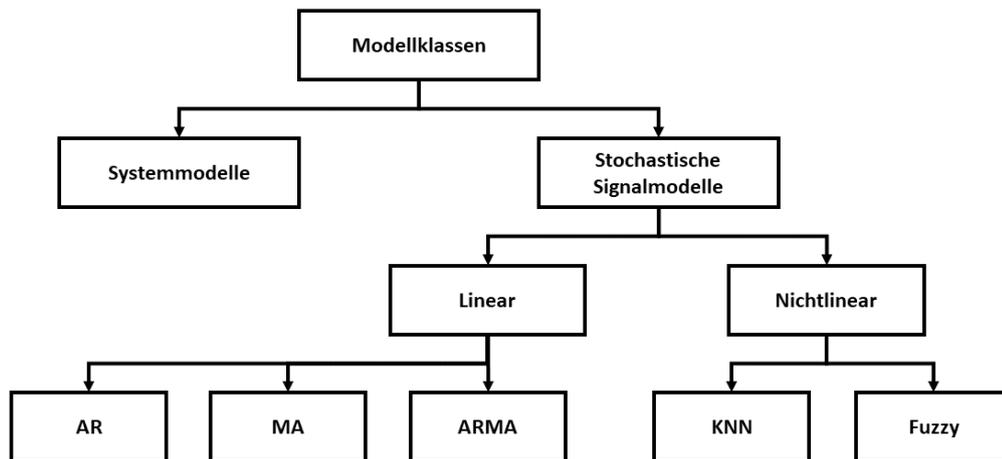


Abbildung 2.4: Ausschnitt relevanter Modellklassen

Systemmodelle drücken die Zusammenhänge eines Prozesses über physikalische oder auch chemische Gesetzmäßigkeiten aus und können mit Hilfe von mathematischen Funktionen beschrieben werden. Daher werden diese Modelle zu meist iterativ berechnet und können von einem gemessenen Ausgangspunkt theoretisch beliebig weit in die Zukunft berechnet werden. Unter Berücksichtigung von zunehmenden Unsicherheiten und abnehmender Prognosequalität werden die Prognosen nach einem bestimmten Prognosehorizont abgebrochen, wenn die Prognosequalität nicht mehr verwertbar ist. Iterativ bedeutet in diesem Kontext, dass Prognoseergebnisse eines Horizonts auf den Ergebnissen des Vorgängers basieren. Ihre Güte richtet sich nach der Genauigkeit und Vollständigkeit der berücksichtigten Funktionalitäten. Eine rekursive Berechnung findet in der Regel nicht statt.

Stochastische Modelle abstrahieren beobachtete Prozesse auf einen Satz bekannter Funktionen und passen diese an den beobachteten Prozess an. Für den Auswahl- sowie den Anpassungsprozess werden gemessene Prozessdaten benötigt. Sie lassen sich in die Unterkategorien linear und nichtlinear unterteilen. In Abbildung 2.4 sind einige konkrete Beispiele dafür aufgelistet.

2.3.1 Lineare stochastische Signalmodelle

Diese Modellkategorie, vgl. [195, 171, 108, 39], beschreibt den inneren linearen Zusammenhang zwischen Signalen. In der Regressionsanalyse wird durch die Messwerte x eine Gerade gelegt, die mittels der Parameter a_0 und a_1 angepasst wird. Für den Prognoseprozess wird der Folgewert der letzten Messung auf der Geraden geschätzt. Nichtlinearitäten werden durch die Identifizierung geeigneter Transformationsfunktionen berücksichtigt. Kann keine geeignete Funktion identifiziert werden, können Nichtlinearitäten nicht abgebildet werden. Formen der

stochastischen Signalmodelle sind unter anderem, vgl. [38, S. 11-12]:

$$\text{AR: } \hat{x}(k) = \sum_{i=1}^p (\alpha_i * x(k-i)) + \epsilon(k), \quad (2.2)$$

$$\text{MA: } \hat{x}(k) = \epsilon(k) + \sum_{i=1}^q (\beta_i * \epsilon(k-i)), \quad (2.3)$$

$$\text{ARX: } \hat{x}(k) = \sum_{i=1}^p (\alpha_i * x(k-i)) + \epsilon(k) + \sum_{i=1}^b (\gamma_i * u(k-i)), \quad (2.4)$$

$$\text{ARMA: } \hat{x}(k) = \sum_{i=1}^p (\alpha_i * x(k-i)) + \epsilon(k) + \sum_{i=1}^q (\beta_i * \epsilon(k-i)) \text{ und} \quad (2.5)$$

$$\text{ARIMA: } \hat{x}(k) = \sum_{i=1}^p (\alpha_i * \nabla^d x(k-i)) + \epsilon(k) + \sum_{i=1}^q (\beta_i * \epsilon(k-i)). \quad (2.6)$$

ARIMA steht für *AR* Auto-Regression, *I* integriert und *MA* gleitendes Mittel. *ARX* bedeutet Auto-Regression mit exogenen Größen. Der Schätzwert wird durch \hat{x} beschrieben, der Messwert durch x , α als AR-Parameter und γ als X-Parameter der exogenen Größen. Das Prozessrauschen wird durch ϵ gekennzeichnet. Es wird auch weißes Rauschen genannt und ist normal verteilt. Die MA Parameter werden durch β bestimmt, die exogenen Messgrößen durch u , deren AR-Parameter durch α und den Integrationsparameter durch ∇ . p , q , b und d sind die Ordnungen der jeweiligen Modellbestandteile. Die Parameter der Modelle werden in der Regel mit der „Methode der kleinsten Quadrate“ bestimmt, vgl. [171, S. 503] bzw. [125, S. 204].

2.3.2 Nichtlineare stochastische Signalmodelle

Nichtlineare stochastische Signalmodelle können zum einen durch die linearen Signalmodelle beschrieben werden. Dazu ist es erforderlich, dass das nichtlineare Übertragungsverhalten zwischen den Eingangs- und den Ausgangsdaten identifiziert werden kann. Anschließend werden mit Hilfe der nichtlinearen Funktion die Eingangsdaten transformiert. Zuletzt wird ein lineares stochastisches Signalmodell auf die transformierten Daten angewandt. Die Bestimmung der Nichtlinearität ist nicht immer gegeben. Zum anderen können nichtlineare Modelle wie die Künstliche Neuronale Netze (KNN) oder Fuzzy Modelle verwendet werden. Laut Literaturrecherche im Abschnitt 1.2 spielen Fuzzy Modelle eine untergeordnete Rolle. Fuzzy Modelle beschreiben mit linguistischen Variablen ein unscharfes Regelwerk und können somit nichtlineare Zusammenhänge erfassen.

Mit den KNN wird versucht das Arbeitsprinzip des biologischen Nervensystems nachzubilden [45, 106, 12]. In diesem haben Nervenzellen ein oder mehrere Eingänge und einen Ausgang. Eingehende Informationen werden verarbeitet und deren Ergebnis weitergeleitet. Dementsprechend sind die Neuronen der KNN aufgebaut. Sie können eine beliebige Anzahl von Eingängen haben, transformieren die summierten Eingangswerte mit Hilfe einer Übertragungsfunktion und leiten das Ergebnis weiter. Die Neuronen können beliebig miteinander verbunden

werden. In der beschriebenen Arbeitsweise wird gezeigt, dass die KNN den statistischen Zusammenhang erlernen. Im Ergebnis erhält man eine Näherungsfunktion. In Bezug auf die nichtlinearen stochastischen Signalmodelle bedeutet es, dass entweder das Gesamtverhalten des entsprechenden Modells mit Hilfe eines KNN angenähert werden kann oder dass die jeweiligen Einzelkomponenten eines jeweiligen Modells entsprechend durch KNN abgebildet werden.

KNN unterscheidet man nach [12, S. 151ff] in total verbundene KNN und in hierarchische KNN, vgl. Abbildung 2.5. In dem total verbundenen KNN sind alle Neuronen untereinander, sowie mit sich selbst verbunden. Hier gibt es keine klar definierten Ein- und Ausgänge. Vielmehr können sie beliebig gesetzt werden. Die hierarchischen KNN unterscheiden sich in nicht rekursive KNN, rekursive KNN und KNN mit einer latenten Hemmung.

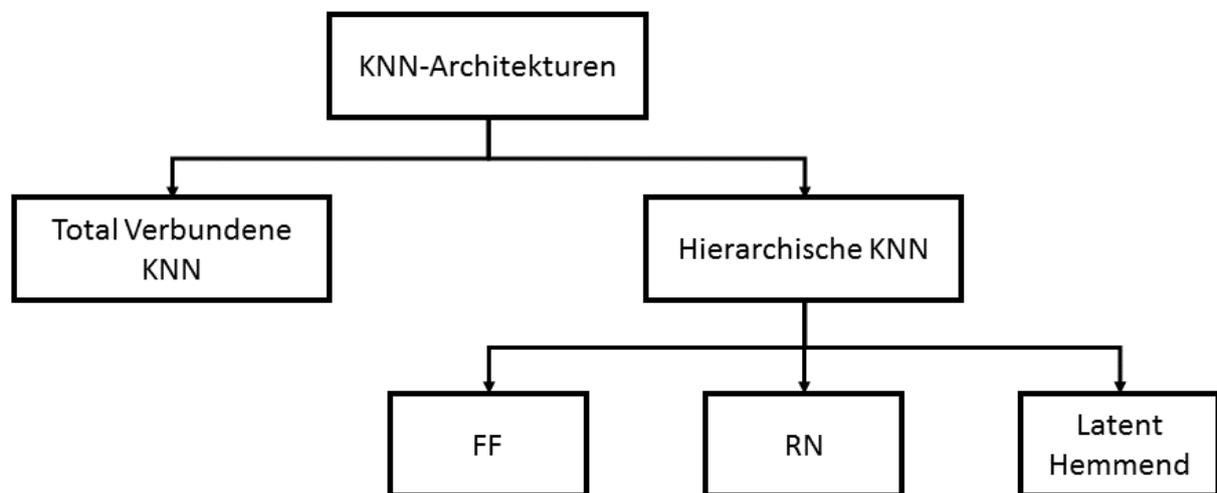


Abbildung 2.5: Übersicht der KNN Architekturen

Hierarchische KNN besitzen einen definierten Informationsfluss von der Eingangsschicht zur Ausgangsschicht, vgl. Abbildung 2.6. Die Eingangsschicht (Input Layer IL) verknüpft die Eingangsdaten, die Ausgangsschicht (Output Layer OL) gibt die Ergebnisdaten aus. Die dazwischenliegenden werden versteckte Schichten (Hidden Layer HL) genannt. Nicht rekursive KNN werden auch als Feed Forward (FF) bezeichnet. Sie verarbeiten die Information streng vorwärts gerichtet. Rekursive Netze (RN) können den Ausgang eines Neurons an sich selbst oder auf vorgelagerte Schichten zurückführen. Dabei verwenden sie ein Zeitverzögerungsglied der Ordnung $n \in \mathbb{N}$. Diese ist im Modellierungsprozess zu ermitteln. Es können äußere, d.h. vom Ausgang zum Eingang, oder innere Rückkopplungen, d.h. Neuronenausgang zum -eingang, eingesetzt werden. In latent hemmenden Netzen sind die Neuronen einer Schicht untereinander verbunden.

Die Funktion für die Transformation wird auch Aktivierungsfunktion oder Transferfunktion genannt. Als Transferfunktionen können die unterschiedlichsten Funktionen eingesetzt werden. Deren Auswahl richtet sich nach dem Prozess, der nachgebildet werden soll. Relevante

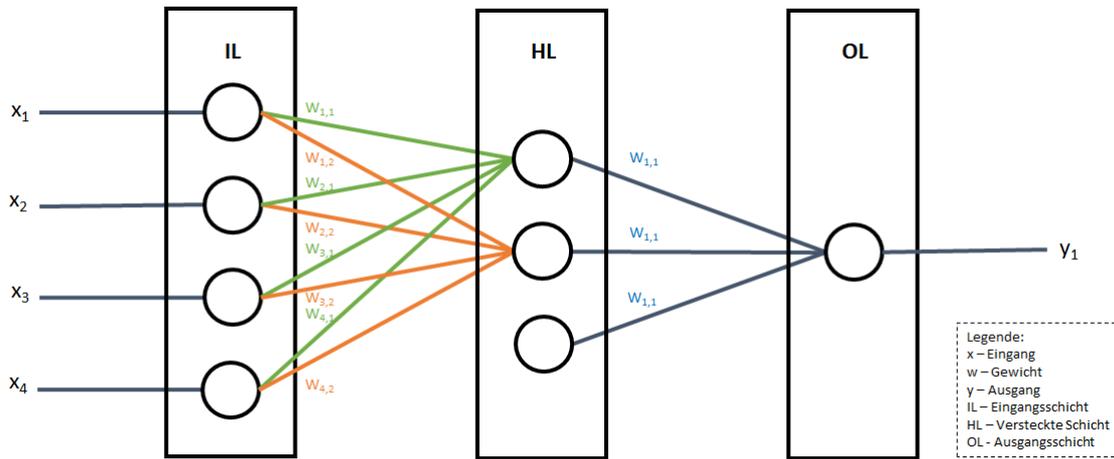


Abbildung 2.6: Vernetzungsprinzip eines Feed Forward Netzes

Funktionen sind [64]:

$$\text{die Linearfunktion: } f(x) = x, \quad (2.7)$$

$$\text{die Sigmoidfunktion: } f(x) = \frac{1}{1 + e^{-x}}, \quad (2.8)$$

$$\text{die hyperbolische Tangens Funktion: } f(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \text{ und} \quad (2.9)$$

$$\text{die hyperbolische Tangens Sigmoidfunktion: } f(x) = \frac{2}{1 + e^{-2x}} - 1. \quad (2.10)$$

Anhand der Abbildung 2.6 und zuvor aufgeführten Übertragungsfunktionen wird folgend Berechnung an einem Neuron dargestellt. Es wird das erste Neuron in der versteckten Schicht beschrieben. Es gilt das allgemeine Übertragungsverhalten des Eingang x_{11} zum Ausgang y_{11} :

$$y_{11} = f(x_{11}). \quad (2.11)$$

Der Eingang x_{11} ist die Summe aus den Einzelprodukten eines jeweiligen Ausgängen der Eingangsschicht x_i und deren Gewichten w_{1i} :

$$x_{11} = \sum_{i=1}^4 w_{1i} x_i. \quad (2.12)$$

Wird als Übertragungsfunktion z.B. die Linearfunktion mit $f(x) = x$ verwendet, erhält man folgendes Übertragungsverhalten:

$$y_{11} = \sum_{i=1}^4 w_{1i} x_i. \quad (2.13)$$

Durch unterschiedliche Trainingsmethoden werden die Übertragungsgewichte w bestimmt und somit die allgemeine Gleichung an ein bestimmtes Problem angepasst.

KNN sind mit einem Trainingsdatensatz anzulernen. Für das Training gibt es zwei Vorgehensweisen: überwachtes und nicht überwachtes Lernen. Das nicht überwachte Lernen wird

nicht weiter betrachtet. Die Trainingsalgorithmen des überwachten Lernens basieren auf Gaus-Newton- oder auf Evolutionsverfahren. Folgend werden zwei ausgewählte Verfahren kurz vorgestellt:

- Resilient Propagation (PROP): Der PROP-Algorithmus ist eine Erweiterung des Gradientenverfahrens, in dem er die Vorzeichenänderung überwacht und wie in [161, S. 587] beschrieben die Gewichtsänderung anpasst wird.
- Levenberg-Marquardt (LM): Der LM-Algorithmus basiert auf der Minimierung des quadratischen Fehlers nichtlinearer Funktionen und der Anpassung des Gaus-Newton Verfahrens:

$$\Delta x = \left[J^T(x) J(x) \right]^{-1} J^T(x) e(x) \quad (2.14)$$

und wird durch:

$$\Delta x = \left[J^T(x) J(x) + \mu I \right]^{-1} J^T(x) e(x) \quad (2.15)$$

[89, S. 990] erweitert. J ist die Jacobi Matrix und I die Identitätsmatrix. μ wird in Abhängigkeit des Quadratischen Fehlers angepasst.

KNN sind auf Grund ihrer Modularen Komponenten stark flexibel in der Modellierung und lassen so eine Vielzahl von Varianten zu. Für die Modellierung gibt es folgende, einschränkende Regeln:

- Das EXISTENZTHEOREM VON KOLMOGOROV [152, S. 42] besagt, dass jede kontinuierliche Funktion mit n Variablen durch die Summation von linearen und nichtlinearen Funktionen berechnet werden kann. Jede kontinuierliche Funktion mit n Variablen kann durch ein dreischichtiges Perzeptronnetz mit $n(2n + 1)$ Neuronen beschrieben werden.
- Nach Aussage von LAPEDES und FARBER [152, S. 42-43] kann jeder reell wertige Datensatz mit nicht mehr als zwei versteckten Schichten berechnet werden. Dabei wird die Genauigkeit durch die Anzahl der Neuronen je Schicht kontrolliert.

2.3.3 Anforderungsanalyse

Entsprechend der Forschungsfragen im Abschnitt 1.3 ist eine Prognose für die lokale Windleistungseinspeisung zu entwickeln. Für die Bearbeitung stehen drei Modellklassen zur Verfügung: System-, stochastische oder hybride Modelle, vgl. Abschnitt 1.2. In Tabelle 2.1 werden die Vor- und Nachteile zwischen System- und stochastischen Modellen gegenübergestellt. Die Hybridmodelle versuchen die Stärken der anderen Modelle zu verbinden.

Tabelle 2.1: Eigenschaftstabelle zwischen System- und stochastischen Modellen

Systemmodelle	
Pro	Contra
- Keine historischen Daten notwendig	- Genaue Kenntnis über funktionale Vorgänge
- Beschriebenes systematisches Verhalten	- Funktionen müssen mathematisch beschreibbar sein
	- Z.T. komplexe analytische Formeln notwendig
Stochastische Modelle	
Pro	Contra
- Genaue Kenntnis der Prozesse ist nicht notwendig	- Historische Datenbasis zum Anlernen notwendig
- Definierte Prozessgleichungen	- Datenbasis muss Verhalten möglichst gut abbilden
	- Parametrierung erfordert z.T. Expertenkenntnisse

Für eine Modellierung eines Systemmodells liegen nicht ausreichende Informationen vor. Zu diesem Zweck müssten alle Informationen eines Windparks zur Verfügung stehen, wie z.B. Regelalgorithmen für das Ansteuern der Windkraftanlagen im Wind. Das so erhaltene Modell ist speziell auf einen Windpark ausgelegt und muss für jeden neuen Windpark zu großen Teilen neu ermittelt werden. Aus diesem Grund werden in der Betrachtung die stochastischen Signalmodelle in dieser Arbeit berücksichtigt.

Die Literaturanalyse im Abschnitt 1.2 zeigt, dass bisherige Arbeiten zur Prognose längerer Zeiträume Klimaprognosen verwenden. Die Einbindung von Klimaprognosen ist zu berücksichtigen. Weiterhin wird aus Abschnitt 2.2 deutlich, dass NWP aufgrund des Aufbaus, sowie der Messwerterhebung vielfältige Fehlerquellen beinhalten. Die Fehler der vorgelagerten Klimaprognose sind zu analysieren und in der Windleistungsprognose zu berücksichtigen. Des Weiteren sind verfügbare Messdaten von umliegenden Wetterstationen zu berücksichtigen. Die Messungen können einen stärkeren funktionalen Zusammenhang zur Windleistungseinspeisung haben als die Klimaprognosewerte, wenn der Fehler des NWP diesen zu sehr schwächt. Diesen Zusammenhang gilt es zu prüfen.

Aufgrund der Vorüberlegungen werden rein funktionale Modelle ausgeschlossen. Es können jedoch dynamische technische Parameter, wie z.B. der Leistungsbeiwert anhand von Windkraftanlagentyp und Windgeschwindigkeit, berechnet werden. Es ist zu untersuchen ob diese einen Beitrag für die stochastischen Signalmodelle liefern können oder nicht.

Durch die Berücksichtigung von Klimaprognosen und berechneter technischer Parameter stehen viele mögliche exogene Einflussgrößen für die Prognoseprozesse zur Verfügung. Entsprechend sind Data Mining Verfahren zu untersuchen, geeignete auszuwählen und in die Prognose zu integrieren. Die Data Mining Analysen sind wenn notwendig zu automatisieren.

Anhand Gleichung (1.1) ist ersichtlich, dass die Windleistungserzeugung einen nichtlinearen Zusammenhang gegenüber seinen exogenen Einflussgrößen hat. Bei Verwendung exogener Größen ist dieses Übertragungsverhalten durch die Prognose abzubilden.

Gemäß der Vergleichbarkeit sind Fehlermaße entsprechend der Vorschläge in [128] einzusetzen. Diese sind mit einem Validierungskonzept zu verknüpfen welches die Modellansätze entsprechend dem BOX-JENKINS Verfahren in Abschnitt 2.3 validiert und auf seine Einsatzfähigkeit prüft.

3 Modellierung

Dieses Kapitel stellt die Modellierung der Prognosemethodik im Sinne der Arbeitsmethodik nach Box-Jenkins, vgl. Abbildung 2.3. Der Aufbau des Kapitels ist wie folgt strukturiert. Im ersten Abschnitt 3.1 werden die Evaluierungskriterien erläutert, das Postulat eines Prognose-Hilfsmodells vorgestellt sowie notwendige Analyseverfahren eingeführt. Der zweite Abschnitt 3.2 erklärt die experimentellen Randbedingungen der gesamten restlichen Arbeit. Der dritte Abschnitt 3.3 behandelt das Thema der Datenanalyse. Gemäß Box-Jenkins wird sie für die Modellidentifizierung benötigt. Dazu werden die Analyseverfahren aus Abschnitt 3.1 verwendet. Abschließend wird im vierten Abschnitt 3.4 das Thema der Prognosemodellierung behandelt. Dieses stellt unterschiedliche Prognosemodelle vor und bewertet diese anhand der Evaluierungskriterien aus Abschnitt 3.1. In diesem Kapitel werden insgesamt 26 Experimente durchgeführt. Im Anhang A befindet sich eine Übersicht der durchgeführten Experimente.

3.1 Deklarationen für die Validierung

3.1.1 Evaluierungskriterien

Für die Evaluierung werden folgende, von MADSEN [128] eingeführte Fehlermaße verwendet. Ihre Gleichungen werden in Tabelle 3.1 präsentiert:

- NMAE: den normalisierten mittleren absoluten Fehler und
- NRMSE: die normalisierte Wurzel des mittleren quadratischen Fehlers.

Die von MADSEN vorgeschlagenen Definitionen werden der mathematischen gegenübergestellt. Die mathematischen Definitionen finden üblicherweise ihre Anwendung in der Energiewirtschaft. Wichtigster Unterschied in beiden Definitionen ist die verwendete Normierungsgröße. In der mathematischen Definition wird die Normierung immer zum gemessenen Istwert durchgeführt und in den meisten recherchierten Arbeiten zur Windleistungsprognose wird die installierte Leistung verwendet. Andere Arbeiten verwenden den mittleren Leistungswert eines bestimmten Zeitraums. Diese Arbeit verwendet als Referenz die installierte Leistung. Dadurch wird die mathematische Unstetigkeit bei einer Messung von 0 Watt in der Einspeiseleistung vermieden.

Windparks werden nicht direkt miteinander verglichen. Sie unterliegen lokalen Gegebenheiten, wie z.B. der Orographie. Daher werden Prognosen individuell aber nicht vergleichend mit unterschiedlichen Windparks durchgeführt. Um Verbesserungen der methodischen Modellierung

Tabelle 3.1: Eingesetzte Fehlermaßdefinitionen, entsprechend [128]

Mathematische Definition	Fehlermaß	Angewandte Definition
$1/N \sum_{i=1}^N P_{i,ist} - \hat{P}_i / P_{i,ist}$	$NMAE$	$1/N \sum_{i=1}^N P_{i,ist} - \hat{P}_i / P_{el,inst}$
$\sqrt{1/N \sum_{i=1}^N (P_{i,ist} - \hat{P}_i)^2 / P_{i,ist}}$	$NRMSE$	$\sqrt{1/N \sum_{i=1}^N (P_{i,ist} - \hat{P}_i)^2 / P_{el,inst}}$

messen zu können, wird die Verbesserung $Imp_{\gamma}^{ref}(k)$ nach [128] bzw. [78] verwendet:

$$Imp_{\gamma}^{ref}(k) = \frac{\gamma^{ref}(k) - \gamma(k)}{\gamma^{ref}(k)}. \quad (3.1)$$

$\gamma^{ref}(k)$ sind die Fehlerwerte der Referenzmethode und $\gamma(k)$ die Fehlerwerte der zu evaluierenden Methode.

3.1.2 Hilfsmodell

Im Abschnitt 3.3 werden mit Hilfe von Datenanalysemethoden sowohl charakteristische Eigenschaften als auch relevante Eingangsdaten für die Prognose bestimmt. Damit die so identifizierten Datensätze interpretiert werden können, werden sie mit Hilfe eines ARX-Modells (2.4) der 1. Ordnung prognostiziert. Hierbei handelt es sich um ein sehr einfaches Modell. Für das eingesetzte ARX-Modell werden ausschließlich die Parameter der 1. Ordnung gesetzt und beinhalten daneben keinen zusätzlichen Modellierungsaufwand. Für die Arbeit wird die Hypothese aufgestellt, dass mit Hilfe eines Vergleichs der Prognoseergebnisse mit dem ARX(1) und den zu untersuchenden Methoden der Güteanteil zwischen Datenanalyse und ausgewählter Prognosemethode bestimmt werden kann. Die Wahl fiel auf ein ARX(1)-Modell, vgl. Abbildung 3.1, weil es die Möglichkeit bietet exogene Größen zu berücksichtigen. Die Auswertung erfolgt im Abschnitt 3.4.6. Ein Modellierungsprozess linearer stochastischer Modelle wird im Abschnitt 3.4.2 durchgeführt.

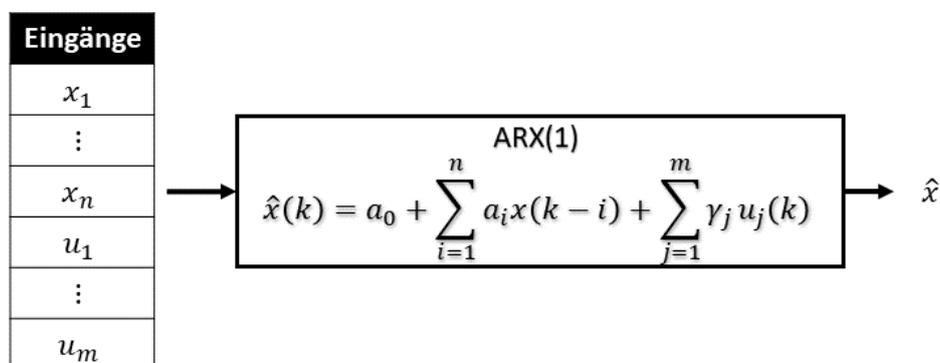


Abbildung 3.1: Blockschaltbild ARX(1) für Validierungszwecke mit unspezifizierten Eingängen

Weiterhin soll entsprechend BOX-JENKINS die Eignung der Modelle untersucht werden. Zu diesem Zweck wird der Fehler analysiert. Dieser kann jedoch nicht ermitteln ob man eine

optimale Prognose erreicht hat. Den Ansatz für die Untersuchung gibt das Komponentenmodell [171, S. 9-12]. Es besagt, dass ein Signal aus vier Komponenten besteht:

- Dem Trend $x_T(t)$,
- Der Konjunkturkomponente $x_K(t)$,
- Der Saisonkomponente $x_S(t)$ und
- Dem Rest $\epsilon(t)$.

Diese können entweder additiv oder multiplikativ miteinander verknüpft sein:

$$\text{Additives Signalmodell: } y(t) = x_T(t) + x_K(t) + x_S(t) + \epsilon(t) \text{ und} \quad (3.2)$$

$$\text{Multiplikatives Signalmodell: } y(t) = x_T(t) \cdot x_K(t) \cdot x_S(t) \cdot \epsilon(t). \quad (3.3)$$

Durch logarithmische Transformation lässt sich das multiplikative Modell auf ein additives zurückführen. Für die Prüfung wird angenommen, dass die Residuen einer optimalen Prognose ausschließlich aus der Restkomponente bestehen. Diese entspricht im Idealfall dem weißen Rauschen. Gemäß BOX-JENKINS können mehrere Verfahren neben dem stark empfohlenen Sichttest eingesetzt werden, vgl. [33, S. 312-326]. Zum einen kann die Autokorrelationsfunktion zur Bestimmung eingesetzt werden. Diese setzt voraus, dass die Residuen normal verteilt sind, vgl. [165]. Das kann nicht gewährleistet werden. Zum anderen bietet sich der verteilungsunabhängige Periodogrammtest an. Bei ihm wird geprüft ob die Leistungsdichtespektren über den Frequenzbereich gleichverteilt sind. Für die Untersuchungen wird ein Unsicherheitskriterium von 5% angenommen. In der Arbeit wird für jeden Prognosehorizont ein Modell trainiert. Aus diesem Grund werden die Periodogramme für jeden Horizont berechnet und als Kurvenschar in der Farbe Gelb dargestellt, Beispiel in Abbildung 3.2 gegeben. Die Kurven mit der minimalen und maximalen Abweichung werden durch die Farben grün und rot dargestellt.

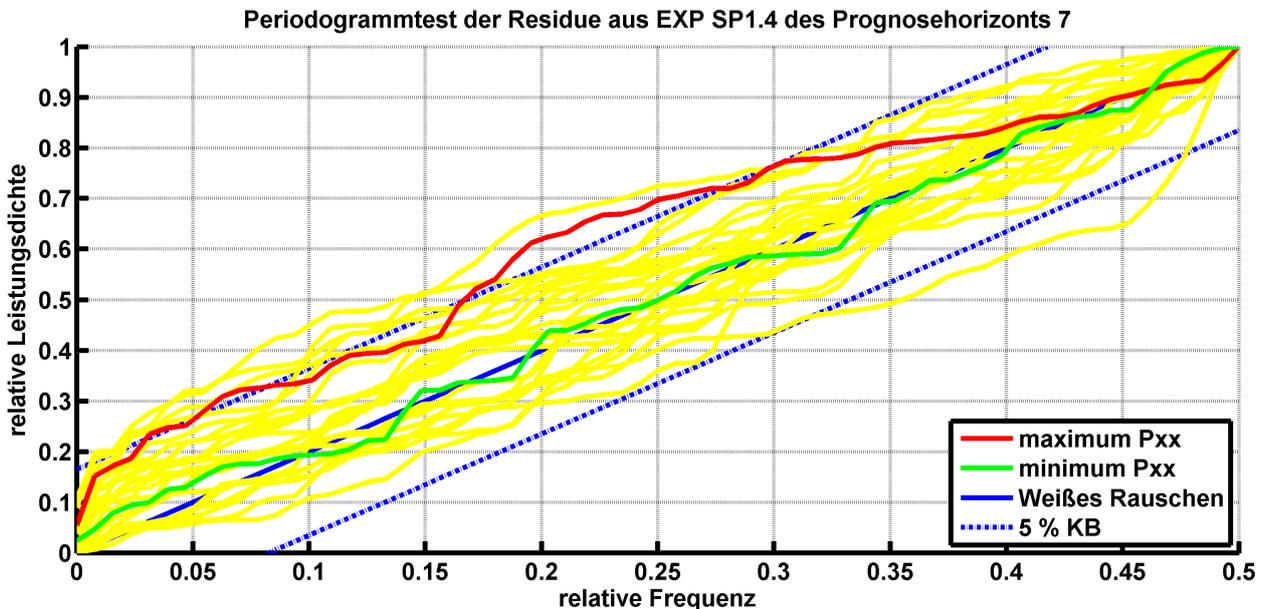


Abbildung 3.2: Erklärungsbeispiel eines Periodogrammtests aus dem Experiment EXP SP1.4 im Kapitel 5

Die geforderte Sichtanalyse nach BOX-JENKINS erfolgt durch die Analyse der gemittelten Fehler je Prognosehorizont und einem Boxplot. Der Boxplot, vgl. Abbildung 3.3, setzt sich aus dem Median, der Box die durch das untere 25% Quantil und das obere 75% Quantil eingefasst

ist, den zugehörigen Whiskern und den Ausreißern zusammen. Die Whisker berechnen sich durch die 1,5-fache Distanz zwischen Median und dem jeweiligen Quantil. Alle außerhalb liegenden Werte werden als Ausreißer gekennzeichnet. Zusätzlich wird in den Analysen die positive und negative Standardabweichung abgebildet. Weiterhin wird das arithmetische Mittel ausgegeben, damit die Lage auf Zentralität geprüft werden kann. Für jeden Prognosehorizont wird ebenso ein Boxplot erstellt.

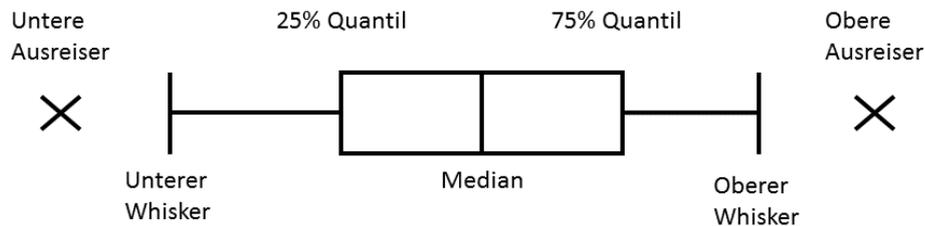


Abbildung 3.3: Schematischer Aufbau des Boxplots

3.1.3 Analysemethodik

Für die Interpretation der Ergebnisse in den folgenden Abschnitten werden nachstehende Analysemethoden und Kenngrößen definiert. Die Korrelationsanalyse vergleicht geordnete Mengen miteinander und ist eine grundlegende Methode um Daten im stochastischen Modellierungsprozess zu analysieren, vgl. [39, 108, 139, 184, 195]. In dieser Arbeit sind die Mengen Messungen oder Prognosen von Leistungs- und Klimagrößen geordnet nach der Zeit. Durch Berechnung des Korrelationskoeffizienten r wird der lineare Zusammenhang bestimmt, vgl. [165, S. 102]:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}) \sum_{i=1}^n (y_i - \bar{y})}}. \quad (3.4)$$

Der Koeffizient ist definiert für den Wertebereich $-1 \leq r \leq 1$. Für den Wert von $+1$ besteht ein direkter linearer Zusammenhang, für -1 ein umgekehrt linearer. Kein linearer Zusammenhang besteht bei einem Wert von 0 . Spezialisierte Formen sind unter anderem:

- Der partielle Korrelationskoeffizient,
- Der multiple (oder multivariate) Korrelationskoeffizient,
- Die Autokorrelationsfunktion und
- Die Kreuzkorrelationsfunktion.

Die Korrelationsfunktionen analysieren den dynamischen mittleren linearen Zusammenhang mit Hilfe einer Verschiebefunktion und die Korrelationskoeffizienten den statischen Zusammenhang. Durch die Autokorrelationsfunktion werden Aussagen zur Periodizität und durch die Kreuzkorrelationsfunktion Aussagen über die Reaktionsverzögerungen getroffen. Letztere vergleicht eine Zielgröße mit exogenen Größen, z.B. Windleistungseinspeisung mit der Windgeschwindigkeit. Für periodische Aussagen könnten auch andere Analysemethoden eingesetzt werden, wie z.B. Leistungsdichtespektren oder Wavelet Analysen. Das ist jedoch nicht notwendig solange Aussagen über die Periodizität durch die Korrelationsfunktionen beantwortet werden können.

Der partielle Korrelationskoeffizient beschreibt den funktionellen Zusammenhang zwischen zwei Größen unter dem Ausschluss des Zusammenhangs weiterer Größen. Folgendes Beispiel beschreibt den partiellen Korrelationskoeffizient $r_{xy.z}$ zwischen den Größen x und y unter Ausschluss des Einflusses von z , vgl. [165, S. 107]:

$$r_{xy.z} = \frac{r_{xy} - r_{xz} * r_{yz}}{\sqrt{(1 - r_{xz}^2)(1 - r_{yz}^2)}}. \quad (3.5)$$

Der multiple Korrelationskoeffizient betrachtet den Gesamtzusammenhang zwischen einer Zielgröße und mehreren Vergleichsgrößen. Folgendes Beispiel beschreibt den Gesamtzusammenhang $r_{x.yz}$ der Zielgröße x zu den Größen y und z , vgl. [165, S. 108]:

$$r_{x.yz} = \sqrt{\frac{r_{xy}^2 + r_{xz}^2 - 2r_{xy}r_{xz}r_{yz}}{1 - r_{yz}^2}}. \quad (3.6)$$

Die Funktionen der Autokorrelation und der Kreuzkorrelation verschieben die Zeitvektoren der Messwerte gegeneinander und untersuchen sie auf ihren funktionalen Zusammenhang. Dadurch können Zeitabhängigkeiten ermittelt werden. Die Autokorrelation ermittelt die inneren funktionalen Zeitzusammenhänge und die Kreuzkorrelation zwischen zwei Größen.

3.2 Experimentelle Randbedingungen

Die Datenanalyse soll Eigenschaften des Prognoseziels der Windleistungseinspeisung untersuchen. Weiterhin sind Abhängigkeiten innerhalb der Messungen und zu exogenen Größen zu identifizieren. Für die Untersuchungen stehen die Daten von vier WPs zur Verfügung:

- WP 1: ist südlich von der Stadt Erfurt gelegen und hat Daten im Trainingszeitraum von „03.11.2009 01:00“ bis „31.03.2010 22:00“ und im Validierungszeitraum von „01.04.2010 01:00“ bis „01.07.2010 01:00“,
- WP 2: ist westlich von der Stadt Erfurt gelegen und hat Daten im Trainingszeitraum von „01.08.2009 01:00“ bis „27.11.2009 22:00“ und im Validierungszeitraum von „28.11.2009 01:00“ bis „31.05.2010 22:00“,
- WP 3: ist in Brandenburg gelegen und hat Daten im Trainingszeitraum von „01.07.2014“ bis „31.01.2015“ und im Validierungszeitraum von „01.01.2015“ bis „31.05.2015“ und
- WP4: ist ein Offshore Windpark in der Ostsee und hat Daten im Trainingszeitraum von „31.12.2012 23:00“ bis „31.10.2013 23:00“ und im Validierungszeitraum von „01.11.2013 01:00“ bis „01.05.2013 23:00“.

Damit eine Durchmischung von Trainingsdaten und Validierungsdaten unterbunden wird, erfolgt eine strenge Trennung zwischen den Zeiträumen. Diese Vorgabe bewirkt, dass unterschiedliche Jahreszeiten in den jeweiligen Datenmengen abgebildet werden. Der Einfluss auf die Prognosegüte wird im Kapitel 5 berücksichtigt.

Für die Windparks WP 1 und WP 2 wurden die historischen Klimaprognosen über die PAMORE Schnittstelle des DWD heruntergeladen. Der DWD speichert seine Prognosemodelle für die zurückliegenden ein bis ca. eineinhalb Jahre. Die Abfragen je Windpark dauerten ca. zehn Monate. Die Prognosen sind in Einzeldateien im GRIB1 bzw. GRIB2 Format abgelegt. Die PAMORE-Abfragen entladen aus den Dateien ein 10x10 Punkteraster einer Schicht mit den Klimagrößen:

- Die vektorielle Windgeschwindigkeit \bar{v} ,
- Die Bodenrauhigkeit z_0 ,
- Die Lufttemperatur T und
- Den Luftdruck p .

WP 3 und WP 4 verwendet die Klimagrößen aus Online-Prognosen des DWD, die aus dem im Abschnitt 4.2 beschriebenen Klimadatenarchiv geladen werden. Nach Erstellung der Wetterprognose werden ausgewählte Ergebnisse bereitgestellt. Somit kann unter realitätsnahen operativen Bedingungen die Prognose berechnet werden. Alle Daten wurden auf ein einstündiges Abtastintervall vereinheitlicht, weil die bezogenen Daten des DWD dieser Auflösung entsprechen. Prognosen mit Abtastzeiten unter einer Stunde werden nicht berechnet. Für die Experimente des Modellierungskapitels 3 wird der WP 1 verwendet. WP 2 bis WP 4 werden in den Validierungsrechnungen des Kapitels 5 verwendet.

3.3 Datenanalyseprozess

3.3.1 Analyse Prognoseziel

Das Prognoseziel dieser Arbeit ist die Windleistungseinspeisung. Die Autokorrelationsverläufe des WP 1 zeigt Abbildung 3.5. Innerhalb der ersten Stunden ist ein starker linearer Zusammenhang zu erkennen, der stark abfällt und statistisch signifikant bleibt. Die partielle Autokorrelationsfunktion zeigt nur für die erste Stunde einen starken linearen Zusammenhang. Danach fällt die Korrelation mehrheitlich unter die Signifikanzschränke des 5 % Konfidenzbands und einige schwache statistische Zusammenhänge sind in den Stunden drei, vier, sieben und acht zu erkennen. Aufgrund des Verlaufs können auf Basis der Messungen keine Day Ahead Prognosemodelle mit ausreichender Güte erstellt werden, welches durch das Beispiel der Persistenz-Methode, [144], verdeutlicht wird, vgl. Abbildungen 3.4 und 3.6:

$$\hat{x}_{t+k} = x_t. \quad (3.7)$$

\hat{x}_{t+k} ist gleich dem Prognosewert und x_t der Messwert. Dementsprechend wird in der Implementierung der letzte Messwert auf den zu prognostizierenden Horizont projiziert. Trotz ihrer Einfachheit wurde sie unter genannter Quelle [144] eingeführt und war eine der ersten wissenschaftlichen Arbeiten zum Thema der Windleistungsprognose.

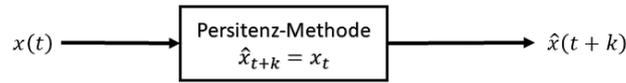


Abbildung 3.4: Blockschaltbild der Persistenz-Methode

Der Fehler in Abbildung 3.7 nimmt schnell von $< 0,05$ NRMSE in der ersten Prognosestunde auf $> 0,10$ NRMSE ab der zehnten Stunde zu. Die maximale Einzelabweichung beträgt $0,618$ NMAE. Für diesen Prognosehorizont sind zusätzliche Größen notwendig, die den fehlenden funktionalen Zusammenhang erklären. In Frage kommen die klimatischen abhängigen Größen der Energieertragsformel (1.1): die Windgeschwindigkeit v und die Luftdichte ρ in Abhängigkeit der Lufttemperatur T , des Luftdrucks p und der Luftfeuchtigkeit φ .

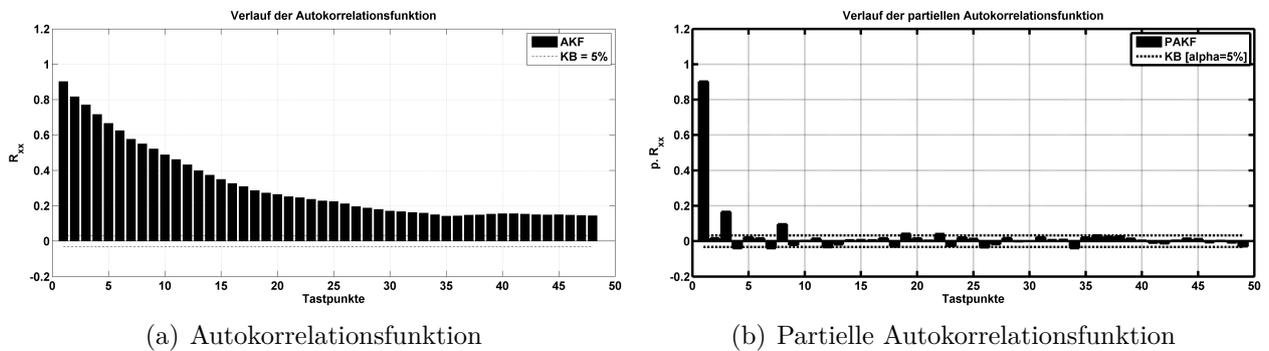


Abbildung 3.5: Visualisierung Korrelationsanalyse der WP1 Einspeisung mit 5 % Konfidenzband

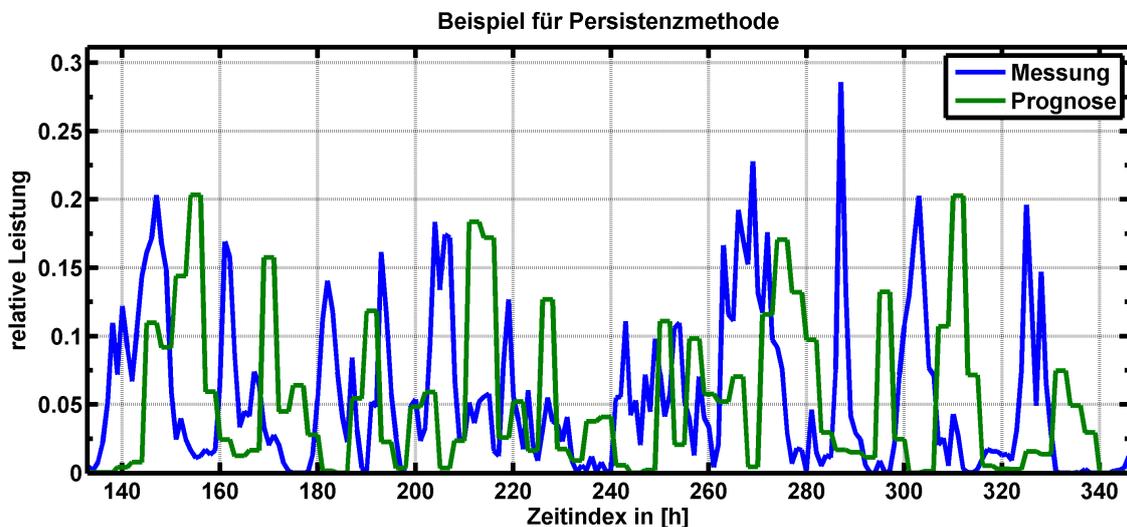


Abbildung 3.6: Beispiel einer Persistenz-Methode, Gl. (3.7), für eine drei-Stunden-Prognose

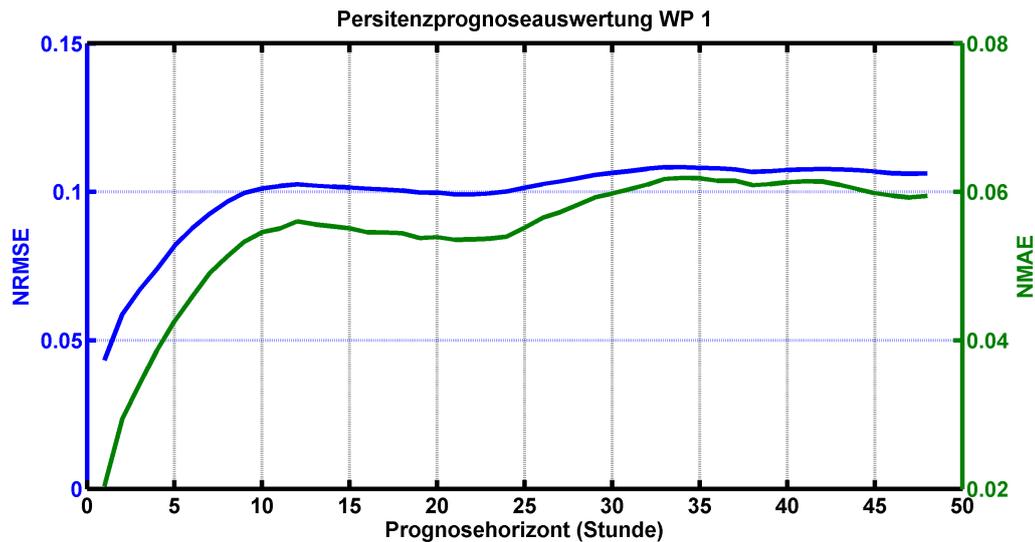


Abbildung 3.7: Auswertung Persistenzmethode WP1 (Fehlermaße: NRMSE - blau und NMAE - grün) der Prognose in Abbildung 3.6

3.3.2 Sensitivitätsanalyse exogener Klimagrößen

Die Persistenz-Prognose zeigt, dass mit einer auf dem Messsignal beruhenden Prognose keine hohe Güte erreicht werden kann. Neben dem Messsignal können weitere exogene Größen entsprechend der Windenergieertragsformel Gl. (1.1) verwendet werden. Der Korrelationskoeffizient einzelner Größen zur Windenergieeinspeisung zeigt hohe Werte mit 0,81 für die Windgeschwindigkeit, die mit der dritten Potenz in den Energieertrag einfließt, vgl. Tabelle 3.2. Die anderen untersuchten Klimagrößen wie Lufttemperatur und Luftdruck haben einen linearen Zusammenhang von 0,33 bzw. $-0,24$.

Tabelle 3.2: Korrelationskoeffizienten zwischen gemessenen Klimagrößen und Windenergieeinspeisung

Klimagröße	Korrelationskoeffizient
Windgeschwindigkeit	0,8105
Lufttemperatur	0,3359
Luftdruck	-0,2403

Mittels einer Sensitivitätsanalyse wurde der Einfluss der einzelnen Klimagrößen untersucht. Dazu werden die Parameter Lufttemperatur, Luftdichte und Luftdruck über die gemessenen Extrema variiert und der theoretische Windertrag gemäß Gl. (1.1) berechnet. Dazu wird die Luftdichte ρ wie folgt berechnet:

$$\rho = \frac{p - \left(\phi p_d \left(1 - \frac{R_l}{R_d} \right) \right)}{R_l T}, \quad (3.8)$$

Ergänzende Parameter sind der Dampfdruck p_d , die Gaskonstante für trockene Luft R_l und

die Gaskonstante für Wasserdampf R_d . Die Formel wurde für die Berechnungen angepasst und basiert auf der Zustandsgleichung für ideale Gase, gemäß [107, Gl. 2.8, S. 49], und der Erweiterung dessen Erweiterung um die Feuchteabhängigkeit. Für die Analyse wurden alle Parameter bis auf einen fixiert und dieser über den Wertebereich der in Deutschland gemessenen Extremwerte berechnet, vgl. Berechnungsprinzip in Abbildung 3.8. Der Leistungsbeiwert c_p aus Gl. (1.1) wird in Abhängigkeit der Windgeschwindigkeit v und den Technologieparametern berechnet.

Der maximale Leistungsbeiwert c_p wurde durch Betz berechnet und beträgt 0,593, vgl. [43, S. 45]. Für jeweilige Windkraftanlagen wird dieser für Normaldruck in Form von Tabellenwerten für unterschiedliche Windgeschwindigkeiten angegeben. Für die Berechnungen werden die Leistungsbeiwerte anhand der zur Verfügung stehenden Tabellenwerte berechnet. Dazu werden die Werte für beliebige Windgeschwindigkeiten linear interpoliert.

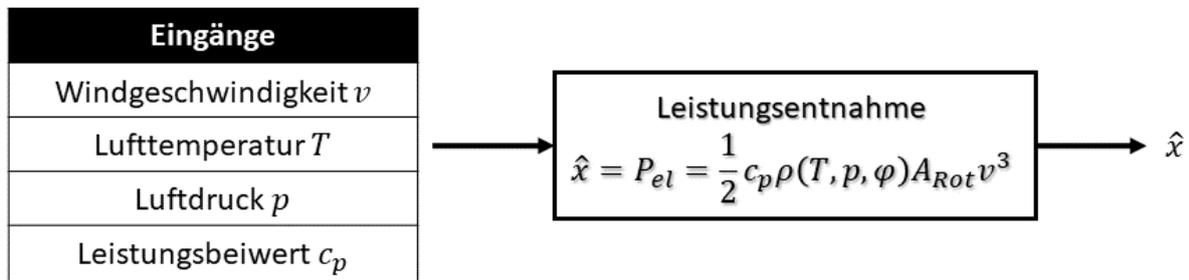


Abbildung 3.8: Blockschaltbild zur Berechnung der Leistungsentnahme anhand der physikalischen Zusammenhänge

Folgend befinden sich die ermittelten Sensitivitäten:

- Lufttemperatur: eine Temperaturerhöhung um 1 K reduziert die Leistung um 0,36 %,
- Luftdruck: eine Druckerhöhung um 100 Pa erhöht die Leistung um 0,10 % und
- Luftfeuchtigkeit: eine Erhöhung um 1,0 % erhöht die Leistung um 0,0023 %.

Die Einflüsse sind gegenläufig, je nach Situation können sich die Effekte verstärken oder abschwächen. Die Luftfeuchtigkeit kann theoretisch einen maximalen Einfluss von 0,2 % auf den Energieertrag erreichen. Damit wird sie in den weiteren Betrachtungen nicht mehr verwendet, weil ihr Einfluss zu gering ist. Dazu wird die Luftfeuchte konstant gesetzt. Der Einfluss der anderen Größen ist aufgrund des Schwankungsbereichs deutlich größer, vgl. Abbildung 3.9. Zum Beispiel kann die Veränderung der Lufttemperatur eine Leistungsänderung von 13 % verursachen, wenn alle anderen Einflussgrößen gleichbleiben. Der nichtlineare Einfluss der Lufttemperatur und des Luftdrucks sind nicht vernachlässigbar und werden daher in den weiteren Untersuchungen eingebunden. Damit ihr Verhalten berücksichtigt wird, werden für die weiteren statistischen Untersuchungen die Luftdichte Gl. (3.8), die synthetische Einspeiseleistung Gl. (1.1), der Massestrom:

$$\dot{m} = \rho A v, \tag{3.9}$$

der Dichtestrom DSt

$$DSt = \rho v, \tag{3.10}$$

und die kinetische Energie E des Winds

$$E = \frac{1}{2} \rho A v^3 \quad (3.11)$$

verwendet.

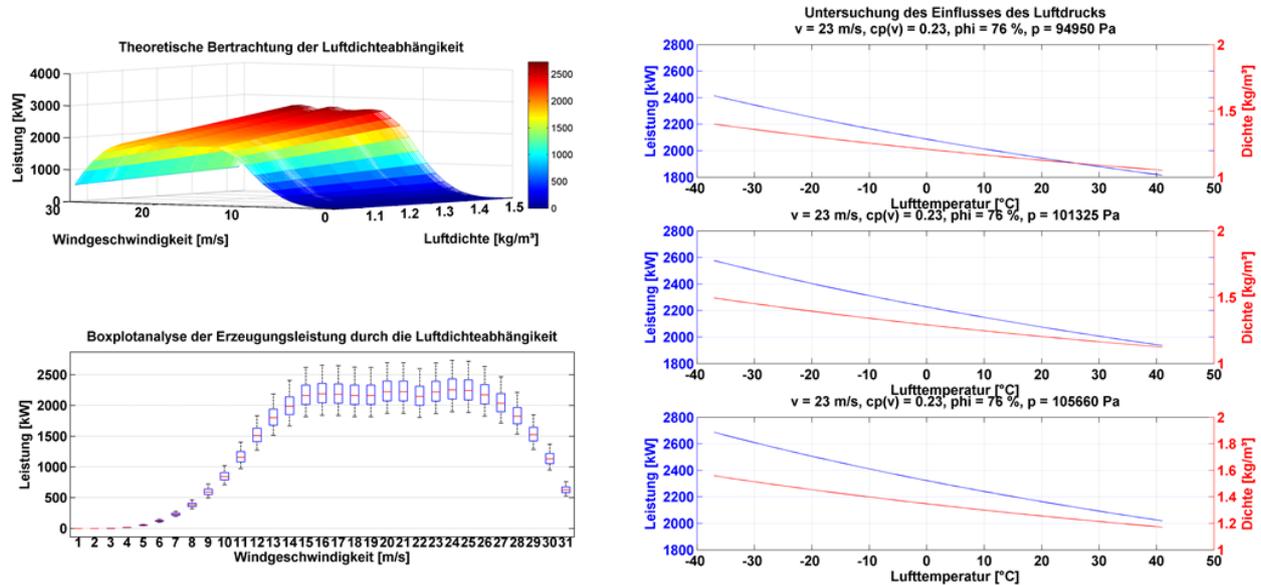


Abbildung 3.9: Luftdichtesensibilität mit der Anwendung der Normparameter einer WKA

3.3.3 Multivariate Untersuchungen

Mittels der bivariaten korrelativen Analysen können Aussagen getroffen werden, die in einem direkten Zusammenhang zueinanderstehen. Multivariate Untersuchungen erlauben es, den Zusammenhang zwischen einer oder mehrere Zielgrößen zu einer Menge von Einflussgrößen zu messen. Für die Untersuchungen können unter anderem die Hauptkomponentenanalyse (HKA) oder der multiple Korrelationskoeffizient eingesetzt werden.

Hauptkomponentenanalyse

Die HKA vergleicht die Gesamtvarianz aller Eingangsgrößen mit den beschreibenden Einzelvarianzen der Hauptkomponenten. Die Hauptkomponenten (HK) werden durch eine Linearkombination aller untersuchten Größen gebildet. Durch Minimieren der Hauptkomponenten wird versucht die Gesamtvarianz im ausreichenden Maß abzubilden. Beim Einsatz dieser Methode ist die Bildungsvorschrift der Varianz σ^2 zu berücksichtigen. Sie ist die mittlere quadrierte Abweichung, vgl. [165, S. 175]:

$$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2, \quad (3.12)$$

mit μ als Mittelwert und x_i als Messwerte.

Ihre Zusammenhänge werden durch das Histogramm in Abbildung 3.10 schematisch dargestellt. Aufgrund der Berechnung verliert die Varianz die Analysefähigkeit des zeitlichen Zusammenhangs einer Messwertzeitreihe. Dieser Aspekt muss in zeitabhängigen Prozessen berücksichtigt werden und kann bei Vernachlässigung zu Scheinzusammenhängen führen. Zum Beispiel haben nicht gleiche Verteilungsfunktionen die gleichen Varianzen und suggerieren somit eine Scheinabhängigkeit. Diese Zusammenhänge können unter anderem durch statistische Tests, wie z.B. den Kolmogoroff-Smirnoff Test [165, S. 472], überprüft werden. Dieser vergleicht den Abstand beider Verteilungsfunktionen und trifft so eine Grundaussage über die statistische Gleichheit.

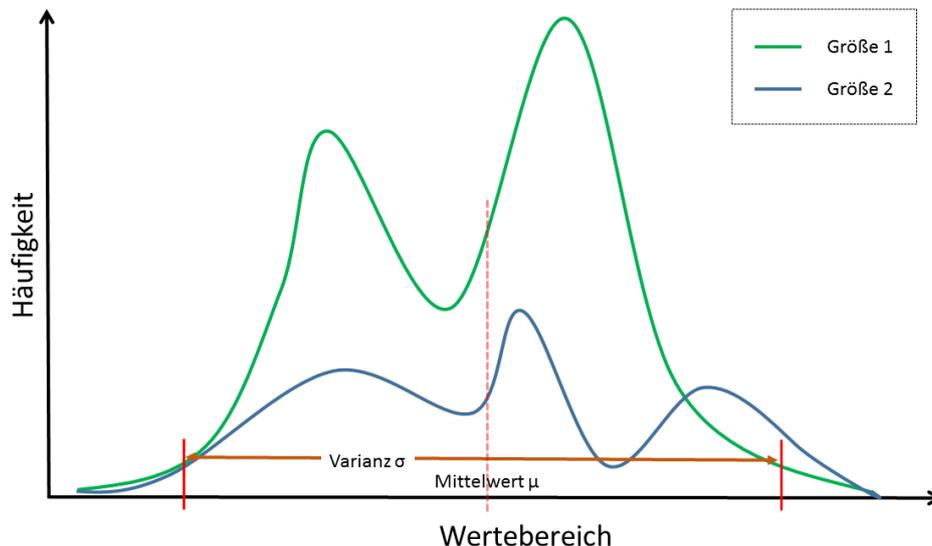


Abbildung 3.10: Eigenschaften der Varianz

Die Analyse des Gesamtdatensatzes zeigt, dass der Leistungsbeiwert cp und die Windrichtung $alpha$ den größten Einfluss auf die Varianz der Einzelkomponenten haben. Durch Auswerten der HK-Koeffizienten der drei stärksten Hauptkomponenten können die Parameter numerisch bestimmt werden. Für das Beispiel werden alle Parameter selektiert, die 70 % des maximalen HK-Koeffizienten entsprechen. Die Ergebnisse für die Horizonte 0, die nullte Prognosestunde, und 1 sind in Tabelle 3.3 dargestellt. Es werden folgende Abkürzungen verwendet:

- „FD“: für die Klimaprognosedaten, „MD“ für die Messdaten,
- „CPID“: für die Koordinatenpunktidentifizierung,
- „cp“: für den Leistungsbeiwert nach BETZ und
- „alpha“: für die Windrichtung.

Für die Modellierung des Horizonts „0“ werden nicht die aktuellen Messwerte, sondern die eine Stunde zurückliegenden Messwerte verwendet, gekennzeichnet durch „hist.“. Für die Untersuchung wurde jeder Prognosehorizont individuell untersucht. Die Ergebnisse bleiben gleich, unabhängig welcher Horizont betrachtet wird. Die grafische Auswertung erfolgt in Abbildung 3.11. Sie zeigt, dass sich die HK-Koeffizienten zu Gruppen ähnlicher räumlicher Ausrichtung bündeln lassen, um die Varianz zu beschreiben. Ihre Vektoren der Linearkombination verteilen sich im Raum und folgen einer gekrümmten Ebene. Es gibt keine klar trennbaren Untermengen, die für eine Klassenbildung herangezogen werden könnten.

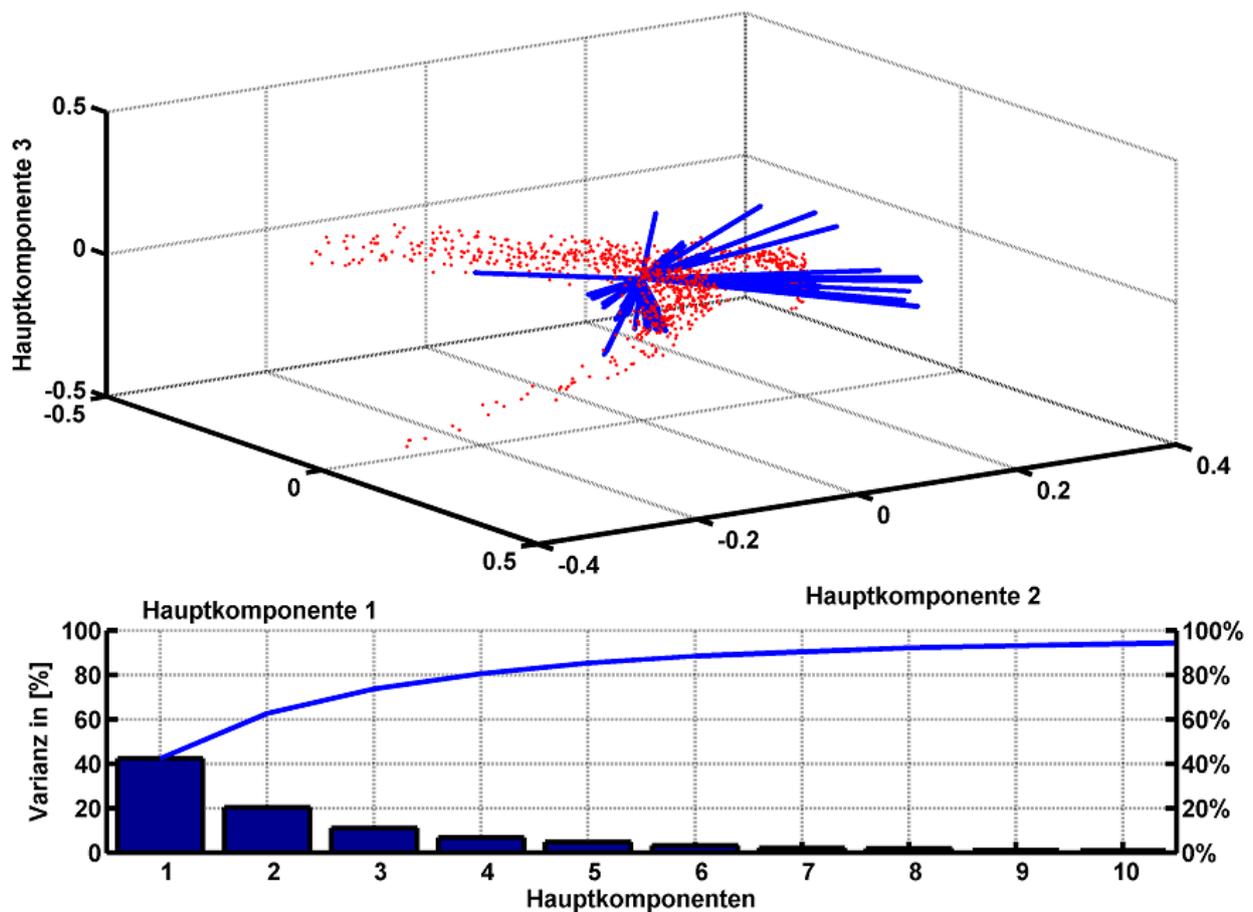


Abbildung 3.11: HKA für WP 1: Die 3D-Grafik (oben) zeigt die HK-Koeffizienten (blau) der Linearkombination als Vektoren und die projizierten Ausgangsdaten (rot) als Streudiagramm. Die PARETO-Darstellung zeigt die Varianzen (Boxen) der Hauptkomponenten und die kumulierte Varianz (Kurve).

Für die identifizierten Parameter in Tabelle 3.3 wurde der Korrelationskoeffizient R gegenüber der Einspeiseleistung berechnet. Entgegen der Varianz verändern sich die linear funktionalen Zusammenhänge für jeden Prognosehorizont, vgl. Abbildung 3.11. Ihre Werte bewegen sich zwischen +30 % und -30 %. Der somit ermittelte schwache Zusammenhang reicht nicht aus, um robuste Prognosen zu erstellen.

Tabelle 3.3: Analyse der einflussreichsten Parameter in den drei stärksten Hauptkomponenten für die Horizonte 0 und 1, Parameter beschrieben auf S. 30

Nr.	Horizont 0	R 0	Horizont 1	R 1
1	cp FD CPID1	0.2741	cp FD CPID1	0.2736
2	cp FD CPID2	0.2719	cp FD CPID2	0.2855
3	cp FD CPID3	0.2067	cp FD CPID3	0.2364
4	cp FD CPID4	0.2381	cp FD CPID4	0.2218
5	cp FD CPID5	0.2218	cp FD CPID5	0.2227
6	cp FD CPID7	0.1099	cp FD CPID7	0.0665
7	cp FD CPID8	0.0821	cp FD CPID8	0.0420
8	alpha MD hist.	0.2294	alpha MD	0.2152
9	alpha FD CPID2	-0.2264	alpha FD CPID2	-0.2190
10	alpha FD CPID3	-0.2389	alpha FD CPID3	-0.2259

Nr.	Horizont 0	R 0	Horizont 1	R 1
11	alpha FD CPID4	-0.2593	alpha FD CPID4	-0.2449
12	alpha FD CPID5	-0.2570	alpha FD CPID5	-0.2547
13	alpha FD CPID6	-0.2572	alpha FD CPID6	-0.2432
14	alpha FD CPID7	-0.2498	alpha FD CPID7	-0.2442
15	alpha FD CPID8	-0.2279	alpha FD CPID8	-0.2052
16	cp MD hist.	-0.0671	cp MD	-0.0515

Allgemein werden die Ergebnisse der HKA verwendet, um Klassen zu bilden. Dieser Ansatz wurde unter anderem in den Arbeiten [177, 61, 29, 114] verfolgt, um richtungsabhängige Prognosen zu bilden. Die für WP 1 vorliegenden Daten reichen nicht aus, um in einem stochastischen Signalmodell alle möglichen windrichtungsabhängigen Klassen ausreichend zu besetzen. Die Untersuchung der Abhängigkeiten von Windrichtungen auf die Ertragskurve wurde in Abbildung 3.12 visualisiert. Aufgrund fehlender Daten konnten keine vollständigen Ertragskurven für den vollständigen Arbeitsbereich der WKAs berechnet werden. Deshalb sind die Windrichtungsabhängigkeit und der Leistungsbeiwert indirekt berücksichtigt, indem sie den Datenanalysealgorithmen weiterhin zur Verfügung gestellt, aber keine expliziten richtungsabhängigen Klassen gebildet werden.

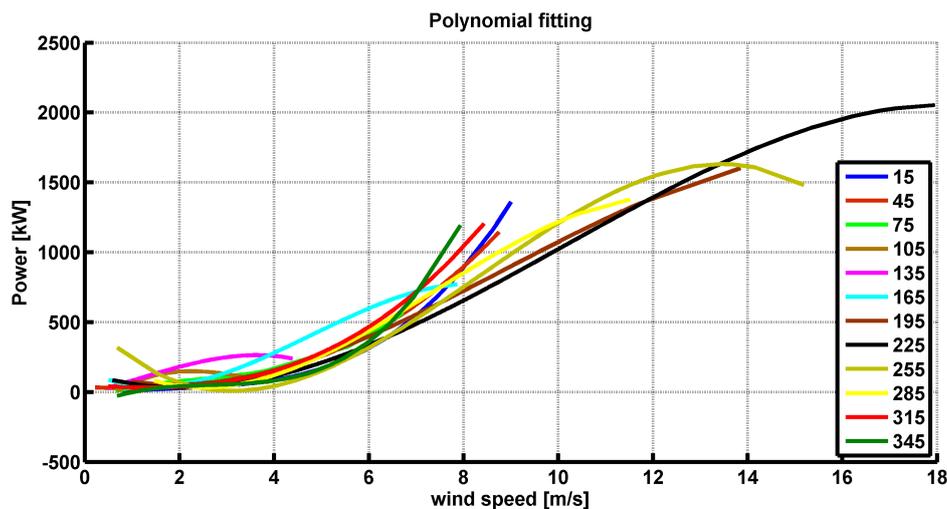


Abbildung 3.12: Windrichtungsabhängige Ertragskurven der WKAs des WP 1 (Die rechte Legende beschreibt die Windrichtung in $[\circ]$)

Wie gezeigt, kann die HKA in diesem Anwendungsfall die exogenen Größen nicht wirkungsvoll auf eine relevante Auswahl von Eingangsgrößen reduzieren. In der Literatur wird der Scree-Horn Test als eine Methode zur Parameterrückführung in der HKA und Faktoranalyse verwendet, vgl. [162, S. 97 ff.]. Dieser betrachtet visuell die absteigend sortierten Eigenwerte und identifiziert einen charakteristischen Knick im Kurvenverlauf. Alle Werte, die sich vor dem Knick befinden, werden als relevante Größen berücksichtigt. Dieser Test ist jedoch subjektiv, weil er von der Interpretation des Betrachters abhängig ist. Horn, vgl. [96], entwickelte die so genannte Parallelanalyse als objektiven Algorithmus. Dieser vergleicht die Eigenwerte gegenüber den Eigenwerten einer Zufallsmenge gleicher Dimension. Alle Eigenwerte der Messung, die über denen der Zufallsgröße liegen, werden als relevante Parameter verwendet.

Untersuchungen mit WP 1 zeigten, dass ebenfalls immer die gleichen Parameter selektiert werden. Im Unterschied zur vorangegangenen Untersuchung variiert allerdings die Reihenfolge und die Anzahl der selektierten Parameter, vgl. Tabelle 3.4. Auffällig ist, dass hier alle Messgrößen der nahegelegenen Messstation des WP 1 verwendet werden, die eine größere Distanz als die umliegenden Gitterpunkte des NWP haben. Auf Grund dieser Auswahl kommt es für die niedrigen Prognosehorizonte zu sehr hohen Korrelationswerten. Diese nehmen jedoch mit zunehmendem Horizont und Abfall der Autokorrelation, vgl. Abbildung 3.5, stark ab.

Tabelle 3.4: Scree-Horn Test für die Horizonte 0,1,12 und 24,
vgl. Abkürzungsverzeichnis S. VIII-IX

Nr.	Horizont 0	R 0	Horizont 1	R 1	Horizont 12	R 12	Horizont 24	R 24
1	P MD hist.	0.90	P MD	0.90	P MD	0.51	P MD	0.23
2	p MD hist.	-0.28	p MD	-0.28	p MD	-0.21	p MD	-0.11
3	T MD hist.	0.40	T MD	0.38	T MD	0.33	T MD	0.26
4	v MD hist.	0.80	v MD	0.78	v MD	0.51	v MD	0.29
5	v_n MD hist.	0.80	alpha MD	0.22	alpha MD	0.19	rho MD	-0.26
6	alpha MD hist.	0.23	rho MD	-0.43	rho MD	-0.36	alpha MD	0.18
7	rho MD hist.	-0.45	v_n MD	0.78	v_n MD	0.51	v_n MD	0.29
8	cp MD hist.	-0.06	cp MD	-0.05	cp MD	0.04	cp MD	0.06
9	\dot{V} MD hist.	0.80	\dot{V} MD	0.77	\dot{V} MD	0.51	\dot{V} MD	0.29
10	E_{kin} MD hist.	0.80	E_{kin} MD	0.76	E_{kin} MD	0.47	E_{kin} MD	0.21
11	p FD CPID1	-0.26			p FD CPID1	-0.27		
12					p FD CPID1	-0.26		

Multiple Korrelationskoeffizient

Als eine weitere Methode vergleicht der multiple Korrelationskoeffizient (MKK) den linearen funktionalen Zusammenhang einer Zielgröße zu einer Vielzahl von exogenen Größen, vgl. Gl. (3.6). In seiner Funktionsweise werden additiv bivariate Zusammenhänge zusammengefügt und Beziehungen zwischen den exogenen Größen untereinander entfernt. Vorteil dieser Methode ist, dass sie den linearen funktionalen Zusammenhang einer Zielgröße, hier Windleistung, zu einer Menge exogener Größen bewertet. Dadurch wird der zeitliche Zusammenhang der Größen untereinander nicht aufgelöst. Nachteil der Methode ist der lineare funktionale Zusammenhang. Rein nichtlineare Zusammenhänge können mit Hilfe des MKK nicht identifiziert werden. Ein weiterer Nachteil ist, dass immer nur der Gesamtzusammenhang zu allen exogenen Größen berechnet wird. Um eine Menge exogener Größen bewerten zu können, muss in einem kombinatorischen Ansatz die optimale Teilmenge gefunden werden, die die Zielgröße hinreichend gut beschreibt. Der kombinatorische Aufwand kann reduziert werden, indem zuerst der Verlauf des MKK über alle zur Verfügung stehenden exogenen Größen mit absteigendem korrelativem Zusammenhang berechnet wird. Anschließend wird der Beitrag zum Gesamtzusammenhang ausgewertet. Positive Auswahlkriterien sind starke und sprunghafte

Steigerungen. Negative Auswahlkriterien sind Stagnation, minimale oder negative Zuwächse, vgl. Abbildung 3.13. Der erste Bearbeitungsschritt für WP 1 wird in Tabelle 3.5 vorgestellt. In dieser werden die MKK mit absteigenden Korrelationskoeffizienten berechnet.

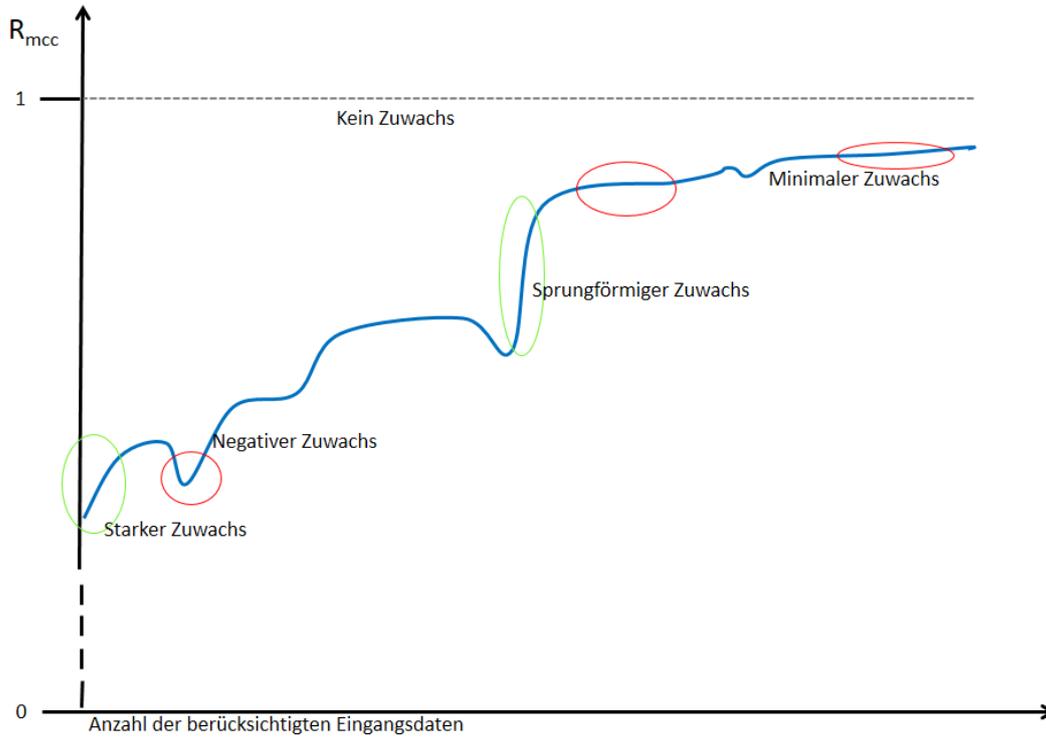


Abbildung 3.13: Arbeitsprinzip Größenauswahl MKK

Tabelle 3.5: Analyse multipler und normaler Korrelationskoeffizient für die Horizonte 1,12 und 24, vgl. Abkürzungsverzeichnis S. VIII-IX

Nr.	Horizont 1	MKK 1	R 1	Horizont 12	MKK 12	R 12	Horizont 24	MKK 24	R 24
1	P MD	0.90	0.90	$E_{kin,max}$ FD CPID8	0.80	0.80	$E_{kin,max}$ FD CPID2	0.82	0.82
2	E_{kin} FD CPID6	0.91	0.83	E_{kin} FD CPID6	0.82	0.79	$E_{kin,max}$ FD CPID6	0.82	0.82
3	E_{kin} FD CPID5	0.91	0.82	E_{kin} FD CPID8	0.82	0.79	$E_{kin,max}$ FD CPID5	0.82	0.82
4	E_{kin} FD CPID7	0.91	0.82	E_{kin} FD CPID7	0.82	0.79	$E_{kin,max}$ FD CPID3	0.82	0.82
5	$E_{kin,max}$ FD CPID7	0.91	0.81	$E_{kin,max}$ FD CPID7	0.82	0.78	$E_{kin,max}$ FD CPID1	0.82	0.81
6	E_{kin} FD CPID3	0.91	0.81	v_{max} FD CPID5	0.84	0.78	E_{kin} FD CPID2	0.82	0.81
7	$E_{kin,max}$ FD CPID8	0.91	0.80	$v_{n,max}$ FD CPID5	0.84	0.78	E_{kin} FD CPID3	0.82	0.81
8	E_{kin} FD CPID8	0.92	0.80	$E_{kin,max}$ FD CPID4	0.85	0.78	$E_{kin,max}$ FD CPID8	0.82	0.81
9	$E_{kin,max}$ FD CPID5	0.92	0.80	E_{kin} FD CPID2	0.85	0.78	$E_{kin,max}$ FD CPID4	0.83	0.81
10	$v_{n,max}$ FD CPID5	0.92	0.79	v_{max} FD CPID6	0.85	0.77	E_{kin} FD CPID6	0.83	0.80

Die Ergebnisse aus Tabelle 3.5 zeigen einen Zuwachs des Gesamtzusammenhangs. Der komplette Verlauf ist in Abbildung 3.14 dargestellt. Anhand der Kurvenverläufe wird deutlich, dass der Gesamtzusammenhang unter Einbezug aller Parameter signifikant gesteigert werden kann. Die Tabellenwerte und die Kurvenverläufe zeigen, dass zwei exogene Größen mit gleich starken Korrelationskoeffizienten keinen Mehrwert zur Steigerung des MKK haben können.

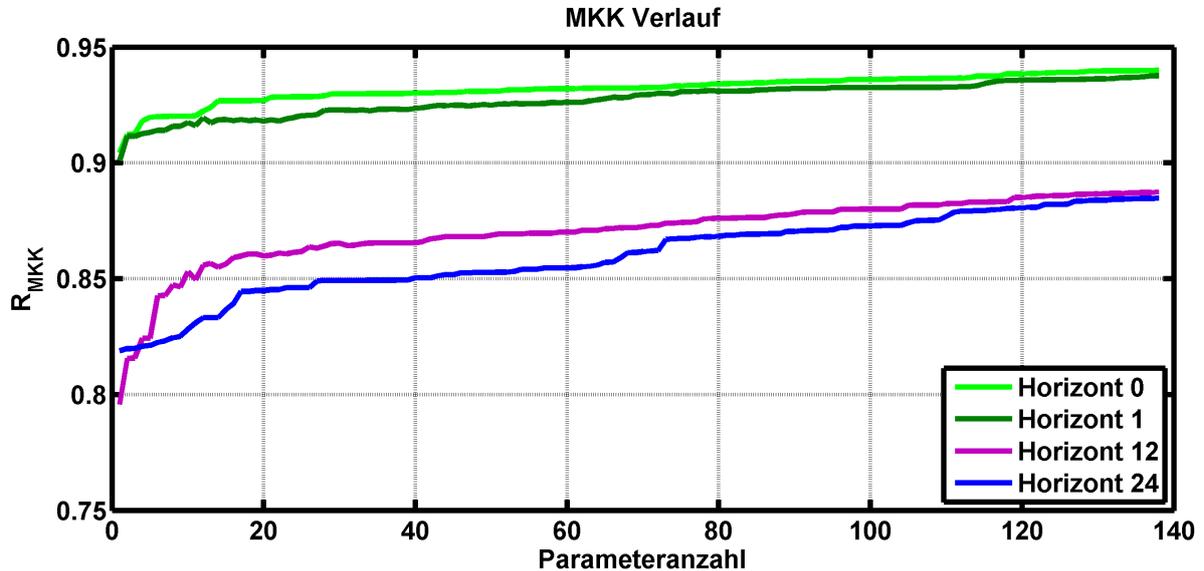


Abbildung 3.14: Darstellung der kompletten Beispielrechnung MKK aus Tabelle 3.5 für die Horizonte s1, 12 und 24

Mehrere Methoden können eingesetzt werden, um die relevante Teilmenge für die Prognose zu identifizieren. Die schnellste Variante die Gradientenoptimierung wertet die Gradienten aus und selektiert die Parameter mit dem stärksten Gradienten. Eine weitere Methode verwendet die Permutation zur Ermittlung der Parameter. Durch das iterative Testen wird sichergestellt das Optimum der zur Verfügung stehenden Daten zu finden. Sie wird folgend Anstiegsoptimierung genannt. Nachteil dieser Vorgehensweise ist der hohe Rechenaufwand. Im folgenden Beispiel wurde die erste Methode eingesetzt. Sie reduziert die Parameter von ursprünglich 138 auf sechs für Horizont 1 mit einem MKK von 0.9143, sieben für Horizont 12 mit einem MKK von 0.8416 und drei für Horizont 24 mit einem MKK von 0.8442, vgl. Tabelle 3.6. In Abbildung 3.15 wird das Ergebnis der Permutation dargestellt. Für dieses Beispiel wurde der Algorithmus so eingestellt, dass immer zehn Parameter auszuwählen sind.

Tabelle 3.6: Analyse multipler und normaler Korrelationskoeffizient nach Optimierung für die Horizonte 1,12 und 24, vgl. Abkürzungsverzeichnis S. VIII-IX

Nr.	Horizont 1	MKK 1	R 1	Horizont 12	MKK 12	R 12	Horizont 24	MKK 24	R 24
1	P MD	0.90	0.90	$E_{kin,max}$ FD CPID8	0.80	0.80	$E_{kin,max}$ FD CPID2	0.82	0.82
2	E_{kin} FD CPID6	0.91	0.83	E_{kin} FD CPID6	0.82	0.79	v_{max} FD CPID8	0.83	0.77
3	E_{kin} FD CPID8	0.91	0.80	E_{kin} FD CPID7	0.82	0.79	y FD CPID7	0.84	0.45
4	$v_{n,max}$ FD CPID5	0.91	0.79	$v_{n,max}$ FD CPID5	0.84	0.78			

Nr.	Horizont 1	MKK	R 1	Horizont 12	MKK	R 12	Horizont 24	MKK	R 24
		1			12			24	
5	v_n FD CPID5	0.91	0.79	$E_{kin,max}$ FD CPID4	0.84	0.78			
6	E_{kin} FD CPID2	0.91	0.78	v_{max} FD CPID6	0.84	0.77			
7				E_{kin} FD CPID5	0.84	0.77			

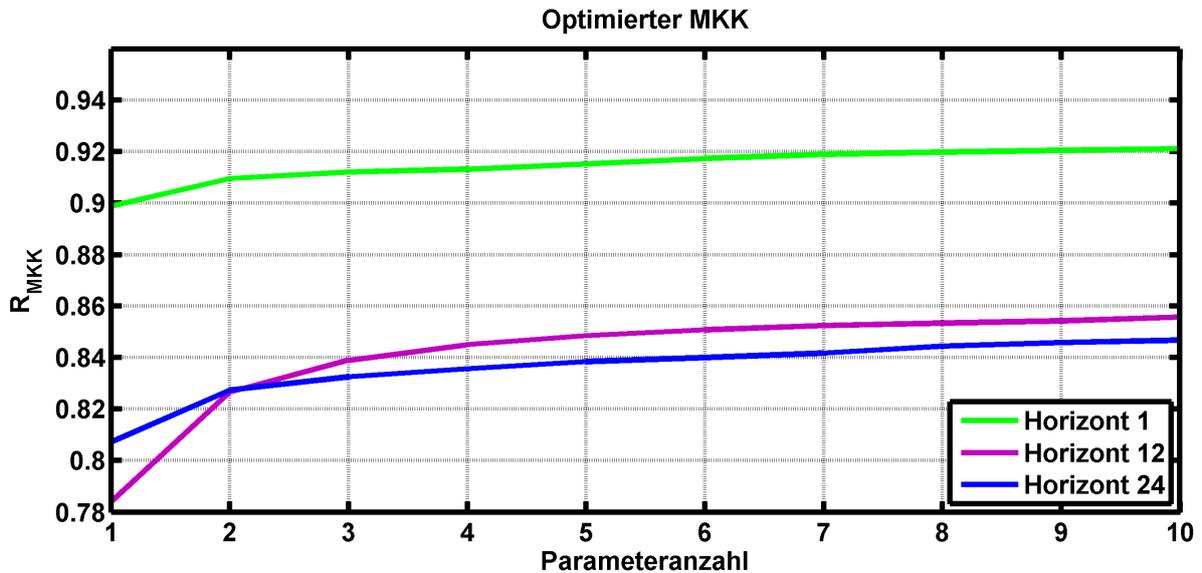


Abbildung 3.15: Darstellung der optimierten MKK mittels Permutation für die Horizonte s_1 , 12 und 24

Der höhere algorithmische Aufwand wird durch eine signifikante Verbesserung der funktionalen Zusammenhänge gerechtfertigt. Mit zunehmendem Horizont nimmt die Verbesserung der maximalen Anstiegsoptimierung gegenüber der Gradientenoptimierung zu, vgl. Abbildung 3.16. An der maximalen Stelle wird eine Verbesserung für das Beispiel WP 1 von über 4% und im Mittel ca. 2% erreicht. Der Anstieg im Zusammenhang ab Horizont 25 resultiert aus den verwendeten Klimamodellen. Im betrachteten Zeitraum weist das COSMO-EU Modell eine höhere Güte auf als das COSMO-DE Modell. Es konnten keine parallelen Datensätze für WP 1 organisiert werden. Deshalb sind Paralleluntersuchungen mit unterschiedlichen Wettermodellen nicht möglich.

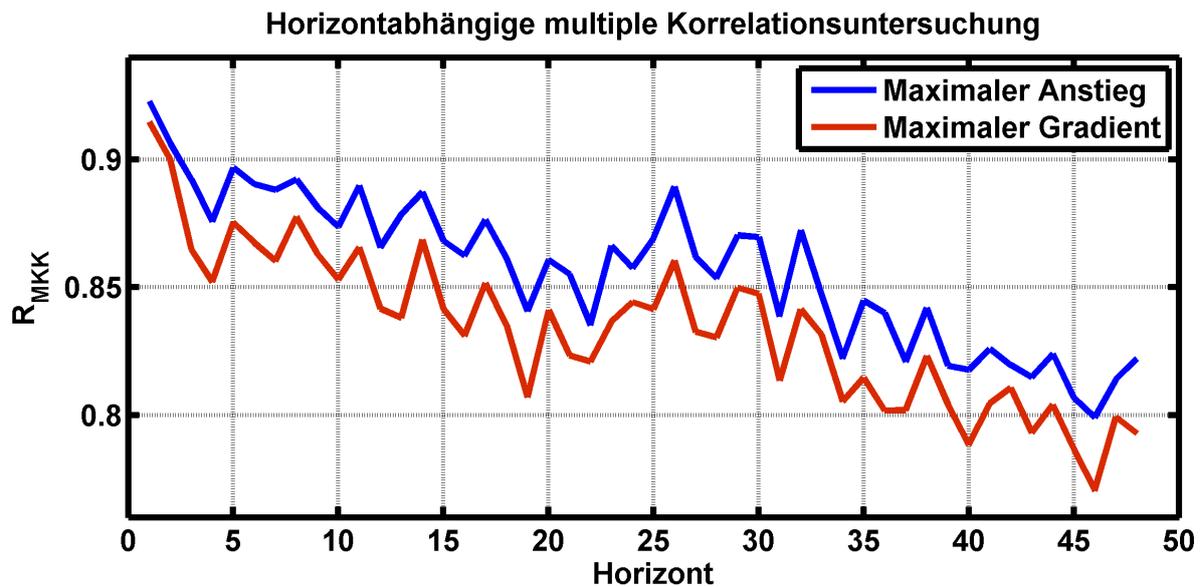


Abbildung 3.16: Vergleich der maximalen Gradienten- und Anstiegsoptimierung über alle Prognosehorizonte

Experimentelle Untersuchungen

Vier Experimente (EXP) zur Auswertung der Analyseergebnisse werden nachfolgend beschrieben. Alle verwenden sie das ARX (1)-Modell entsprechend Abschnitt 3.1. Das ARX-Modell wird eingesetzt, um reproduzierbare Ergebnisse zu berechnen. Je Prognosehorizont eines EXP wird ein Modell trainiert und prognostiziert.

EXP 1: Experiment 1 untersucht die Leistungsfähigkeit des bivariaten Korrelationskoeffizienten. Es werden die stärksten Größen als Eingangsdaten verwendet.

EXP 2: Experiment 2 verwendet die Eingangsdaten die durch die Hauptkomponentenanalyse identifiziert werden.

EXP 3: Experiment 3 verwendet den multiplen Korrelationskoeffizienten. Für die Auswahl der Eingangsdaten wird die beschriebene Gradientenoptimierung eingesetzt.

EXP 4: Experiment 4 verwendet den multiplen Korrelationskoeffizienten mit einer Permutation zur Ermittlung des maximalen funktional linearen Zusammenhangs durch eine Anstiegsoptimierung.

Zur Veranschaulichung des Modellaufbaus wird in folgender Abbildung 3.17 das Modell des EXP 3 für den ersten Prognosehorizont $H = 1$ visualisiert. Die Eingangsdatenbelegung wurde in Tabelle 3.6 aufgeführt und der Prozess der Identifizierung zuvor erklärt. Jeder einzelne Prognosehorizont erhält mittels der erklärten Methoden eine jeweilige individuelle Belegung der Modelleingänge. So werden für eine 24-Stundenprognose 24 individuelle Modelle für ein Experiment erstellt, trainiert und berechnet.

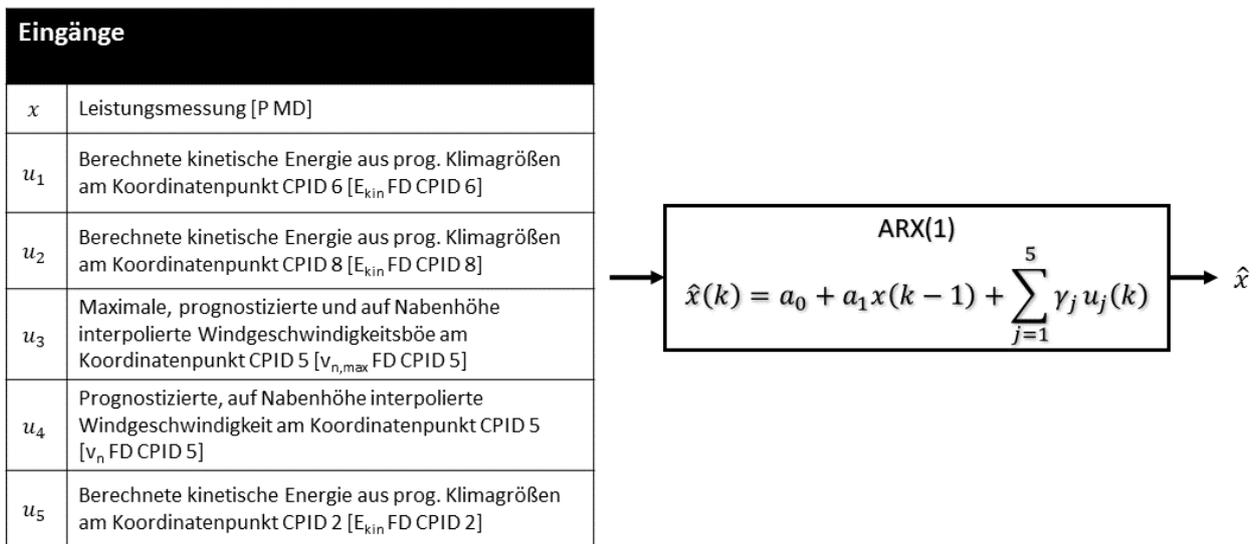


Abbildung 3.17: Modellaufbau für Horizont 1 des Experiments EXP3 auf Basis der Analyseergebnisse in Tabelle 3.6

Vergleichend ist in nachfolgender Abbildung 3.18 der Modellaufbau des EXP 4 für den ersten Prognosehorizont H 1 visualisiert. Als exogene Größen wurden durch den beschriebenen Algorithmus neben prognostizierten Klimagrößen bzw. Berechnungsgrößen, wie z.B. der kinetischen Energie auch Messgrößen identifiziert. Die prognostizierten Werte können zum Prognosehorizont k verwendet werden. Die Messwerte der exogenen Berechnungsgrößen haben den gleichen Zeitpunkt $k - 1$ wie die Leistungsmesswerte.

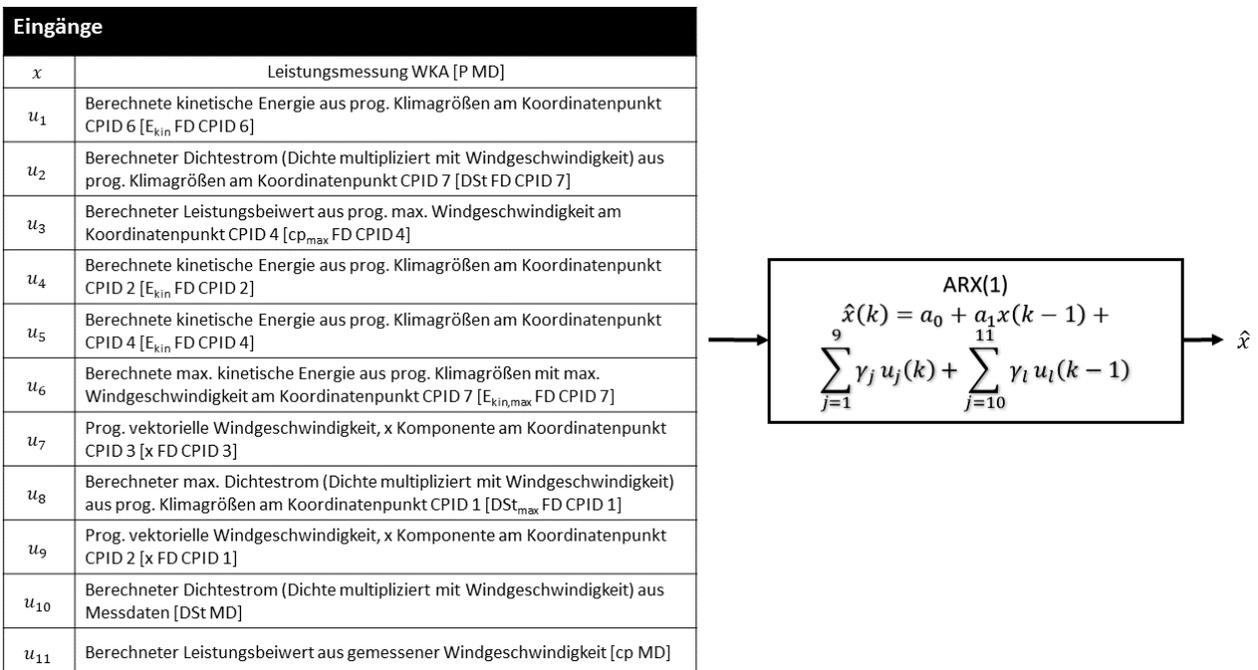


Abbildung 3.18: Modellaufbau für Horizont 1 des Experiments EXP4

Die Ergebnisse werden in Abbildung 3.19 dargestellt. Die Experimente EXP 2 und EXP 3 haben mit einem durchschnittlichen NRMSE von 9,8% und 10,6% am schlechtesten abgeschnitten. Sie sind daher ungeeignet und werden im weiteren Verlauf der Arbeit nicht

eingesetzt. EXP 1 ist das zweitbeste Modell mit einem durchschnittlichen NRMSE von 6,53% und EXP 4 das beste mit 6,25% NRMSE.

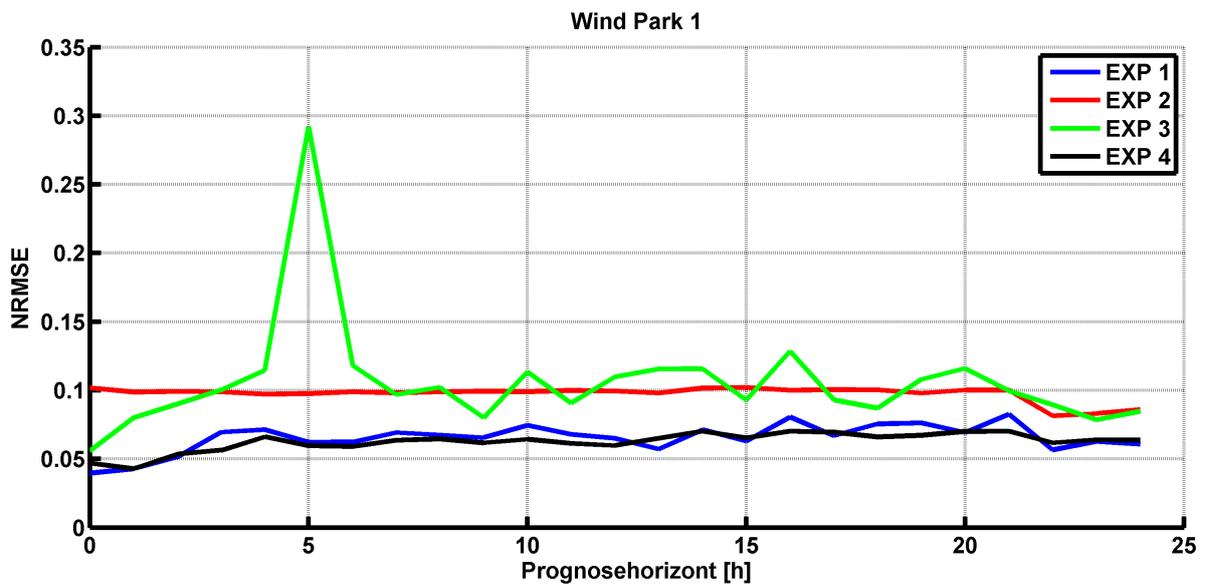


Abbildung 3.19: NRMSE Analyse der EXP 1 bis EXP 4

Die detaillierte Abbildung 3.20 zeigt, dass EXP 1 ein besseres Fehlerverhalten für einige Horizonte hat. Insgesamt hat EXP 4 eine Verbesserung, Imp gemäß Gleichung (3.1), von 3,1% gegenüber EXP 1. Die Verbesserung ist über weite Horizonte kontinuierlich, daher ist die MMK Methode von den hier vorgestellten zu favorisieren. Der Korrelationskoeffizient vergleicht immer zwei Zeitreihen miteinander und kann daher nicht den Gesamtzusammenhang beurteilen. Die Verringerung des Fehlers ab Horizont 22 H ist auf die unterschiedlichen Wettermodelle zurückzuführen.

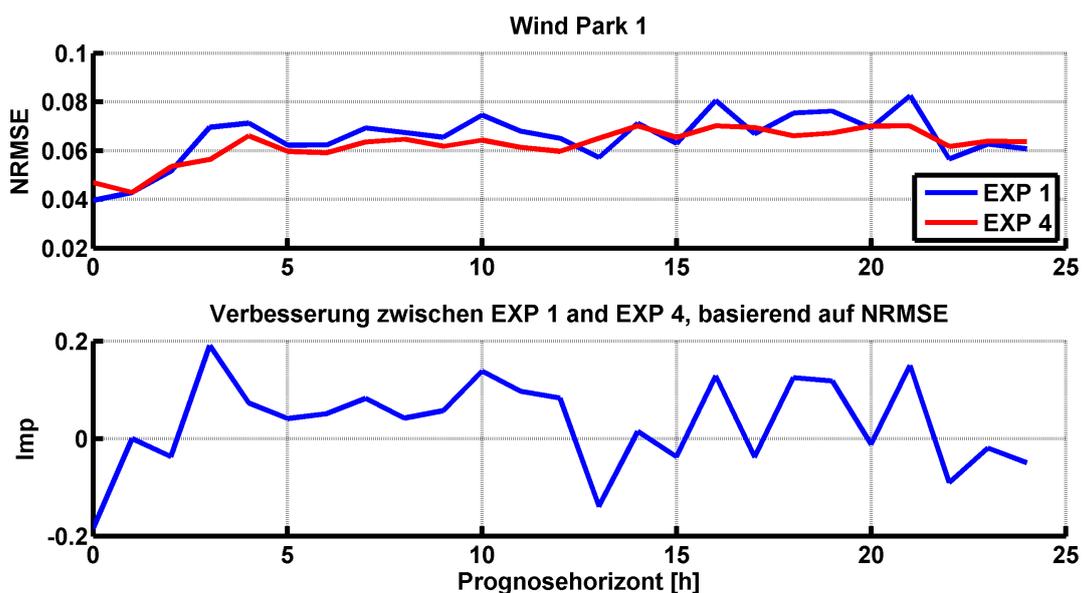


Abbildung 3.20: Detailvergleich EXP 1 mit EXP 4

Die Validierungsanalyse mittels Boxplot und Periodogrammtest in Abbildung 3.21 zeigt gleichfalls ein besseres Verhalten von EXP 4. Die maximalen Ausreiser und die Whisker sind

stärker in EXP 1 ausgeprägt. Der Periodogrammtest zeigt für die minimalen Abweichungen vom weißen Rauschen, dass EXP 1 die geringste Abweichung hat. Aber die maximale Abweichung und der überwiegende Teil der anderen Horizonte (gelb) zeigen eine stärkere Abweichung vom weißen Rauschen auf als bei EXP 4.

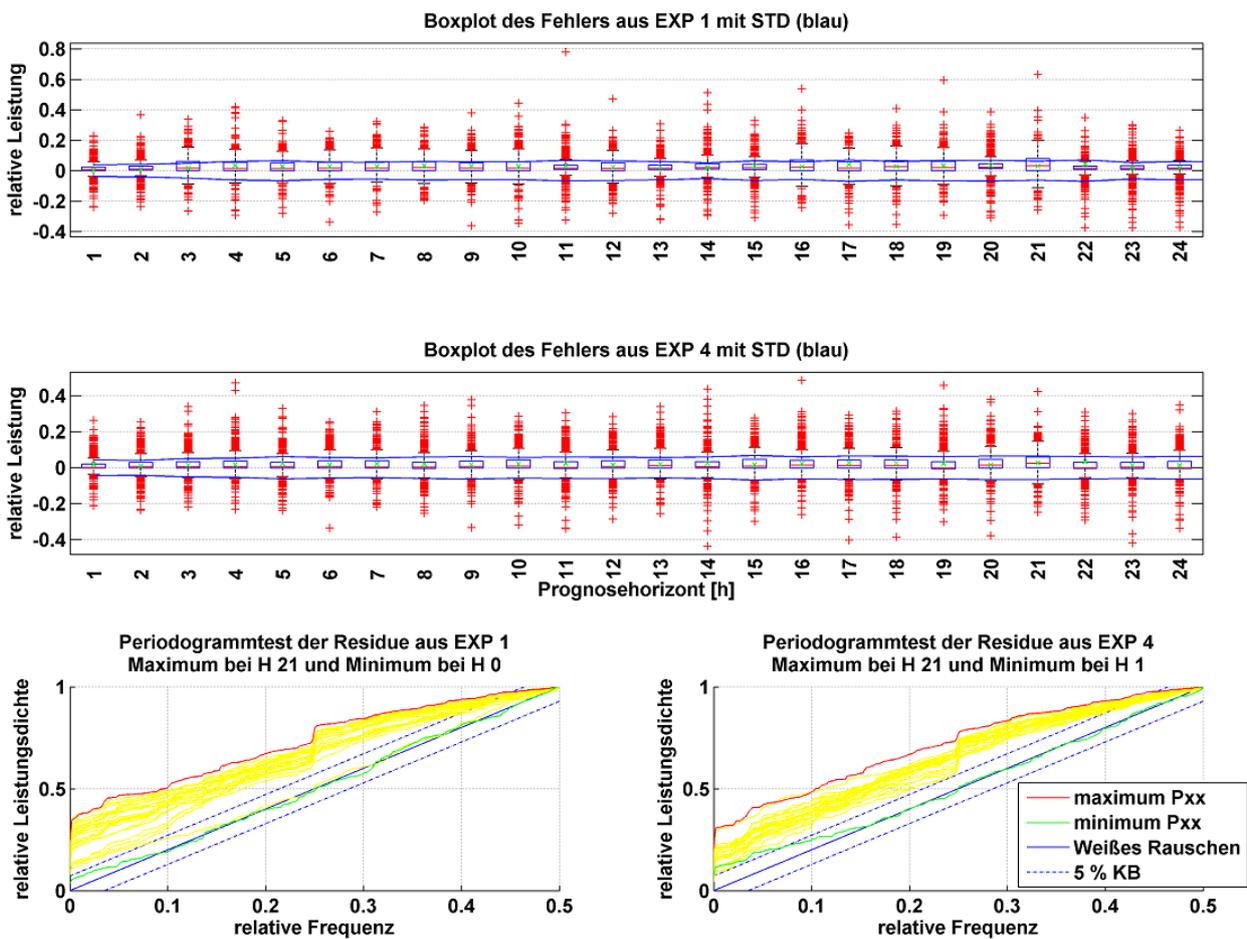


Abbildung 3.21: Validierung EXP 1 mit EXP 4 mit Boxplot und Periodogrammanalyse

3.3.4 Untersuchungen zum Datenmanagement

In dem gesamten Abschnitt 3.3.3 und folgenden wurden individuelle Datenanalysen für den jeweiligen Prognosehorizont aufgestellt. Die individuellen Analysen bedingen eine verlustfreie Datenspeicherung (VDS) aller relevanten Daten. Dieses Datenmanagement wird in etablierten Systemen, z.B. zur Lastprognose, nicht eingesetzt. Stattdessen wird ein offenes Zeitreihenmanagement (OZM) eingesetzt, vgl. [38, 71, 88, 86, 196]. Das OZM speichert auf einer endlosen Zeitreihe für jeden Zeitstempel einen vorhandenen Wert ab. Dementsprechend werden auch die Ergebnisse einer Prognose je Zeitstempel abgespeichert. Somit überschreiben überlappende Prognoseläufe ältere Prognosewerte. Im VDS werden die Prognosen einzeln abgespeichert und können horzionscharf für die Analysen ausgewertet werden, siehe Abbildung 3.22.

Überlegungen zufolge ist ein OZM ausreichend, wenn kein oder ein geringfügiges systematisches Fehlerverhalten der Prognosehorizonte und ihrer Eingangsdaten vorhanden ist. Im Falle einer

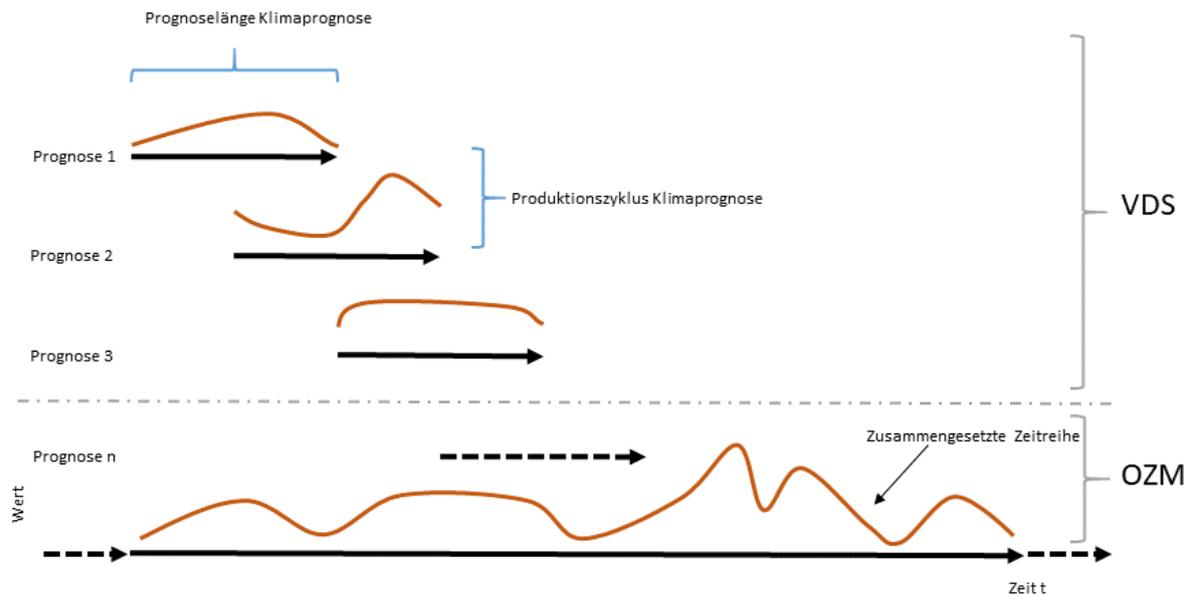


Abbildung 3.22: Vergleich Speichersystematik zwischen VDS und OZM

signifikanten Existenz kann dieser durch einen auf einem OZM aufgesetzten Prognoseprozess nicht ermittelt und berücksichtigt werden. In der Praxis wird die Wahl meist durch die zugrundeliegende Datenstruktur vorgegeben. Folgendes Beispiel soll dies veranschaulichen. Ein vorgelagerter Prognoseprozess stellt alle drei Stunden eine neue 24 Stundenprognose bereit. Ab der 10. bis zur 20. Stunde prognostiziert dieser mit einem negativen Bias. Das OZM speichert alle drei Stunden die aktuelle Prognose auf eine Zeitreihe. Dadurch ist es dem Validierungsprozess nicht möglich den Bias zu berücksichtigen und verbleibt somit nicht korrigiert in der Prognose. Das VDS kann die Standardabweichung berücksichtigen und diesen Fehler in der Prognose berücksichtigen.

In der Literatur [24, 23] wird der Fortschritt der NWP-Modelle beschrieben. Allerdings erläutern sie auch die möglichen Fehlerquellen, vgl. 2.2. Durch diese dürfen systematische Fehler nicht ausgeschlossen und müssen entsprechend geprüft werden. Weiterhin zeigen autokorrelative Untersuchungen in Abschnitt 3.3.1, dass sich der Korrelationsgehalt des Messsignals nach wenigen Prognosestunden verliert und mit zunehmendem Prognosehorizont einen schwachen Einfluss auf das Prognoseziel hat. Somit ist ein Prognosesystem weitestgehend abhängig von der Prognosequalität der verwendeten NWP-Daten. Das wird durch die Verwendung des multiplen Korrelationskoeffizienten in Tabelle 3.6 belegt. Hier wird für jeden Horizont ein individueller Zusammenhang aus den zur Verfügung stehenden Parametern ermittelt und es zeigt sich, dass die Messwerte schon nach wenigen Horizonten keinen relevanten Einfluss ausüben.

Vier Experimente sollen den Einfluss des Datenmanagementsystems auf die Prognose untersuchen. Sie verwenden wie die vorangegangenen EXP das ARX-Modell nach Gleichung (2.4), welches die selektierten Eingangsdaten der Datenanalyse verwendet. Als Datenanalysemethode wird ein MKK nach Gleichung (3.6) mit einer Anstiegsoptimierung verwendet.

EXP 4: Das Experiment verwendet die VDS und dient als Referenzmodell für die folgenden Experimente. Es wurde im Abschnitt 3.3.3 eingesetzt und Abbildung 3.18 dargestellt. Im Prinzip ist der Modellaufbau für die EXP 5 bis EXP 7 ist identisch. Die Werte der Zeitreihen sind unterschiedlich, wie folgend erklärt wird. Es führt individuelle Datenanalysen aus und verwendet ein individuelles Prognosemodell für jeden Prognosehorizont. Abbildung 3.23 verdeutlicht grafisch das Prinzip. Um den Prognosehorizont t_{0-k} zu berechnen, werden die historischen Prognosen t_{0+k-p} und $t_{0+k-2*p}$ verwendet. Der Zeitpunkt wird mit t beschrieben, der Zeitpunkt zur Ausführung einer Prognose mit t_0 , der Prognosehorizont mit $k \in \mathbb{N}$ und der Produktionszyklus vorgelagerter Prognosen mit $p \in \mathbb{N}$.

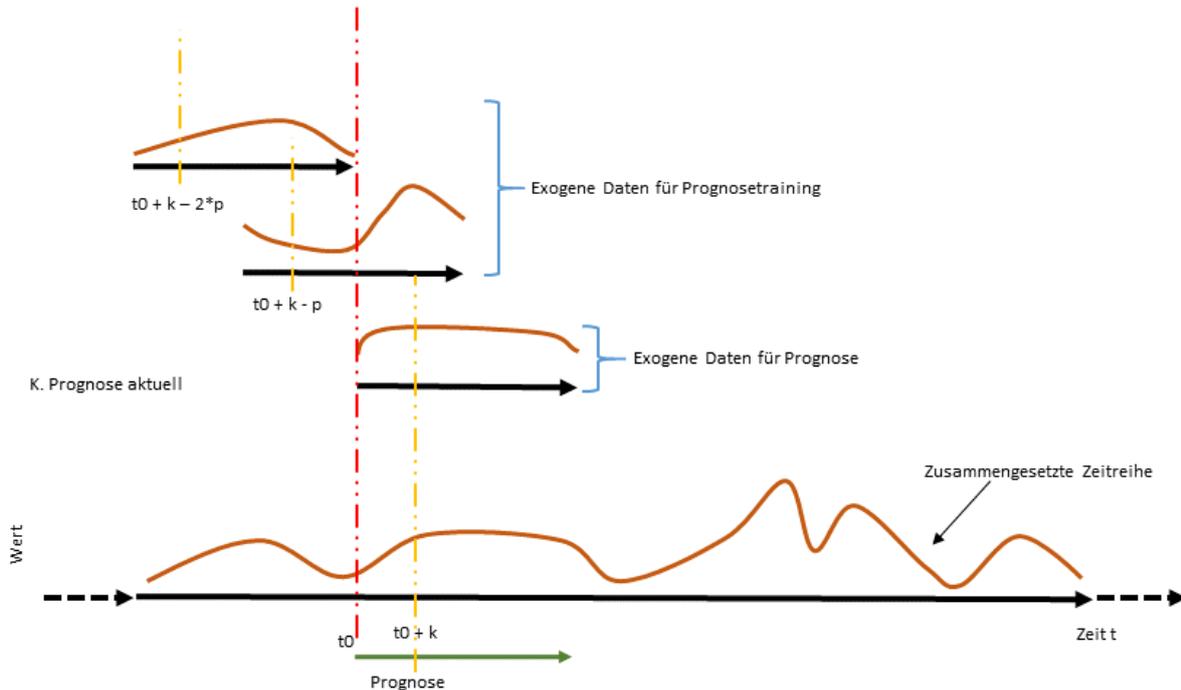


Abbildung 3.23: Datenzusammenhänge EXP 4 für ein VDS System

EXP 5: In dieser Berechnung wird für die Datenanalyse ein OZM Datensatz erzeugt und eine Analyse für alle Horizonte durchgeführt. Das Analyseergebnis wird auf die Prognose angewendet mit einem VDS analog zu EXP 4. Mit diesem Experiment soll der Einfluss der Datenanalyse ermittelt werden. Die angewandte Datenanalyse entspricht einem Vorgehensmodell für eine Lastprognose von Privatkunden eines Energieversorgers.

EXP 6: Alle Daten werden in ein OZM transformiert, analysiert und prognostiziert. Bei diesem Vorgang, dargestellt in Abbildung 3.24, werden immer noch die gleichen relativen Datensätze (gelbe Markierungen) zum Training und für die Prognose eingesetzt. In diesem Experiment wird erwartet, dass die Prognoseergebnisse für den nicht überschriebenen Zeitbereich identisch mit EXP 4 sind. In dem hier verwendeten Datensatz sind das die ersten drei Stunden.

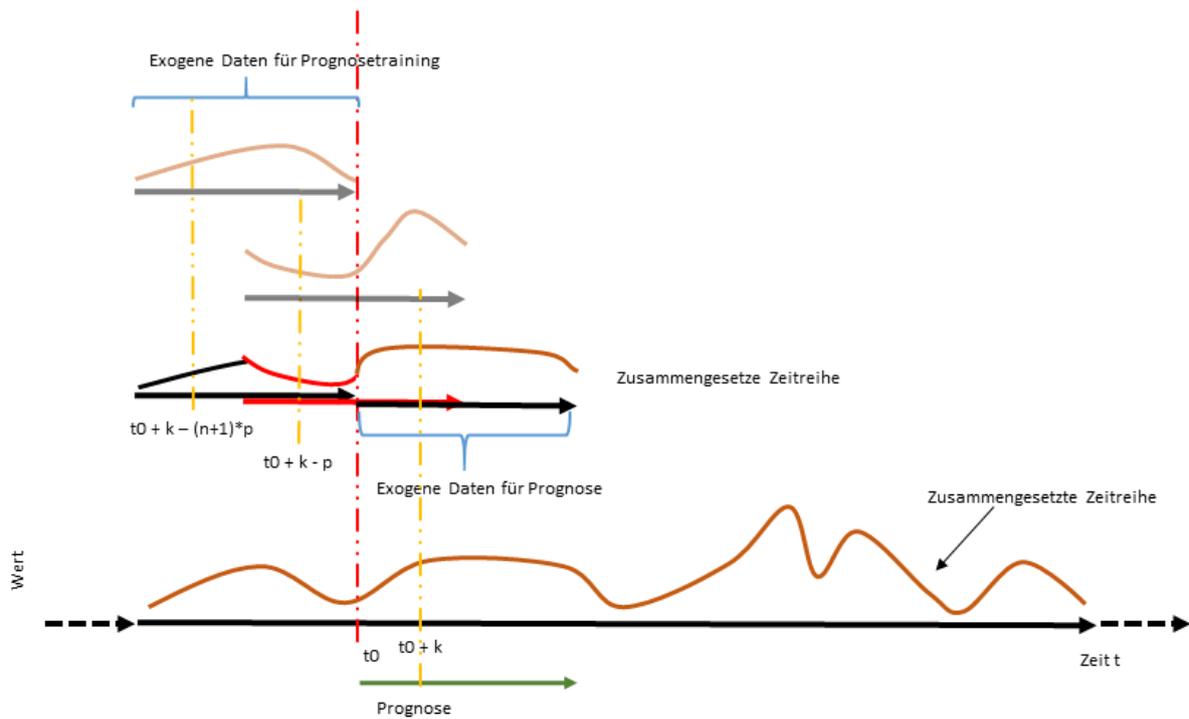


Abbildung 3.24: EXP6 - Darstellung Transformierung VDS zu OZM mit festhalten der Trainingsdatenpunkte

EXP 7: Dieses Experiment stellt ein komplettes OZM dar. Im EXP 6 werden die relativen Datenpunkte aus einem VDS Ansatz verwendet. In einem reinen OZM Ansatz wird der ganze zur Verfügung stehende Zeitraum verwendet, sofern keine Muster für eine feinere Klassifizierung erkennbar sind. Hier wird der gesamte Trainingszeitraum zum Training der Prognose eingesetzt, vgl. Abbildung 3.25 gegenüber 3.24. Weiterhin sind die Datenanalysergebnisse von EXP 5 und EXP 7 identisch, weil die identischen OZM Datenbasen zur Verfügung standen.

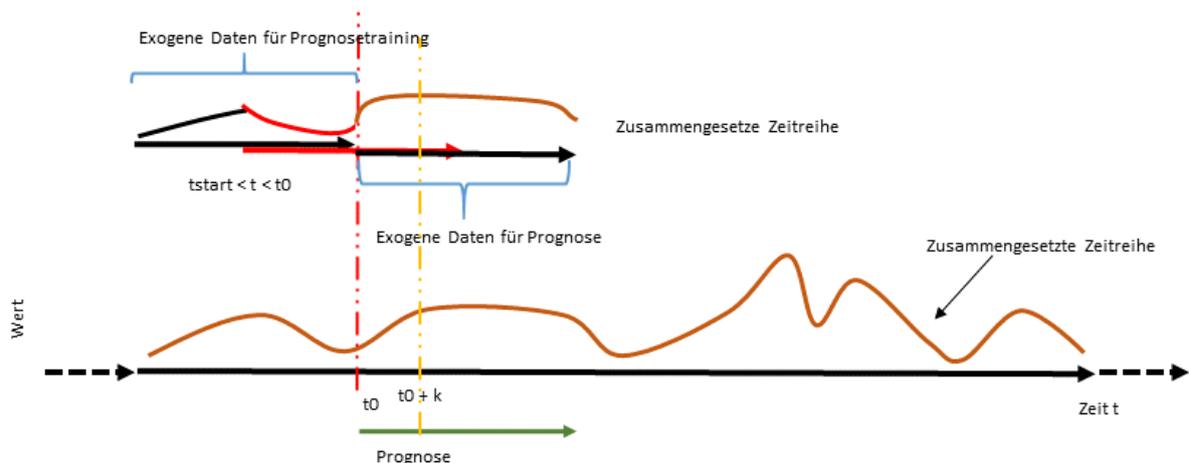


Abbildung 3.25: EXP 7 - OZM Prognose mit ununterbrochenen Trainingszeitraum

Für die Auswertung wird der NRMSE aus Tabelle 3.1 und die Verbesserung Imp nach Gleichung (3.1) mit diesem eingesetzt. Der Vergleich wird immer mit EXP 4 durchgeführt. Positive Werte von Imp zeigen eine Verbesserung und negative eine Verschlechterung an. Die Analysen zeigen insgesamt eine Verschlechterung gegenüber EXP 4, vgl. Tabelle 3.7. Am

besten hat sich EXP 6 verhalten mit $-15,66\%$ und am schlechtesten EXP 5 mit $-39,16\%$. In den folgenden Abbildungen 3.26 bis 3.28 werden die Fehlerberechnungen individuell für jeden Horizont (H) dargestellt. Die Abbildungen sind zweigeteilt. Die obere Grafik zeigt den NRMSE Verlauf und die untere die Verbesserung. Blau ist immer die Referenz EXP 4 und rot das jeweilige Vergleichsmodell.

Tabelle 3.7: Mittlere Verbesserung von EXP 4 gegenüber EXP 5 - 7

<i>Imp</i>	EXP 5	EXP 6	EXP 7
EXP 4	$-39,16\%$	$-15,66\%$	$-30,28\%$

EXP 5: Es zeigt sich eine Verschlechterung von $-13,74\%$ bei Horizont 21 bis $-142,90\%$ bei Horizont 22. Auffällig sind die starken Fehlerentwicklungen am Beginn und Ende der Horizonte. Diese Bereiche markieren Änderungen in den Datensätzen. Horizont 0 bildet den Ist-Zustand des Systems ab. Damit das Modell nicht die Leistungsmessung für den nullten Prognosehorizont verwendet, werden diesem in der Datenanalyse die Messwerte zum Zeitpunkt t_0 verweigert. Würden die Messwerte anliegen, wäre der Prognosefehler 0% , weil die Analysealgorithmen die Leistung als stärksten funktionalen Zusammenhang aufschalten. Des Weiteren entnimmt der Horizontbereich 22 bis 24 die Daten aus einem anderen COSMO Modell. Das Ergebnis zeigt, dass die Zusammensetzung der Ausgangsdatenbasis mit einer OZM Analyse schlechter prognostiziert werden kann als mit einer VDS Analyse. VDS ermöglicht es individuell auf Horizontspezifika einzugehen. Der Bereich von Horizont 1 bis 21 ist besser an das Prognoseziel angepasst. Hier beträgt die Verbesserung $-23,95\%$ und das Betragsmaximum reduziert sich auf $-31,76\%$. In dem Bereich verhält sich EXP 5 besser als EXP 7. Somit haben die VDS Systemanteile im Prognoseschritt einen positiven Einfluss auf das Prognoseergebnis, weil die Datenanalyse identisch mit EXP 7 ist.

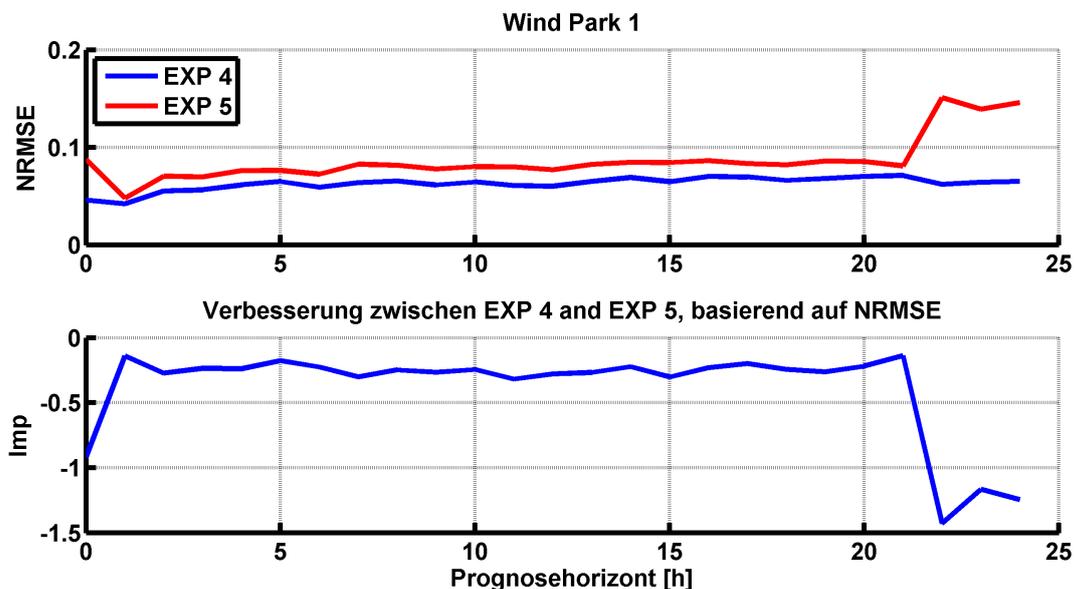


Abbildung 3.26: Horizont scharfe Auswertung zwischen EXP 4 und EXP 5

EXP 6: Die Verbesserung variiert von 2,25% bei Horizont 8 bis $-42,77\%$ bei Horizont 12. Der Fehler verhält sich wie eine Sägezahnswingung. Das Verhalten deutet auf einen stark systematischen Fehler hin. Details zu diesem Fehlerverhalten werden nach Auswertung der Datenmodelle berücksichtigt. Die Übereinstimmung der Horizonte 0 bis 2 entspricht den Erwartungen der Versuchsplanung.

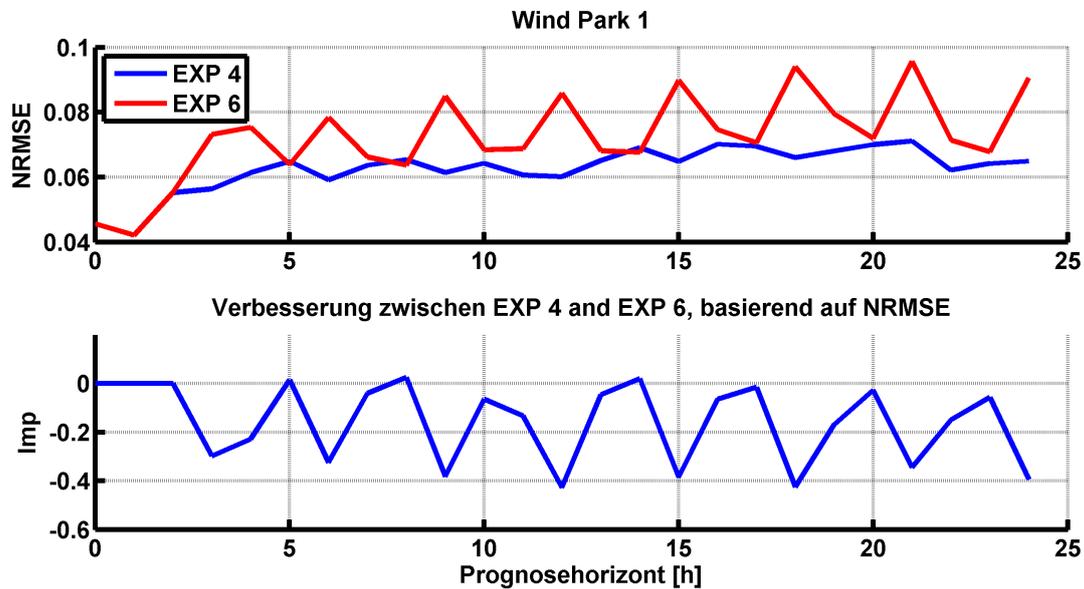


Abbildung 3.27: Horizont scharfe Auswertung zwischen EXP 4 und EXP 6

EXP 7: Die Verbesserung zeigt eine kontinuierliche Verschlechterung von $-19,08\%$ bei Horizont 21 bis $-44,53\%$ bei Horizont 6. Der Fehlerverlauf über die Horizonte ist insgesamt glatter als bei den anderen Experimenten. Gegenüber EXP 7 treten keine Ausreißer mehr auf. Zum einen stehen mehr Trainingsdaten für die Prognose zur Verfügung. Die Quantität mittelt Extrema im Training aus den Datensätzen. Zum anderen kann es durch den OZM Datensatz für die Prognose im Vergleich zum VDS in EXP 7 zu Fehlerauslöschungseffekten kommen. Insgesamt verhält sich der OZM Ansatz für diese Experimente am schlechtesten, wenn bei EXP 7 die Ausreißer nicht berücksichtigt werden.

Die Ergebnisse zeigen, dass sich die Prognosen schlechter verhalten, je mehr sie einem OZM Ansatz entsprechen. Das lässt vermuten, dass systematische Fehler in den vorgelagerten Klimaprognosen vorhanden sind, die durch den OZM Ansatz nicht berücksichtigt werden können. Mit Hilfe der Validierungsmethodik werden die neuen Experimente auf ihre Fehler und gegen weißes Rauschen getestet. Für den Periodogrammtest wird EXP 4 als Referenz verwendet. EXP 7 zeigt gegenüber EXP 4, vgl. Abbildung 3.29 mit 3.21, eine stärkere Streuung der Fehler im Boxplot. Das Periodogramm entfernt sich weiter vom weißen Rauschen als EXP 4. Entsprechend der Ergebnisse existiert in beiden Experimenten eine bleibende funktionale Restinformation. Die eigentlichen Prognosemodelle sind für diese Berechnung noch nicht optimiert auf das Prognoseproblem. Die verbleibende Restinformation wird im Abschnitt 3.4 der Prognosemodellierung behandelt.

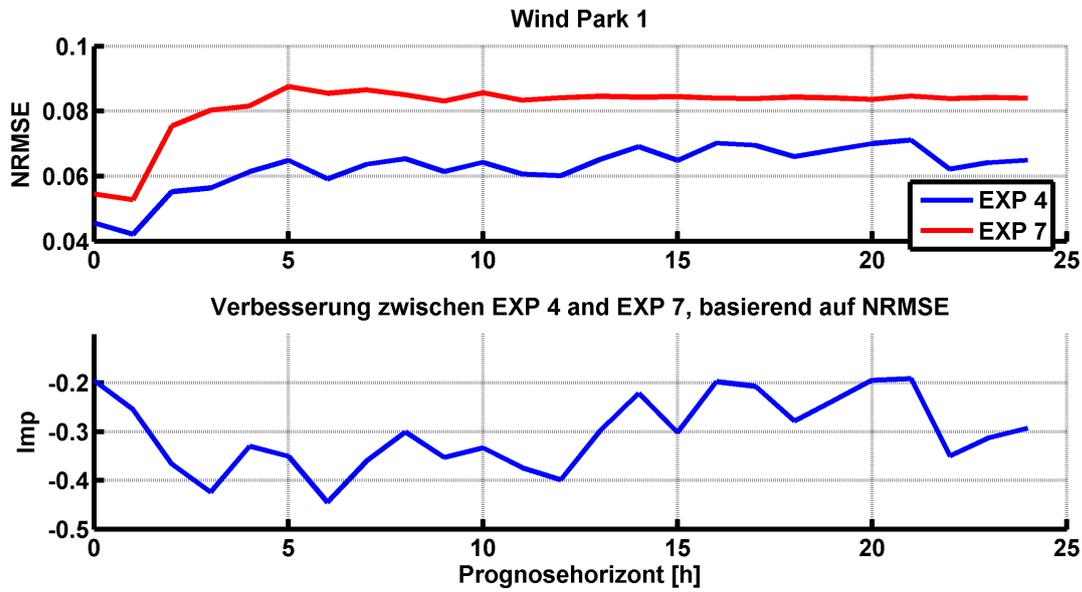


Abbildung 3.28: Horizont scharfe Auswertung zwischen EXP 4 und EXP 7

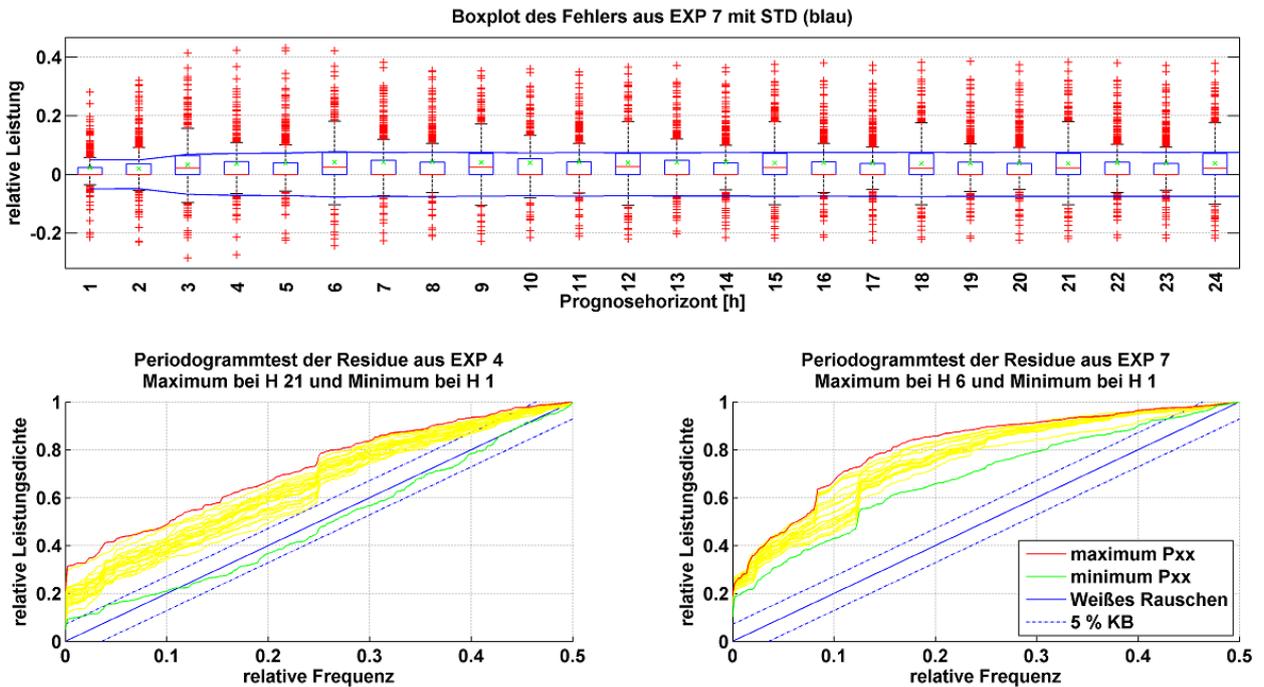


Abbildung 3.29: Validierung EXP 7 mit Boxplot und Periodogramm gegen EXP 4

EXP 6 zeigt in Abbildung 3.27 eine ausgeprägte Sägezahnswingung. Im Unterschied zu EXP 7 wurde hier die Datenanalyse mit einem OZM und die Prognose mit einem VDS Ansatz berechnet. Der Vergleich der Boxplots in Abbildungen 3.30 und 3.21 zeigt eine stärkere Streuung der extremen Fehler in EXP 6 gegenüber EXP 4. Ebenso haben die Periodogramme einen größeren Abstand zum weißen Rauschen als in EXP 4. EXP 7 hat einen noch größeren Abstand gegenüber EXP 6. Die Validierungsergebnisse für EXP 5 sind im Anhang C in Abbildung C.1 dargestellt.

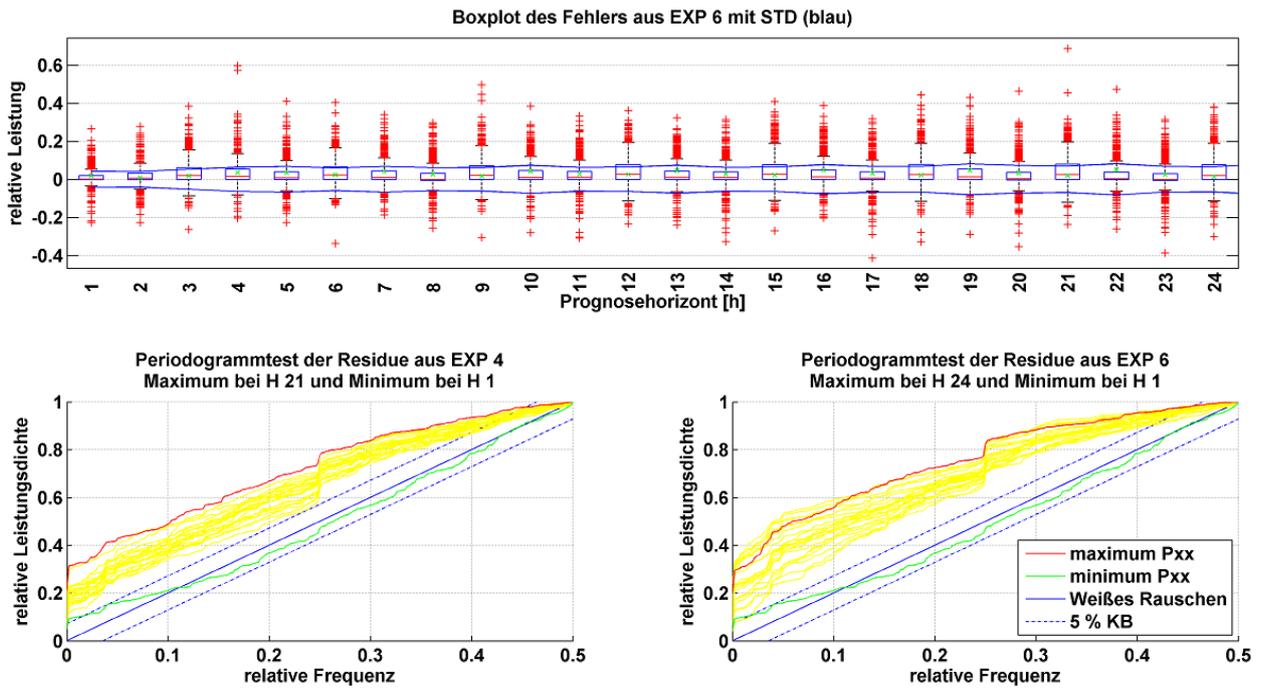


Abbildung 3.30: Validierung EXP 6 mit Boxplot und Periodogramm gegen EXP 4

Das ausgeprägte Fehlerverhalten in EXP 6 ist bedingt durch die lokalen Werte der Klimaprognosen. Für WP 1 wurde der Fehler der NWP Prognosen auf die Messwerte einer Klimastation untersucht. Dazu wurden die zwei nächst gelegenen NWP Gitterpunkte in Stationsnähe ausgewertet. Dazu wurden alle Prognoseläufe übereinandergelegt und horizontabhängig untersucht. Dabei wird erkenntlich, dass die Luftgeschwindigkeit und die Lufttemperatur Ursache des Fehlerverhaltens in EXP 6 sind. Als Beispiel ist Abbildung 3.31 aufgeführt, welche die Windgeschwindigkeit zeigt. Für die Analysen werden zum einen die Güte in [%], der MAE in [m/s] sowie eine Boxplot-Darstellung der Fehler verwendet. Die Güte ist definiert mit:

$$\text{Güte} = 100 - 100 * \left(\frac{1}{N} \sum \frac{|\hat{x} - x|}{x} \right), \quad (3.13)$$

und der MAE mit:

$$MAE = \frac{1}{N} \sum \frac{|\hat{x} - x|}{x}. \quad (3.14)$$

In der oberen Teilgrafik 3.31 werden in einem YY-Liniendiagramm die Güte, blau und gelb, und der MAE, ocker und grün, der NWP Gitterpunkte zum Messpunkt dargestellt. Die unteren beiden Teilgrafiken zeigen Boxplots der jeweiligen Fehler.

Der mittlere Fehlerverlauf zeigt eine sägezahnartige Schwingung. Ursachen für dieses Verhalten können nicht ermittelt werden, ohne die zu zugrundeliegenden Klimamodelle näher in diesem Kontext zu analysieren. Die Boxplots zeigen für beide Gitterpunkte einen positiven Median über alle Horizonte. Die positiven Ausreißer überwiegen in Anzahl und Größe die negativen.

Im Mittel kann aus den Daten eine Fehlersystematik der vorgelagerten Klimaprognose für diesen Datenpunkt ermittelt und berücksichtigt werden. Diese ist jedoch von der Auswertung der verfügbaren Daten in einem VDS abhängig und geht in einem OZM verloren.

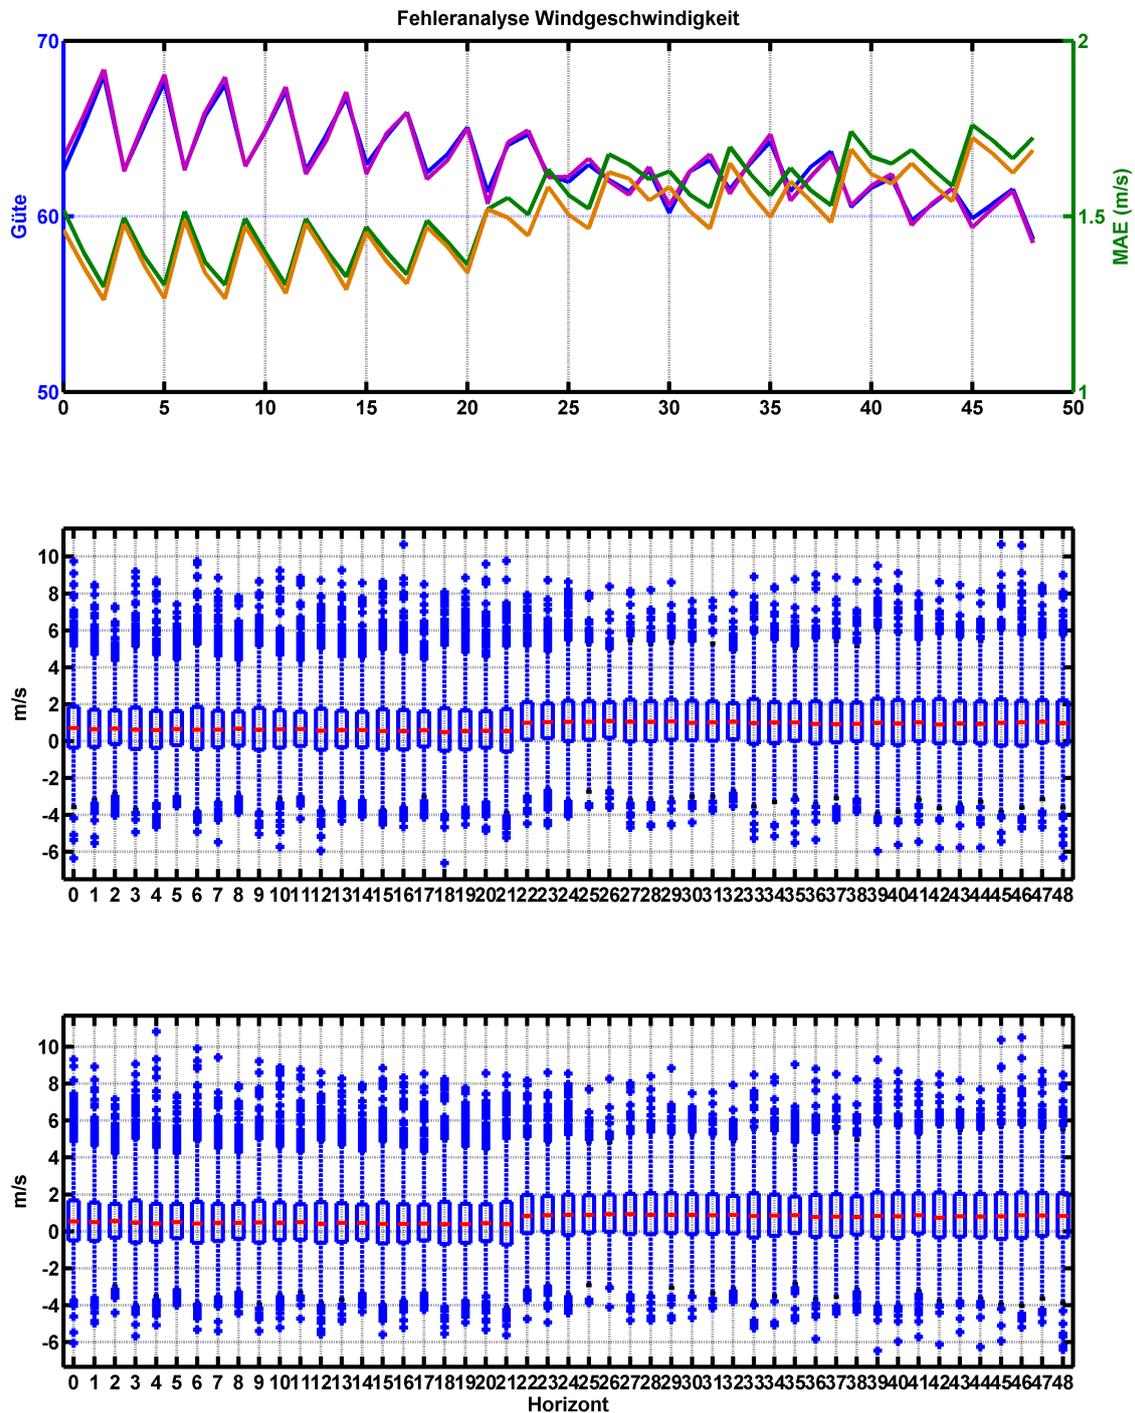


Abbildung 3.31: Fehleranalyse Windgeschwindigkeitsmessung mit Klimaprognose

3.3.5 Informationsanalyse

Die Informationsanalyse ermittelt wie viel Aussagekraft über Menge Y durch die Beobachtung der Menge X enthalten ist, vgl. [99, 60]. Übertragen auf die Fragestellungen bedeutet das, inwieweit Informationen über das Einspeiseverhalten eines Windparks erhalten werden können, wenn z.B. die Windgeschwindigkeit gemessen wird. Die Information ist gegenseitig. Das heißt umgekehrt kann auch durch die Messung des Einspeiseverhaltens Aussagen über die Windgeschwindigkeit getroffen werden. Die wechselseitige Information $I(X;Y)$, vgl. Abbildung 3.32, zwischen zwei Mengen X und Y ist wie folgt definiert [99, S. 24]:

$$I(X;Y) = H(X) + H(Y) - H(XY). \quad (3.15)$$

$H(X)$ ist die ermittelte Entropie der Größe X , $H(Y)$ von Y und $H(XY)$ die gemeinsame Entropie beider Größen X und Y . Die Information $I(X;Y)$ ist für den Wertebereich ≥ 0 definiert. Ein Wert von 0 bedeutet informelle Unabhängigkeit zwischen den Größen X und Y . Die Entropie ist definiert durch, vgl. [99, S. 24]:

$$H(x) = - \sum_{i=1}^n f_x(x_i) \log f_x(x_i). \quad (3.16)$$

Aufgrund der Bildungsvorschrift der Wahrscheinlichkeitsfunktionen $f_x(x_i)$ findet über den geordneten Zusammenhang der Messungen keinerlei Aussage statt. Es werden ausschließlich die Verteilungen der Größen betrachtet.

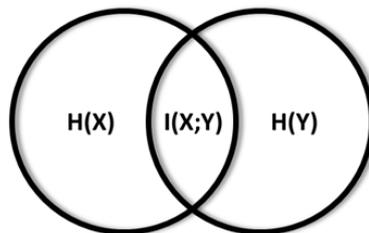


Abbildung 3.32: Wechselseitige Information

Das vorgestellte gegenseitige Informationsmaß $I(x;y)$ in Gleichung (3.15) soll auf seine Datenanalysefähigkeiten für die WLP untersucht werden. Zugrunde liegen folgende Überlegungen. Korrelative Methoden können ausschließlich lineare funktionale Zusammenhänge analysieren. Für Zeitreihen bezieht sich die Funktionalität auf die zeitdynamischen Zusammenhänge. Damit sind sie blind für rein nichtlineare Funktionalitäten. Auf Grund der Definitionen des Windleistungsertrags in Gleichung(1.1) ist bekannt, dass der Ertrag stark von den nichtlinearen Zusammenhängen seiner exogenen Größen abhängt. Das Informationsmaß beschreibt einen anderen Zusammenhang, wie aus der Gleichung (3.15) hervorgeht. $I(x;y)$ misst die Beschreibbarkeit der Menge x durch Beobachtung von y . Als Berechnungsgrundlage wird die Wahrscheinlichkeitsfunktion $f_x(x_i)$ verwendet. Sie kann empirisch aus den Messwerten über Histogramme oder Kerndichteschätzer, z.B. [32], ermittelt werden. Die Wahrscheinlichkeitsfunktion ignoriert die Zeitfunktionalität, indem sie ausschließlich auf die Eintrittswahrscheinlichkeiten der Werte eingeht. Somit bewertet die Information die

gegenseitige Aussagekraft ohne Berücksichtigung der Zeit. Damit können lineare Funktionale auch durch die Information gemessen werden, weil sie bei einer linearen Funktionalität von 100% deckungsgleiche, normierte Wahrscheinlichkeitsfunktionen liefern. Umgekehrt lässt sich kein Rückschluss bilden. Daher beinhaltet die Information nichtlineare und lineare Funktionalitäten, kann aber auch andere mathematische Charakteristiken enthalten.

Aus den Überlegungen ergibt sich ein möglicher Vorteil für das Informationsmaß. Es misst Nichtlinearitäten und Linearitäten gleichermaßen. Gleichzeitig ist die Unabhängigkeit der Zeitfunktionalität von Nachteil, weil diese ein Hauptbestandteil der Prognose ist. Zwei Untersuchungen, EXP 8 und EXP 9, sollen die Anwendungsfähigkeit beurteilen. Es wird das voran beschriebene ARX-Modell in Gleichung (2.4) verwendet.

Für die Information und Entropie wird folgend beschriebene Normierung, vgl. [159, S.28], für einen Wertebereich zwischen null und eins eingesetzt:

$$\rho = \sqrt{1 - e^{-2I}}. \quad (3.17)$$

EXP 8: In diesem Experiment wird die gemeinsame Information $I(x; y)$ (3.15) gemessen. Zu diesem Zweck werden alle Informationsmaße zwischen der gemessenen Einspeiseleistung und den exogenen Größen ermittelt. Anschließend werden mit Hilfe einer Selektionsfunktion die Größen mit der maximalen Information bestimmt.

EXP 9: In diesem Experiment wird die bedingte Entropie $H(y|x)$ bzw. $H(x|y)$ untersucht, vgl. [60, S.17]. Es soll indirekt die Information über y durch Beobachtung von x ermittelt werden, bzw. umgekehrt. Dazu wird $H(y)$ vom Anteil x bereinigt, vgl. Abbildung 3.33:

$$H(y|x) = H(xy) - H(x). \quad (3.18)$$

$H(y|x)$ beschreibt die Gesamtentropie von x und y . Die exogenen Größen mit den Minimalen $H_{y|x}$ bzw. $H_{x|y}$ werden für die Prognose selektiert.

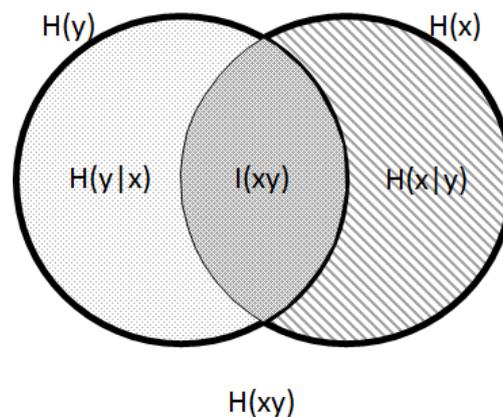


Abbildung 3.33: Darstellung Information und Entropie im Zusammenhang

EXP 10: Die Arbeiten [63, 62, 159] treffen eine Aussage über die Vorhersagbarkeit einer Größe anhand der ermittelten linearen und der nichtlinearen Information. Die Berechnung

der nichtlinearen wird in Gleichung (3.15) beschrieben. Die lineare ist wie folgt definiert, vgl. [63]:

$$I_{lin}(x; y) = -\frac{1}{2} \ln(1 - r^2(x; y)). \quad (3.19)$$

r^2 beschreibt den Korrelationskoeffizienten. Für die Bestimmung der Eingangsdaten wird nach der maximalen linearen und nichtlinearen Vorhersagbarkeit selektiert.

Für die Auswertung der Experimente wird das Prognoseergebnis mit dem EXP 4 in Abschnitt 3.3.4 verglichen.

EXP 8: Die Datenanalyse mittels der Information $I(x; y)$ war mit einem mittleren NRMSE von 6,9% erfolgreich. Gegenüber EXP 4 konnte im Mittel mit $-11,91\%$ keine Verbesserung erreicht werden. Die Auswertung des Verlaufs zeigt in Abbildung 3.34, dass insbesondere für die niedrigen Prognosehorizonte eine starke Verschlechterung gegenüber EXP 4 eintritt. Ab dem zwölften Horizont nähern sich die Fehlermaße beider Experimente an. Zum Teil ist $I(x; y)$ besser, aber nicht signifikant. Die größte Abweichung ist zwischen den Horizonten 0 H und 4 H zu messen.

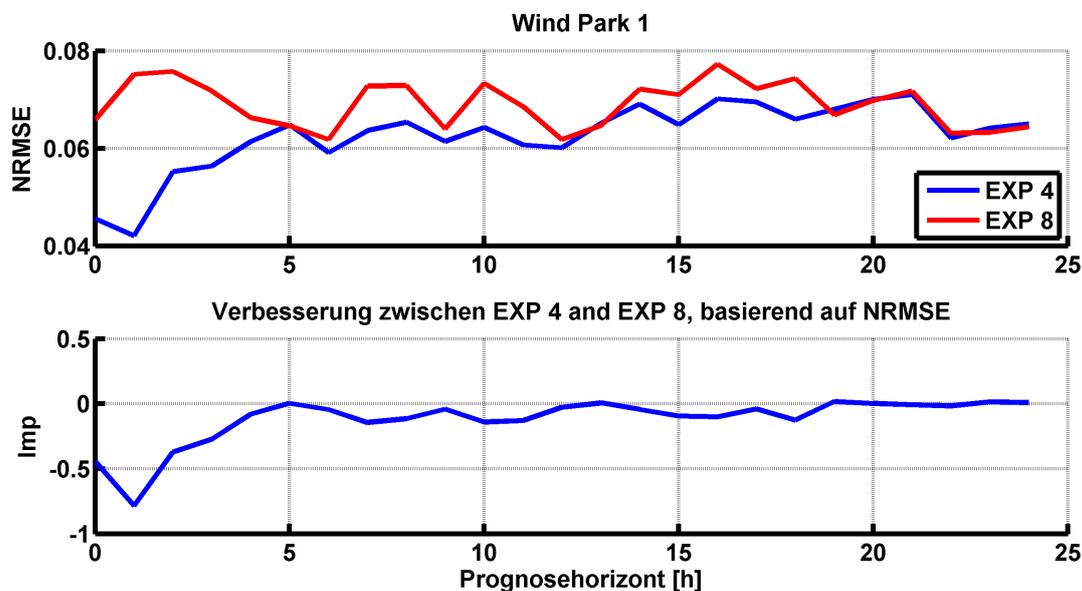


Abbildung 3.34: EXP 8 im Vergleich zu EXP 4

EXP 9: Ein Blockschaltbild mit dem Aufbau des Prognosemodells für den ersten Prognosehorizont H_1 ist in Abbildung 3.35 visualisiert worden. Die Messgrößen, der Leistungsmessung des Windparks und den auf Messungen beruhenden, exogenen Berechnungsparameter Dichtestrom DSt , wurden mit der zeitlichen Verschiebung $k - 1$ aufgeschaltet. Das entspricht dem Zeitpunkt t_0 den Startzeitpunkt der Prognose. Alle anderen exogenen und prognostizierten Parameter sind zum Zeitpunkt k aufgeschaltet.

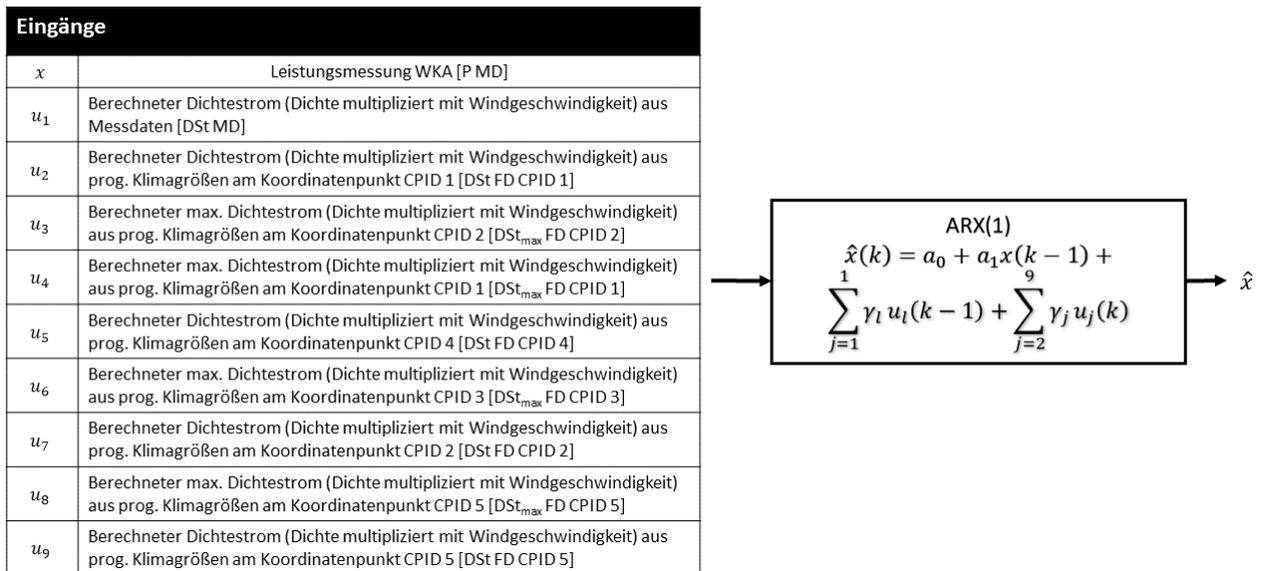


Abbildung 3.35: Blockschaltbild des Modellaufbaus für EXP 9 im Prognosehorizont H 1

Im Ergebnis war die Datenanalyse mittels der bedingten Entropie mit einem NRMSE von 6,1% erfolgreich. Gegenüber EXP 4 konnte im Mittel mit 3,03% eine Verbesserung erreicht werden. In Abbildung 3.36 ist zu erkennen, dass EXP 4 und EXP 9 sehr dicht beieinander liegen und wechselweise die besseren Ergebnisse liefern. Die bedingte Entropie liefert häufiger geringere Fehlermaße gegenüber dem MKK aus EXP 4.

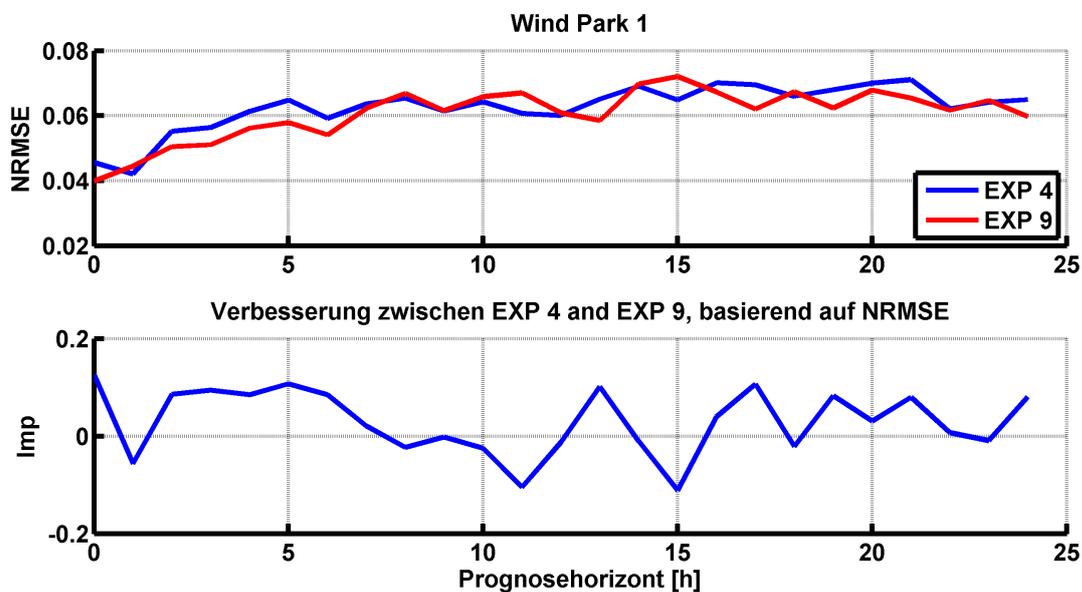


Abbildung 3.36: EXP 9 im Vergleich zu EXP 4

EXP 10: Das Blockschaltbild für das erhaltene ARX Modell im ersten Prognosehorizont H 1 wird in Abbildung 3.37 dargestellt. Auffällig gegenüber anderen Datenanalyseergebnissen lieferte in diesem Anwendungsfall keine Auswahl der autoregressiven Eingangsgröße der Leistungsmessung $x(k-1)$. Aus diesem Grund wurde der Eingang deaktiviert. Im strengen Sinn handelt es sich durch den fehlenden autoregressiven Anteil nur noch um ein X-Modell. Aufgrund der generischen Implementierung der Modelle ist bis auf die fehlende Eingangsbelegung der komplette ARX Algorithmus erhalten geblieben. Eine Änderung der Implementierung

war daher nicht erforderlich. Aus diesem Grund wird auf eine Neudefinition als eigenständige Modellklasse verzichtet.

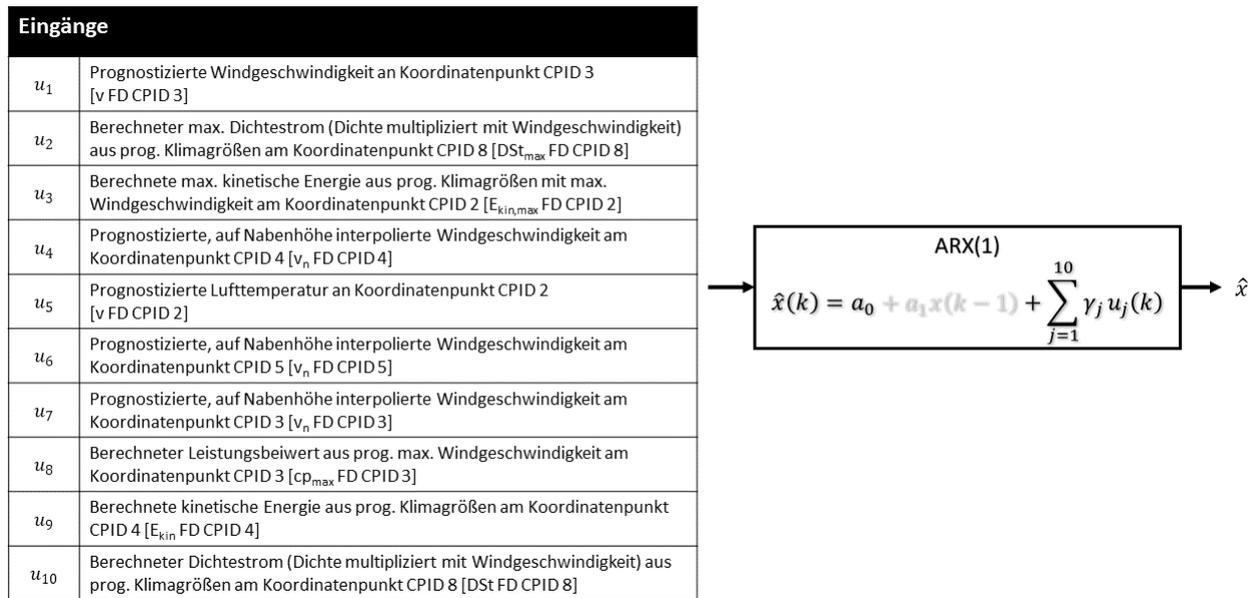


Abbildung 3.37: Blockschaltbild des Modellaufbaus für EXP 10 im Prognosehorizont H 1

Die Datenanalyse mittels der linearen und nicht linearen Vorhersagbarkeit war im Ergebnis mit einem NRMSE von 7,1% erfolgreich. Gegenüber EXP 4 konnte im Mittel mit $-13,91\%$ keine Verbesserung erreicht werden. Abbildung 3.38 zeigt ein weitestgehend kontinuierlich schlechteres Ergebnis gegenüber EXP 4. Die Horizonte 10 H, 22 H, 23 H und 24 H zeigen eine minimale Verbesserung, die jedoch nicht signifikant ist. Die größte Abweichung ist, wie bei EXP 8, zwischen den Horizonten 0 H und 4 H zu messen.

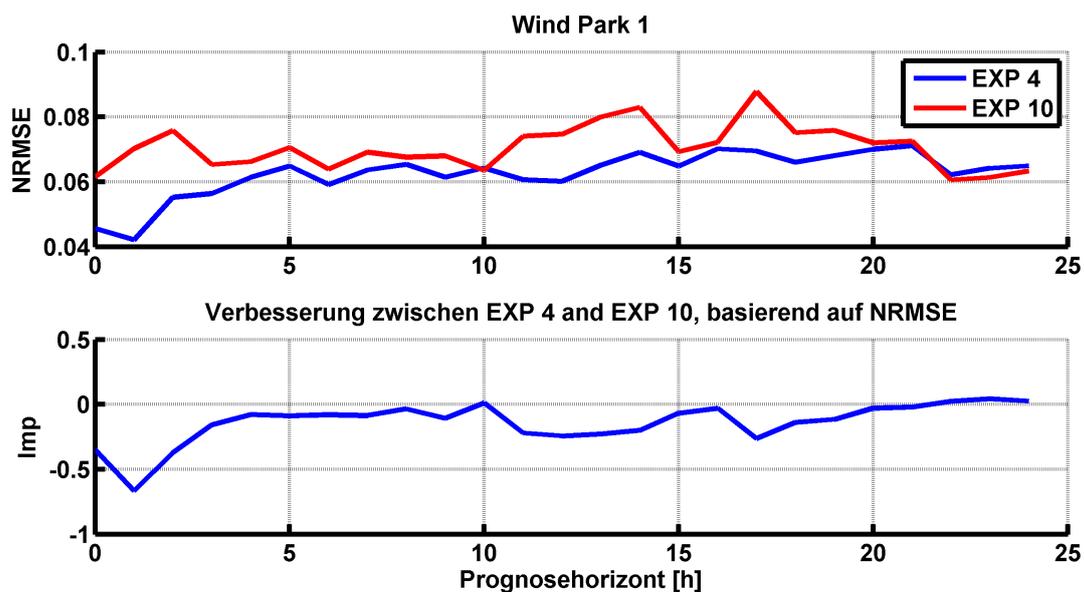


Abbildung 3.38: EXP 10 im Vergleich zu EXP 4

Die Ergebnisse erklären EXP 9 als überlegenen Analyseansatz gegenüber EXP 8 und 10. Deren Validierung wird in Anhang C in den Abbildungen C.2 und C.3 dargestellt. Die

Validierung von EXP 9 zeigt Abbildung 3.39. Der Vergleich der Boxplots zeigt, dass die Streuung der extremen Ausreißer leicht zugenommen hat. Gleichzeitig tritt bei einigen Horizonten eine Minimierung der Ausreißer auf. Der Vergleich der Periodogramme zeigt, dass sich die Kurvenschar für EXP 9 an das weiße Rauschen annähert und mehr Kurven sich im Konfidenzband befinden als bei EXP 4.

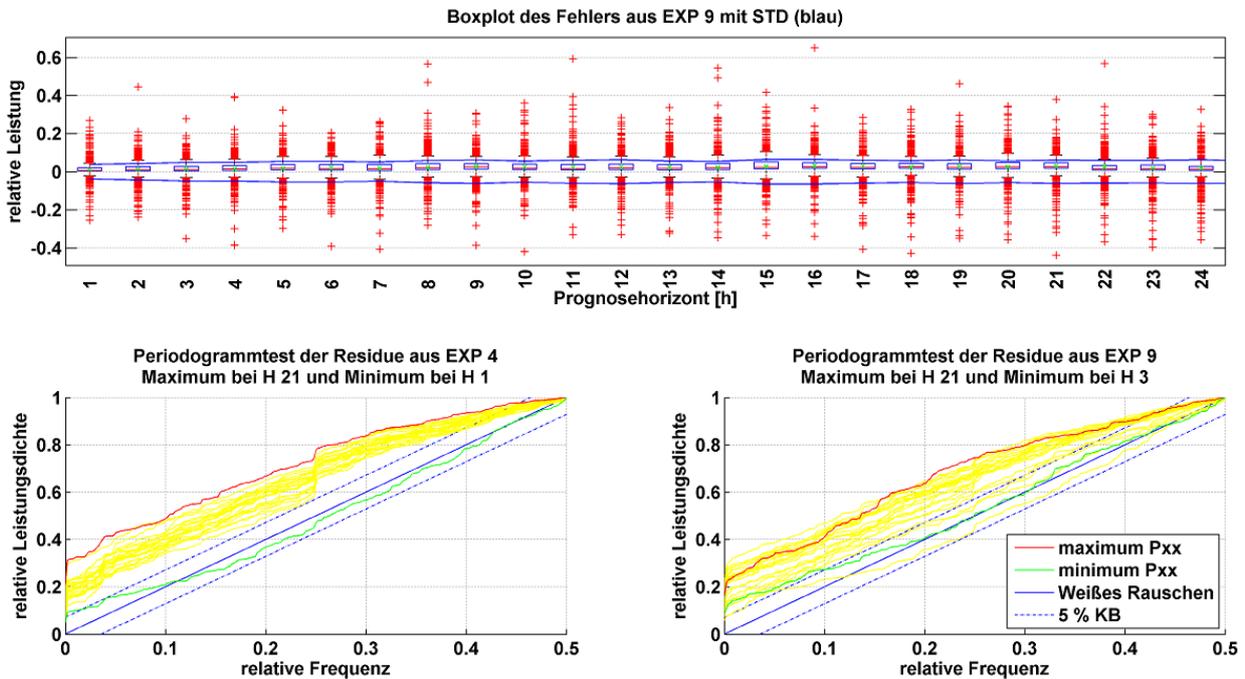


Abbildung 3.39: Validierung EXP 9 im Vergleich zu EXP 4

3.3.6 Zusammenfassung Datenanalyse

Es wurde gezeigt, dass klimatische Parameter, wie z.B. die Lufttemperatur, einen signifikanten Einfluss auf die Windleistungsproduktion haben. Diese lassen sich mit Kreuzkorrelationen nur schwer messen, weil diese in einem nichtlinearen funktionalen Zusammenhang stehen. Auf Grund der Signifikanz sind diese Werte in der Datenbasis zu integrieren.

Mittels der mathematischen Eigenschaften der Varianzanalyse, HKA, des linearen funktionalen Gesamtzusammenhangs, dem MKK und dem Informationsmaß können relevante Größen für den Prognoseprozess selektiert werden. Diese beruhen auf messbaren Auswahlkriterien und ermöglichen es ohne Expertenwissen Entscheidungen zu treffen.

Das Datenmanagement hat einen nicht zu vernachlässigenden Einfluss auf die Prognosequalität. Aufgrund nicht verfügbarer Informationen können Datenanalysealgorithmen nicht die richtigen Schlüsse ziehen. So zeigt ein offenes Zeitreihenmanagement und ein informationsverlustfreies System einen Leistungsunterschied von rund 30%. Somit ist das zugrundeliegende Datenmanagement ein Systembestandteil der Prognose.

Als ungeeignet haben sich die HKA, die MKK mit Gradientenoptimierung, die gegenseitige

Information und die lineare und nichtlineare Vorhersagbarkeit erwiesen. Als geeignete Verfahren zeigen sich die Analysen mit dem MKK unter Verwendung der Anstiegsoptimierung und mit der bedingten Entropie. Die Korrelationskoeffizienten Analyse ist eine einfache und effiziente Methode, mit der Ergebnisse plausibilisiert werden können. Die Unterschiede in allen Ergebnissen zeigen, dass mit jeder Methode unterschiedliche Eingangsbelegungen für das ARX-Modell gefunden worden sind.

3.4 Prognosemodellierung

In diesem Abschnitt wird die Prognosemodellierung vorgestellt. Entsprechend der geforderten Eigenschaften aus Tabelle 2.1 der Anforderungsanalyse werden statistische Modelle zur Prognose eingesetzt. Es wird keine eigenständige Windprognose auf Nabenhöhe als Zwischenschritt eingeführt. Die numerischen Wettermodelle dienen als exogene Datenbasis für die Prognosen. Als Referenz wird das in der Datenanalyse eingesetzte ARX-Modell in Gleichung (2.4) verwendet, das Persistenzmodell in Gleichung (3.7) und ein vereinfachtes Windertragsmodell als Systemmodell. Für die Modellierung der Prognosemodelle wird der Ergebnisdatensatz der multiplen Korrelationsanalyse, EXP 4, aus Abschnitt 3.3 verwendet.

Von den stochastischen Modellen werden die künstlichen neuronalen Netze für diese Arbeit eingesetzt. Dieser Abschnitt wird folgendermaßen aufgebaut. Zuerst werden die Referenzmodelle miteinander verglichen. Anschließend wird ein lineares stochastisches Signalmodell nach dem BOX-JENKINS-Verfahren erstellt. Darauf wird ein Vergleich mit einem ausgewählten der KNN durchgeführt. Die nachfolgenden zwei Teilabschnitte beschäftigen sich mit der Strukturoptimierung und der Optimierung des Trainingszeitraums. Im Anschluss wird ein Verfahren eingeführt, dass die Qualitätsanteile zwischen Prognose und Datenanalyse bewerten soll. Anschließend wird das Verbesserungspotential einer Metaprognose auf Basis mathematischer Charakteristiken untersucht und abschließend die Zusammenfassung der Prognosemodellierung präsentiert.

3.4.1 Analyse Referenzmodelle

Die vorgestellten Referenzmodelle können bis auf das ARX-Modell nicht ohne Einschränkungen mit dem Ergebnisdatensatz der Datenanalyse verwendet werden. Die Persistenzmethode (3.7) verwendet per Definition die letzte verfügbare Messung der Einspeiseleistung. Das Systemmodell ist auf dem klimatischen Datensatz sowie den technischen Parametern angewiesen. Es verwendet eine Korrekturfunktion durch die Methode der kleinsten Quadrate, um Anpassungen vorzunehmen. Folgend werden die Details beschrieben.

EXP 4: Das Experiment verwendet den bisherigen Referenzdatensatz, vgl. Abbildung 3.18. Als Eingangsdaten werden die ausgewählten Parameter der MKK-Analyse verwendet und das ARX-Modell in Gleichung (2.4).

EXP 11: Das Experiment untersucht das Fehlerverhalten des einfachen Persistenzalgorithmus in Gleichung (3.7), vgl. Abbildung 3.4. Per Definition wird die letzte verfügbare Messung der Einspeiseleistung für die Prognose berücksichtigt. Es gibt Erweiterungen dieses Algorithmus, z.B. [144], die nicht näher berücksichtigt werden.

EXP 12: Das Experiment verwendet den Windertrag in Gleichung (1.1) zur Berechnung der Leistung als ein vereinfachtes Systemmodell, vgl. Abbildung 3.8. Mit Hilfe der multi-

plen Regression wird eine gewichtete Summe über die Gitterkoordinatenpunkte des NWP gebildet und gleichzeitig eine implizite Korrektur über den Trainingszeitraum berechnet. Alle höhenabhängigen Parameter wurden auf Nabenhöhe interpoliert. Das Modell verwendet die Leistungsmessung nur zu Trainings- und Validierungszwecken.

Die Auswertung in Abbildung 3.40 zeigt, dass das ARX Modell aus EXP 4 die besten Prognoseergebnisse auf Basis der vorgelagerten Datenanalyse mit 6,2512% NRMSE liefert. Das Persistenzmodell, welches in EXP 11 verwendet wird, hat einen mittleren NRMSE von 9,0818%. In Horizont 0 hat es keinen Fehler, weil der Messwert eingeschaltet wird. Im Horizont 1 ist das ARX Modell nur minimal besser als das Persistenzmodell. Bis Horizont 8 nimmt der Fehler kontinuierlich zu und stagniert. Das EXP 12 hat einen Fehler von ca. 10,673% NRMSE schwankend von Horizont 0 bis 21 danach nimmt der Fehler zu. Somit ist im Mittel und absolut das ARX Modell das beste Modell. Die 0% Fehler des Persistenzmodells haben keine praktische Relevanz. Die geringe Abweichung zwischen den Ergebnissen des ARX und Persistenzmodells empfiehlt letzteres als Alternative im Prognosebereich bis zu 1 – 2 Stunde/-n neben dem ARX Modell. Die Validierung für EXP 4 ist in Abbildung 3.21 dargestellt, die für die EXP 11 und 12 im Anhang C in den Abbildungen C.4 und C.5. Sie bestätigen die schlechtere Modellbildungsfähigkeit sowohl im Vergleich der Boxplots wie auch der Periodogramme.

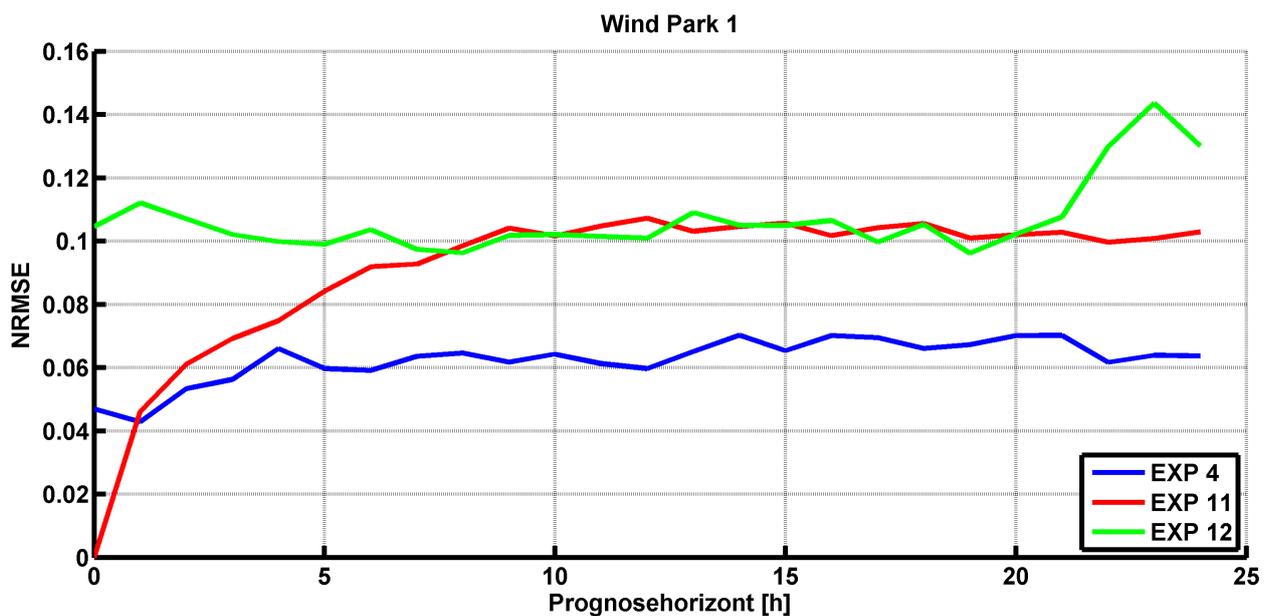


Abbildung 3.40: Vergleich Referenzmodelle

3.4.2 Modellierung lineares stochastisches Signalmodell

In diesem Abschnitt erfolgt die Modellierung des linearen stochastischen Signalmodells. Einige Vertreter wurden in den Grundlagen Abschnitt 2.3.1 eingeführt. Die Validierung im Abschnitt 3.1 setzt für die Validierungsrechnungen ein ARX(1)-Modell an ohne den Modellbildungsprozess zu berücksichtigen. In diesem Abschnitt werden die Ergebnisse der Datenanalyse, insbesondere der korrelativen Untersuchungen, auf die Modellklasse der linearen

3.4 Prognosemodellierung

stochastischen Signalmodelle angewendet. Es kommt das BOX-JENKINS-Verfahren zum Einsatz.

Zuerst wird die Windleistung des WP 1 in die geeignete Modellklasse anhand der charakteristischen Eigenschaften der Autokorrelations- und partiellen Autokorrelationsanalyse, vgl. Abschnitt 3.1.3, in Abbildung 3.5 eingeordnet. Dazu werden die beschriebenen Eigenschaften der einzelnen Modelle herangezogen, vgl. [33, S. 84]. Die AKF hat einen Verlauf einer gedämpften, auslaufenden Exponentialfunktion. Somit entspricht sie einem AR oder ARMA Prozess. Für einen MA Prozess müsste sie nach einer Ordnung n abbrechen. Die PAKF bricht nach der ersten Ordnung unterhalb des Unsicherheitskriteriums von 5% ab und hat noch zwei signifikante Korrelationen für eine Verschiebung von drei und acht. Damit entspricht es einem AR Prozess. Für einen ARMA Prozess hätte sie gedämpft auslaufen müssen. Die Datenanalyse entsprechend Abschnitt 3.3 belegt, dass der Prozess von exogenen Größen abhängig ist. Auf Basis dieser Analyse ist ein ARX zu verwenden.

Die Ordnung des ARX-Modells kann anhand der PAKF abgeschätzt werden. In Abbildung 3.5 hat sie für die erste Verschiebung einen Korrelationskoeffizienten von ca. 90%. Der zweite signifikante Koeffizient mit ca. 18% hat die Verschiebung drei. Dementsprechend kommen zwei Konfigurationen in Betracht ARX(1) und ARX(3) ohne den Anteil der zweiten Ordnung. Das ARX(1) Modell wurde im Abschnitt 3.3 und in den Referenzmodellen eingesetzt. Das ARX(1) wird mit dem Eingangsdatenmodell aus EXP 4, vgl. Abbildung 3.18, mit dem ARX(3) in EXP 13 verglichen, Abbildung 3.41.

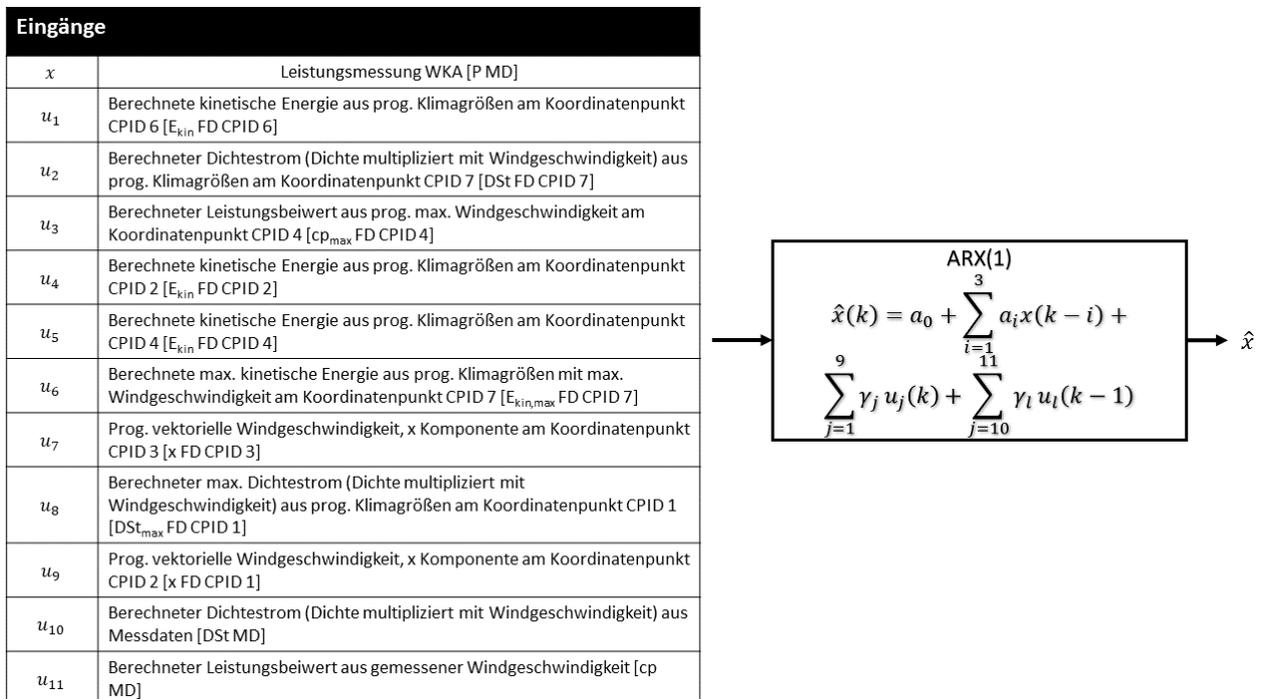


Abbildung 3.41: Blockschaltbild des Modellaufbaus für EXP 13 im Prognosehorizont $H = 1$

Der Vergleich der Ergebnisse zeigt, dass durch die höhere Ordnung entsprechend der Analyse keine signifikante Verbesserung erzielt wurde. Der mittlere NRMSE sinkt von 6,25% NRMS in EXP 4 auf 6,22% NRMSE in EXP 13. Der Verlauf der Fehlerkurven in Abbildung 3.42

zeigt, dass je Horizont nur minimale oder keine Verbesserungen erreicht werden können. Die Verbesserung nach Gleichung (3.1) erzielt einen Wert von 0,4%. Der Vergleich der Boxplots und Periodogramme zeigt geringfügige Unterschiede, vgl. Abbildung C.6. Die geringfügige Verbesserung rechtfertigt keine Verwendung eines ARX(3)-Modells.

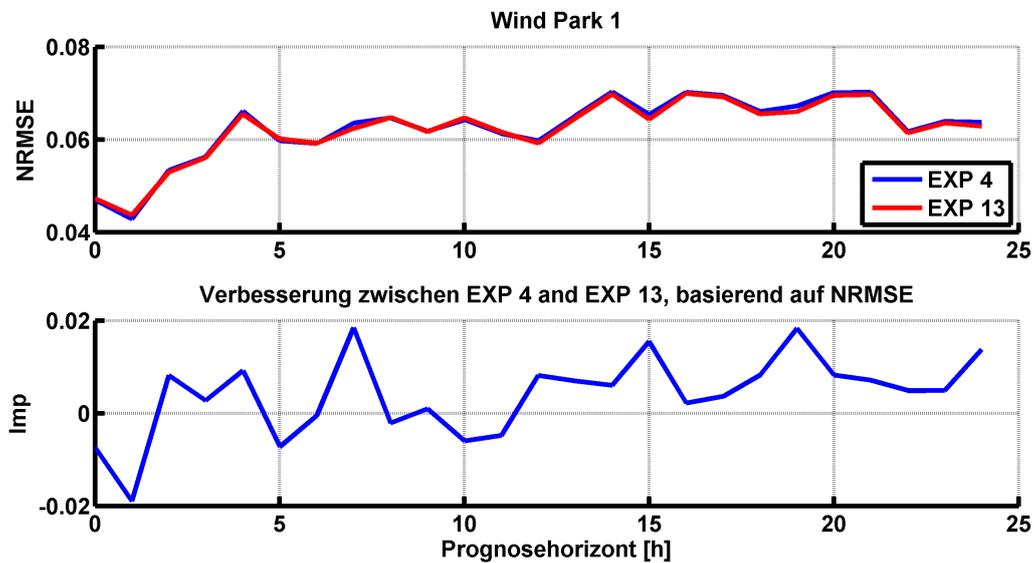


Abbildung 3.42: Vergleich ARX(3) in EXP 13 mit EXP 4

3.4.3 Auswahl Netzwerkarchitektur

Künstliche neuronale Netze wurden im Abschnitt 2.3.2 kurz eingeführt. Die Auswahl der zu untersuchenden KNN als Vertreter der nichtlinearen stochastischen Signalmodelle wurde durch folgende Überlegungen beeinflusst. Anhand der Ertragskennlinie in Abhängigkeit der Windgeschwindigkeit, Abbildung 3.43, wird ersichtlich, dass eine Sigmoid-Funktion vorliegt. Dieses nichtlineare Übertragungsverhalten kann mit Hilfe KNN abgebildet werden. Weiterhin wurde der nichtlineare Zusammenhang der exogenen Eingangsgrößen zur Windleistung durch die Datenanalysen in Abschnitt 3.3 dargestellt. Die Modelleigenschaften der KNN bilden einen weiteren Vorteil. Sie ermöglichen das Training mit unvollständigen Datensätzen und erzeugen dennoch generalisierte Modelle. Die Eigenschaft ist wichtig, wenn keine ausreichenden Daten zur Verfügung stehen. Beispielsweise liegen für WP 1 im vorliegenden Datensatz kaum Messungen für Windgeschwindigkeiten oberhalb von 21 m/s vor.

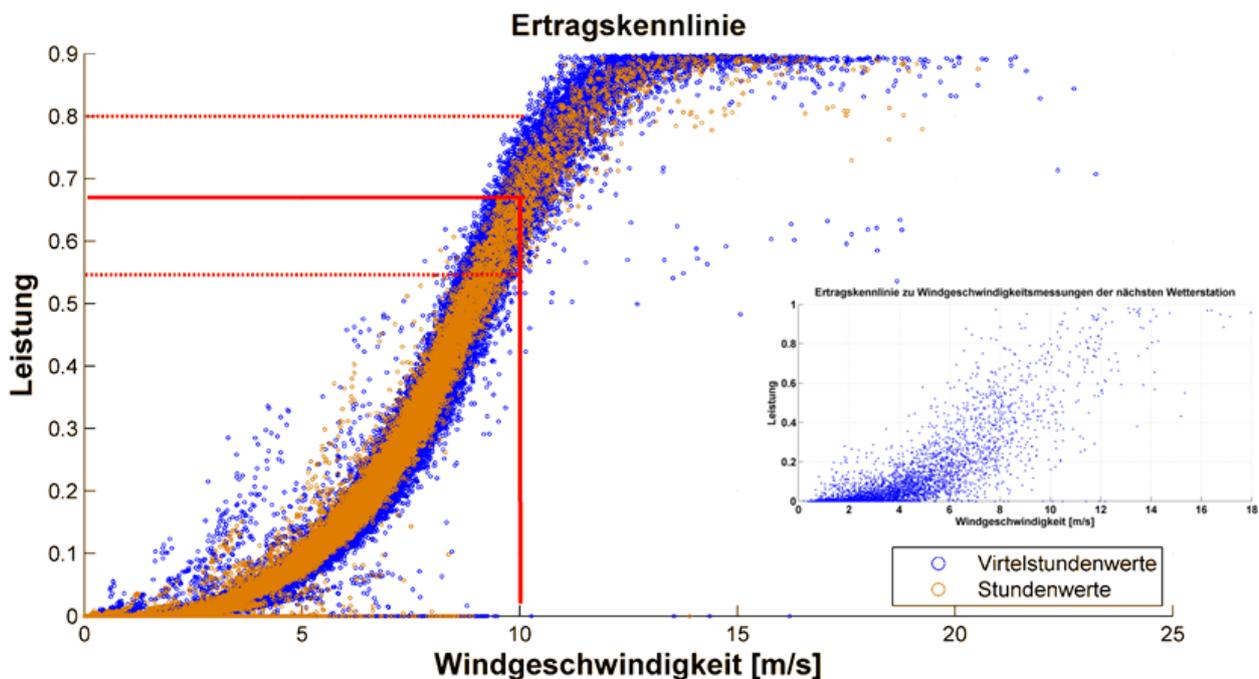


Abbildung 3.43: Ertragskennlinie des WP 1 in unterschiedlichen zeitlichen Mittlungen; kleines Bild im Bezug auf nächstgelegene Messstation

Diese Gründe sprechen für die Modellklasse der KNN. Der interpretierte Existenzsatz von KOLMOGOROV besagt, dass eine kontinuierliche Funktion durch n Variablen abgebildet werden kann, vgl. Abschnitt 2.3.2. Die Ertragskurve bildet unter Vernachlässigung der Ausreißer in ihrem Verhalten eine solche kontinuierliche Funktion. Der Nachteil von KNN ist, dass sie schwer reproduzierbare Ergebnisse liefern und eine starke Abhängigkeit zum verwendeten Trainingsdatensatz aufweisen. Die Abhängigkeit gegenüber dem Trainingsdatensatz hat jede lernende Methode und kann daher vernachlässigt werden. Die mangelnde Reproduzierbarkeit wird in Kauf genommen, weil die Vorteile der Abbildung von Nichtlinearitäten und Erstellung von generellen Modellen überwiegen. Der Mangel der Reproduzierbarkeit hat seine Ursache in der Initialisierung. In der Regel werden KNN mit zufälligen Startgewichten an den Neuroneneingängen initialisiert. Dadurch hat jedes Training einen individuellen Startpunkt.

Durch die Nichtlinearität der abzubildenden Prozesse kann nicht sichergestellt werden, dass die eingesetzten Lernalgorithmen das gleiche Trainingsergebnis liefern. Weiterhin ist es durch die Nichtlinearität sehr schwer das globale Optimum zu identifizieren.

Die Arbeit untersucht die Windleistungsprognose mit Hilfe von Messwerten und vorgelagerten Klimaprognosen. Durch den Prozess entsteht ein hierarchischer Informationsverarbeitungsprozess. Die Zusammenhänge der Daten untereinander können linear funktional oder über den Informationsgehalt bestimmt werden, vgl. Abschnitt 3.3.3 und 3.3.5. Die Beziehungen wurden zwischen Ausgangsdaten und der Windleistung hergestellt. Somit ergibt sich ein hierarchischer Informationsfluss. Aus diesem heraus empfiehlt es sich hierarchischen KNN als Untersuchungsgegenstand zu verwenden. Eine latente Hemmung der Daten konnte nicht nachgewiesen werden. Deshalb wird die latent hemmende KNN Klasse nicht betrachtet. Somit verbleiben die FF und RN als Untersuchungsgegenstand.

Neben der Architektur und dem Neuronenaufbau, vgl. Abschnitt 2.3.2, beeinflussen die Trainingsalgorithmen die Güte des modellierten Prognoseprozesses. Abschnitt 2.3.2 führt die Levenberg-Marquardt (LM) und die Resilient Propagation Trainingsmethoden ein. Es wurden acht vergleichende Experimente in [21] mit KNN durchgeführt, um sich auf einen Trainingsalgorithmus festzulegen. Sechs von acht Experimenten inklusive des global besten Experiments verwendeten das LM. Daher wird für alle weiteren Untersuchungen die LM Trainingsmethode verwendet.

Zur Bewertung der neuronalen Netzarchitektur werden die Experimente 14 und 15 durchgeführt. Sie verwenden beide die LM Trainingsmethode. Beide Architekturen verwenden die interne Strukturoptimierung, vgl. Abschnitt 3.4.4, um die optimale Anzahl an Neuronen des Hidden Layers zu bestimmen. EXP 14 berechnet das FF. EXP 15 berechnet ein RN. Diese Verzögerung der Rekursion wird durch die PAKF in Abbildung 3.5(b) bestimmt. Es gibt drei signifikante partielle Korrelationen. Die erste ist die Stärkste mit ca. 90% für die Verzögerung um einen Tastschritt. Die beiden Weiteren sind mit Werten unter 20% schwach signifikant und werden daher nicht berücksichtigt.

Das Ergebnis der Modellierung und Datenanalyse für EXP 14 wurde in Abbildung 3.44 für den ersten Prognosehorizont H 1 visualisiert. Im Aufbau hat die Eingangsschicht IL zwölf Eingangsneuronen, in der versteckten Schicht HL fünf Neuronen und in der Ausgangsschicht OL 1 Neuron. Alle Neuronen verfügen über einen Bias der nicht abgebildet wurde. Die Abbildung 3.44 hat eine zusätzliche Vereinfachung. Die Neuronen zwischen den Schichten sind voll vermascht. Aufgrund der besseren Darstellung wurde nur die Verbindungen zwischen dem ersten Neuron der versteckten Schicht und allen Eingangsneuronen dargestellt.

3.4 Prognosemodellierung

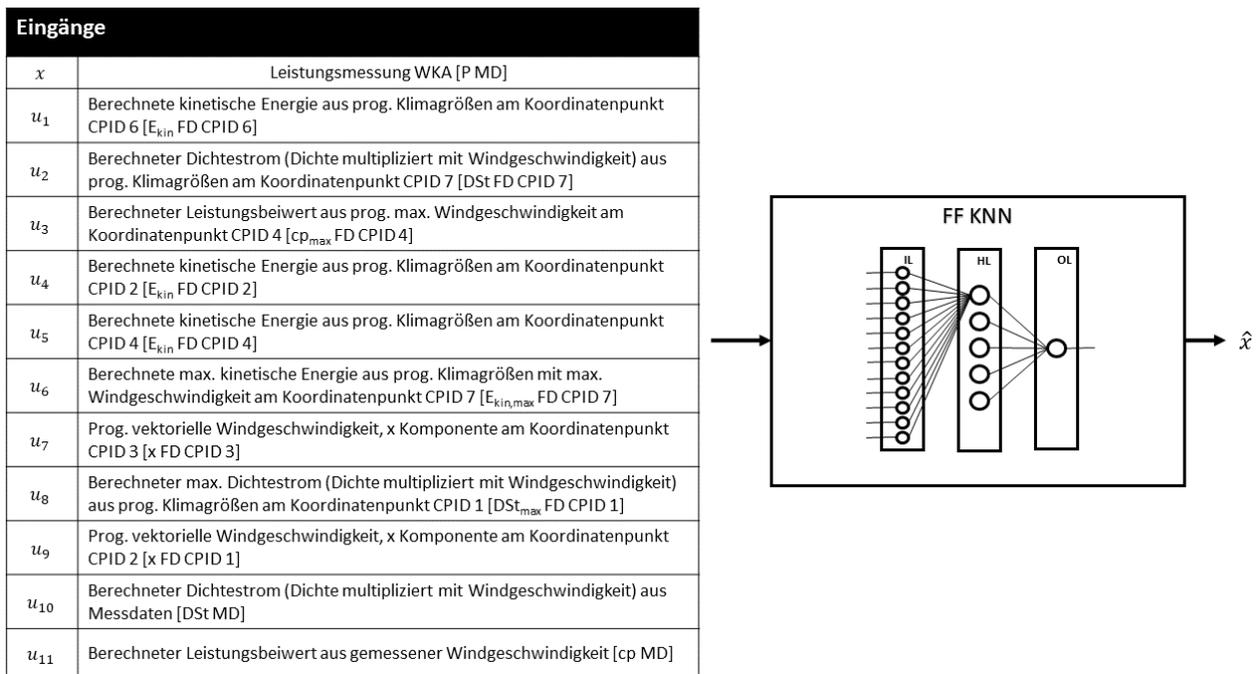


Abbildung 3.44: Blockschaltbild des Modellaufbaus für EXP 14 im Prognosehorizont H 1

Das FF Modell in EXP 14 war im Mittel mit 5,97 % NRMSE besser als das ARX-Referenzmodell mit 6,26 % NRMSE. Die Verbesserung beträgt 4,31 %. Der Abstand des Fehlers zwischen beiden Modellen ist sehr gering, vgl. Abbildung 3.45. In fünf Prognosehorizonten hat das ARX einen geringeren Fehler. Aufgrund des geringen Fehlerabstands ist abzuwägen welches Modell verwendet werden soll. Das ARX hat die geringeren Leistungsanforderungen und empfiehlt sich, wenn geringe Berechnungszeiten gefordert sind. Das FF liefert hingegen leicht bessere Ergebnisse.

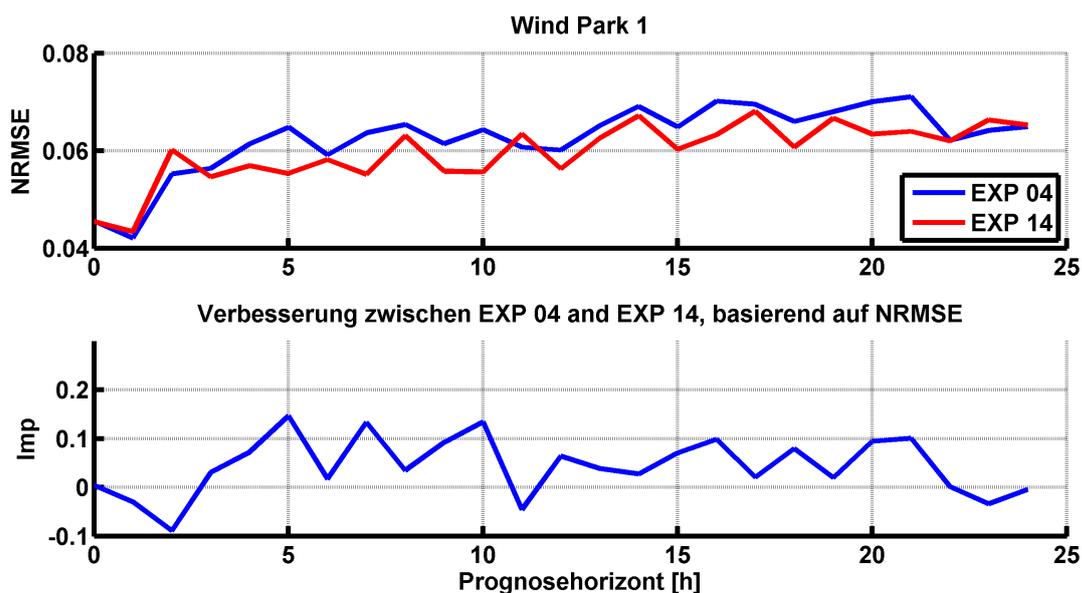


Abbildung 3.45: Vergleich Referenzmodell ARX in EXP 4 mit FF in EXP 14

Die Modellstruktur des EXP 15 wird in Abbildung 3.46 für den ersten Horizont H 1 dargestellt. Es hat die gleichen Strukturparameter in der der Ausgangsschicht OL, sowie die Biase. Die

versteckte Schicht HL hat drei Neuronen. Als Rekursion ist eine äußere Schleife programmiert wurden. Das heißt der Ausgang wird mit einer Verzögerung auf den Eingang aufgeschaltet. Somit vergrößert sich die Eingangsschicht von zwölf auf dreizehn Neuronen. Als Verzögerung Z^{-1} wurde ein Abtastschritt, hier eine Stunde, eingestellt.

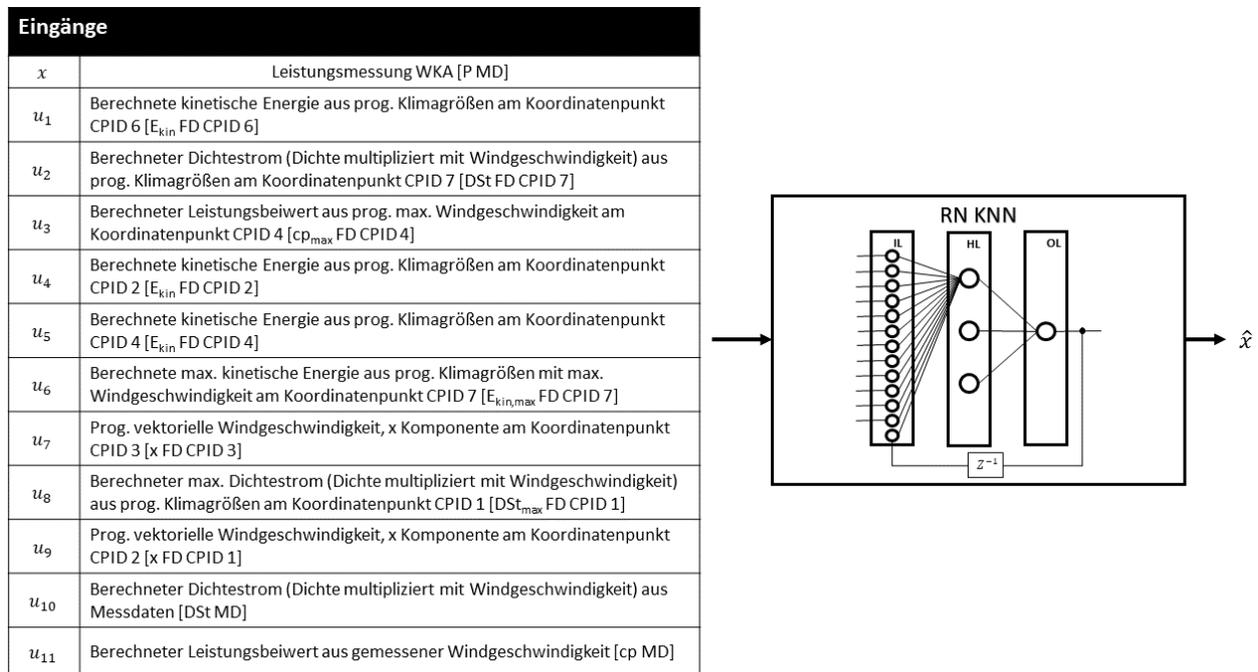


Abbildung 3.46: Blockschaltbild des Modellaufbaus für EXP 15 im Prognosehorizont H 1

Die Ergebnisse des EXP 15 zeigen ein geringeres Fehlerverhalten des RN mit 5,73 % NRMSE und einer Verbesserung von 8,19 % gegenüber dem ARX Modell. In Horizont 1 ist das ARX Modell einmalig besser als das RN mit einer Verbesserung $< 1\%$, vgl. Abbildung 3.47. Das Ergebnis zeigt einen signifikant geringeren Fehler gegenüber dem FF sowie ARX Modell.

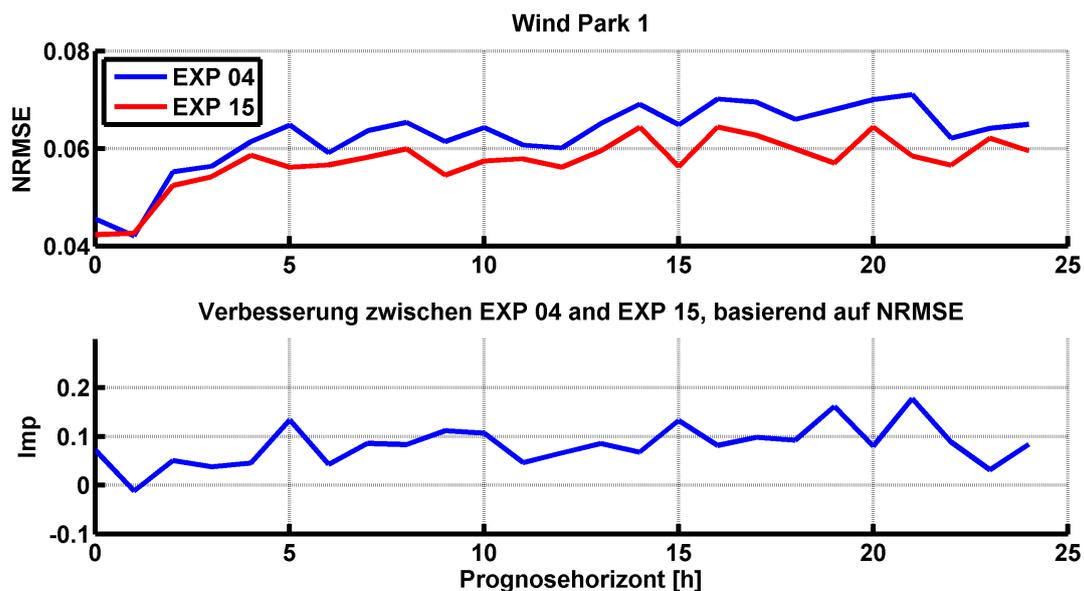


Abbildung 3.47: Vergleich Referenzmodell ARX in EXP 4 mit FF in EXP 15

Der Vergleich der Boxplots für EXP 15 in Abbildung 3.48 mit EXP 4 in Abbildung 3.21

3.4 Prognosemodellierung

zeigt eine geringfügige Verbesserung durch eine Verringerung der Ausreißer. Eine deutliche Verbesserung ist in den Periodogrammen zu erkennen. Die gesamte Kurvenschar liegt näher am weißen Rauschen. Die Ergebnisse für diese EXP befinden sich im Anhang C in Abbildung C.7.

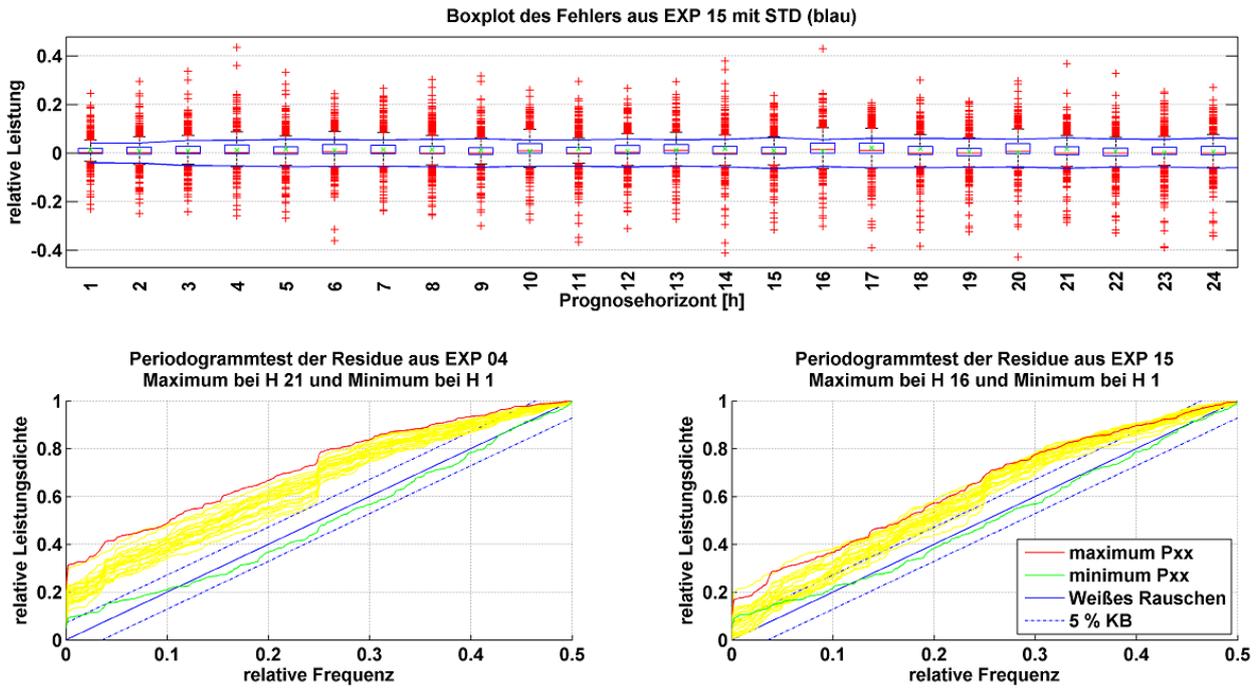


Abbildung 3.48: Validierung EXP 15 im Vergleich zu EXP 4

Exemplarisch wird ein Beispiel für die Zusammenhänge zwischen Eingang und Prognoseausgang in Abbildung 3.49 visualisiert. Sie zeigen die ermittelten Eingänge für den Prognosehorizont + 1 h und deren prognostizierte Leistung. Zusätzlich wurde das zur Validierung gemessene Leistungssignal im Ergebnis dargestellt. Im Horizont 1 h werden sowohl Messwerte als auch Prognosewerte des Wettermodells verwendet. Die Koordinaten wurden anonymisiert durch fortlaufende Identifizierungsnummern.

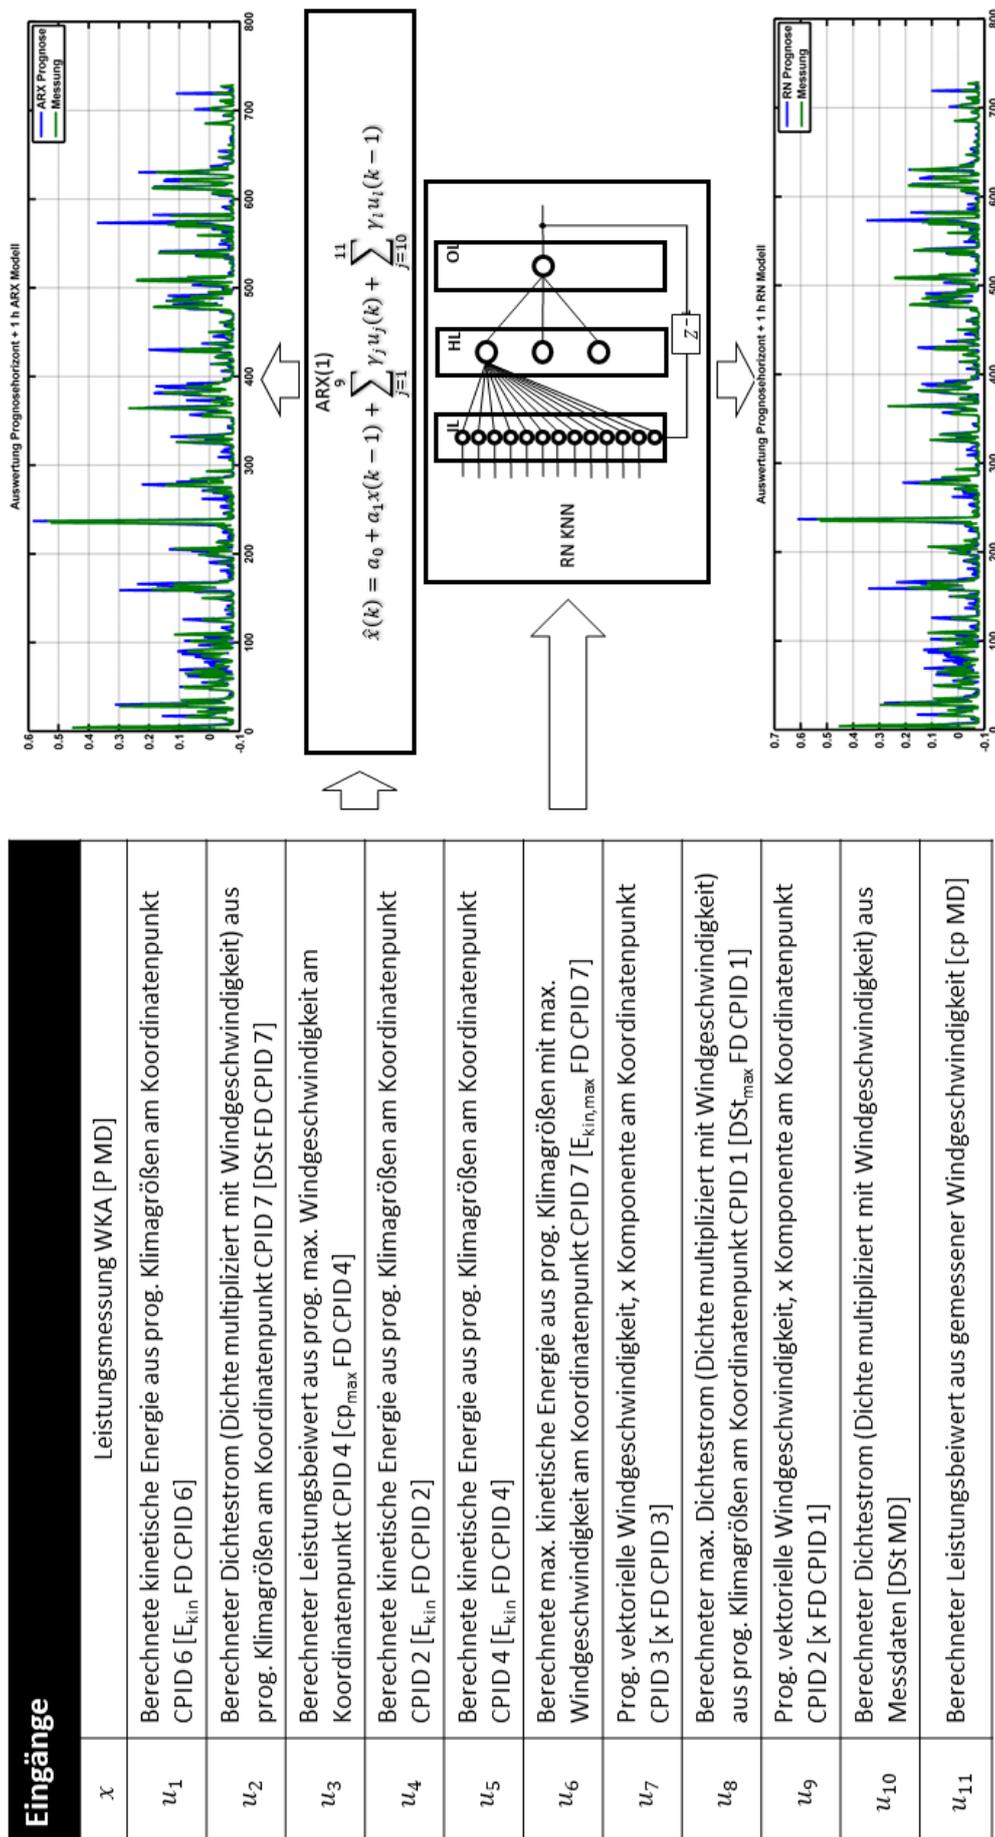


Abbildung 3.49: Vergleich der Ein- und Ausgänge der Modelle ARX und RN für den Prognosehorizont + 1 h

3.4.4 Strukturoptimierung der Hidden Layer Schicht

In Versuchsrechnungen wurden Varianzen in den Trainingsergebnissen festgestellt. Diese können nicht vollständig nachvollzogen werden. Dieser Abschnitt betrachtet einen Aspekt näher und versucht ihn zu optimieren.

Ursachen des genannten Verhaltens ist unter anderem die zufällige Initialisierung der Startgewichte an den Neuroneneingängen. Diese veränderlichen Startpositionen verursachen die Unterschiede der Güten in den Berechnungsergebnissen. Eine weitere Herausforderung ist die Reproduzierbarkeit der Ergebnisse. Die zufällige Initialisierung verhindert Ergebnisse exakt zu reproduzieren, wenn die Startwerte nicht abgespeichert werden.

Ein weiteres Problem betrifft die Modellierung der KNN-Struktur. Durch Zielvorgaben lässt sich die Ausgangsschicht und durch Datenanalysen die Eingangsschicht von KNN objektiv definieren. Über die verdeckte Schicht (engl. Hidden Layer) finden sich in der Literatur häufig Aussagen zu Obergrenzen der verwendeten Neuronen und Faustregeln. Es gibt jedoch kein etabliertes Verfahren zur Ermittlung der konkreten Anzahl der Neuronen. Laut zitiertem Existenzsatz von KOLMOGOROV, vgl. Abschnitt 2.3.2, soll die maximale Neuronenanzahl des Gesamtnetzes nicht $n(2n + 1)$ überschreiten. n ist dabei die Variablenanzahl. OTTO führt eine Formel zur Berechnung der geeigneten Neuronenanzahl [159, S. 156] ein:

$$h = \frac{\text{AnzahlTrainingsdaten}}{10(\text{AnzahlEingänge} + \text{AnzahlAusgänge})}. \quad (3.20)$$

Als Anzahl der Trainingsdaten ist die Menge der Trainingsdatensets zu verstehen. Zusätzlich wiederholt sich in unterschiedlichen Literaturquellen die Aussage, dass Erfahrungswissen zur Modellierung herangezogen werden soll. KOLMOGOROV's Aussage hat die Bedingung, dass die Systemgleichung bekannt sein muss. Je nach Betrachtungsweise können es die fünf Parameter aus der Gleichung für die Windleistung (1.1) sein oder tausende Parameter, wenn die Abhängigkeiten der vorgelagerten Klimaprognosen und deren Wettermodelle einbezogen werden. OTTO's Ansatz ist abhängig von der Datenbasis. Je nach Verfügbarkeit der Trainingsdaten ergeben sich neue Grenzen für die Neuronenanzahl. Erfahrungswissen hat die Einschränkung, dass es über längere Zeit aufgebaut werden muss.

Empirische Untersuchungen zeigten, dass die Variabilität der Güte in Abhängigkeit der Initialisierung der Startposition minimiert werden kann. Dazu ist es notwendig, mehrere Netze parallel zu trainieren und gegeneinander zu vergleichen. Eine geeignete Anzahl ist empirisch zu ermitteln und anzuwenden. Dadurch wird die Variabilität signifikant minimiert. Eine praktikable Anzahl ist empirisch zu ermitteln.

Mit den folgenden Untersuchungen soll geklärt werden, welcher Ansatz zur Strukturierung der HL geeignet ist. Üblicherweise wird die Anzahl experimentell oder über Faustformeln definiert. Alternativ kann die Bestimmung der optimalen Neuronenanzahl in der verdeckten Schicht durch einen iterativen Ansatz empirisch ermittelt werden. Zur Verdeutlichung werden verschiedene Berechnungen in den EXP 16 bis 21 durchgeführt. In diesen werden die Anzahl

der Neuronen vorgegeben. Die Vorgaben lauten 3 (in EXP 15), 5, 10, 11, 15 und 44 Neuronen (in EXP 21). Die Anzahl drei bis zehn sowie 15 wurden auf Basis von Faustregeln vorgegeben. Die Anzahl elf Neuronen ist das Berechnungsergebnis aus Gleichung (3.20). 44 Neuronen ist das Ergebnis, wenn die fünf Parameter aus der Windleistungsformel (1.1) in KOLMOGOROV Formel eingesetzt werden und die Aus- sowie Eingänge abgezogen werden. Alle EXP verwenden das in EXP 15 eingesetzte RN, vgl. Abbildung 3.46, aber mit den jeweils zuvor definierten Neuronenanzahl im HL. EXP 15 integriert einen iterativen Optimierungsalgorithmus, der die Neuronenanzahl bestimmt und gleichzeitig die Startposition je getesteter Anzahl optimiert. Der Optimierungsalgorithmus beruht auf einer Heuristik. Auf Grund der Variabilität der Ergebnisse sind gradientenbasierte Optimierungsverfahren, z.B. GAUS-NEWTON, ungeeignet zur Lösung dieser Aufgabe.

Die Ergebnisse in Abbildung 3.50 und Tabelle 3.8 zeigen, dass es keinen klaren Sieger für die untersuchten Varianten gibt. Das beste Ergebnis erzielte EXP 17 mit einem mittleren NRMSE von 5,6832 % und das schlechteste EXP 18 mit 5,737 %. Die Varianz der mittleren Ergebnisse beträgt rund 0,05 % des NRMSE. KOLMOGOROVs Ansatz (EXP 21) ist das sechstbeste Ergebnis, EXP 15 das viertbeste und OTTOs Ansatz das drittbeste. Berücksichtigt man die Zufälligkeit der Ergebnisse kann mit insgesamt 0,05 % Unterschied kein dominant besseres Verfahren identifiziert werden. EXP 15 hat den Vorteil, dass ein Anwender keine Kenntnis über KNN haben muss, weil es sich selbstständig einstellt. Nachteil dieser Variante ist der durch die Heuristik notwendige numerische Rechenaufwand. Die Ergebnisse der Boxplots und der Periodogramme in den Abbildungen C.8 bis C.13 zeigen kleinere aber wenig signifikante Unterschiede zwischen den einzelnen KNN-Varianten.

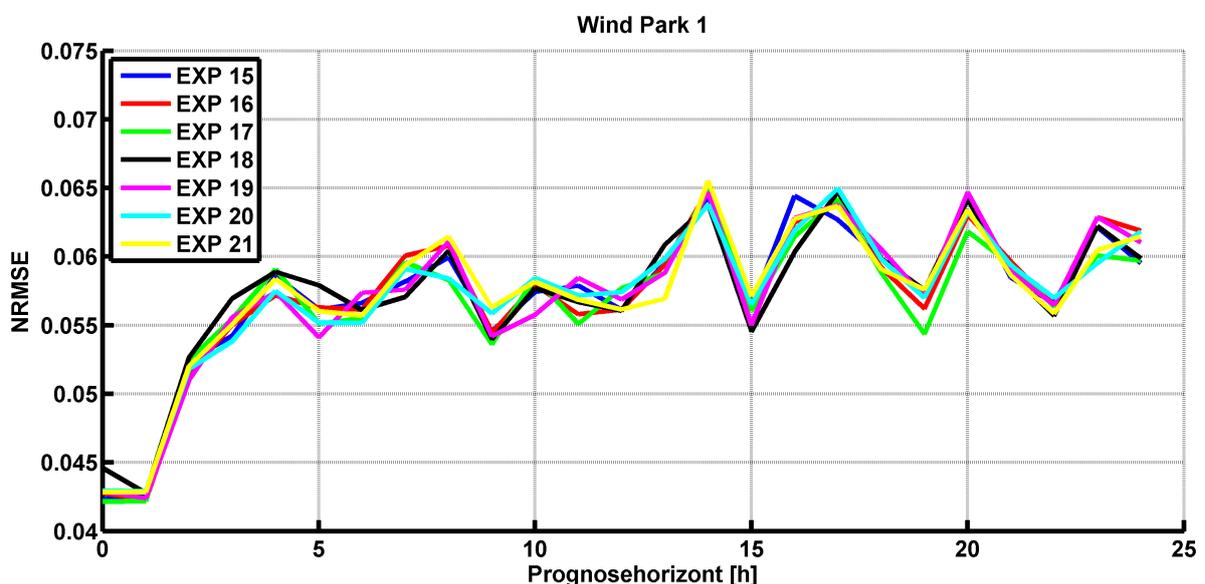


Abbildung 3.50: Vergleich EXP15 bis 21: Einfluss der Optimierung der Neuronenanzahl

Tabelle 3.8: Mittlerer NRMSE und Verbesserung (mit EXP 15 als Referenz) über alle Horizonte der EXP 15 bis 21

	EXP 15	EXP 16	EXP 17	EXP 18	EXP 19	EXP 20	EXP 21
NRMSE	5,7297 %	5,7312 %	5,6832 %	5,737 %	5,7253 %	5,7221 %	5,7348 %
Imp	0,00 %	-0,03 %	0,78 %	-0,22 %	0,08 %	0,08 %	-0,12 %

3.4.5 Optimierung des Trainingszeitraums

In dieser Arbeit wurde die Bestimmung des Trainingshorizontes durch Faustregeln und empirische Untersuchungen beeinflusst. In KNN-Forschungsarbeiten finden sich weitere Ansätze, die den optimalen Trainingszeitraum ermitteln. Ein Ansatz ist es die Menge der Trainingsdaten über die Messung der Entropie zu bestimmen.

EXP 22 soll die Menge der Trainingsdaten optimal kürzen. Durch die Kürzung wird der zeitliche Zusammenhang nicht aufgelöst. Diese Anforderung wurde anhand der starken linearen funktionalen Abhängigkeit zu den Vorgängerwerten, vgl. Abbildung 3.5 b), getroffen. Im Algorithmus wird die Entropie, Gl. (3.16), minimiert. Dadurch soll der Datensatz so ausgewählt werden, dass er möglichst viele Systemzustände beinhaltet und Wiederholungen gleicher Zustände minimiert. Die Modellstruktur ähnelt dem EXP 15. Es wird als Prognosemodell ein RN KNN verwendet. Die Eingangsdatenbelegung wird mit Hilfe der MKK Datenanalysemethodik identifiziert, vgl. EXP4. Die Anzahl der Neuronen im HL wird mittels einer Strukturoptimierung festgelegt, vgl. Abbildung 3.51.

Eingänge	
x	Leistungsmessung WKA [P MD]
u_1	Berechnete kinetische Energie aus prog. Klimagrößen am Koordinatenpunkt CPID 6 [E_{kin} FD CPID 6]
u_2	Berechneter Dichtestrom (Dichte multipliziert mit Windgeschwindigkeit) aus prog. Klimagrößen am Koordinatenpunkt CPID 7 [DSt FD CPID 7]
u_3	Berechneter Leistungsbeiwert aus prog. max. Windgeschwindigkeit am Koordinatenpunkt CPID 4 [cp_{max} FD CPID 4]
u_4	Berechnete kinetische Energie aus prog. Klimagrößen am Koordinatenpunkt CPID 2 [E_{kin} FD CPID 2]
u_5	Berechnete kinetische Energie aus prog. Klimagrößen am Koordinatenpunkt CPID 4 [E_{kin} FD CPID 4]
u_6	Berechnete max. kinetische Energie aus prog. Klimagrößen mit max. Windgeschwindigkeit am Koordinatenpunkt CPID 7 [$E_{kin,max}$ FD CPID 7]
u_7	Prog. vektorielle Windgeschwindigkeit, x Komponente am Koordinatenpunkt CPID 3 [x FD CPID 3]
u_8	Berechneter max. Dichtestrom (Dichte multipliziert mit Windgeschwindigkeit) aus prog. Klimagrößen am Koordinatenpunkt CPID 1 [DSt _{max} FD CPID 1]
u_9	Prog. vektorielle Windgeschwindigkeit, x Komponente am Koordinatenpunkt CPID 2 [x FD CPID 1]
u_{10}	Berechneter Dichtestrom (Dichte multipliziert mit Windgeschwindigkeit) aus Messdaten [DSt MD]
u_{11}	Berechneter Leistungsbeiwert aus gemessener Windgeschwindigkeit [cp MD]

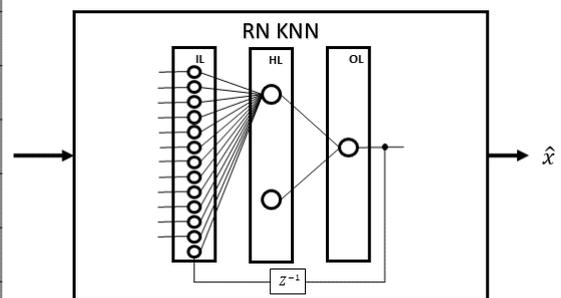


Abbildung 3.51: Blockschaltbild des Modellaufbaus für EXP 22 im Prognosehorizont H 1

Das Ergebnis von EXP 22 wird mit EXP 15 verglichen, vgl. Abbildungen 3.46 und 3.52. Es konnte keine Verbesserung erzielt werden. EXP 22 erzielte einen mittleren NRMSE von

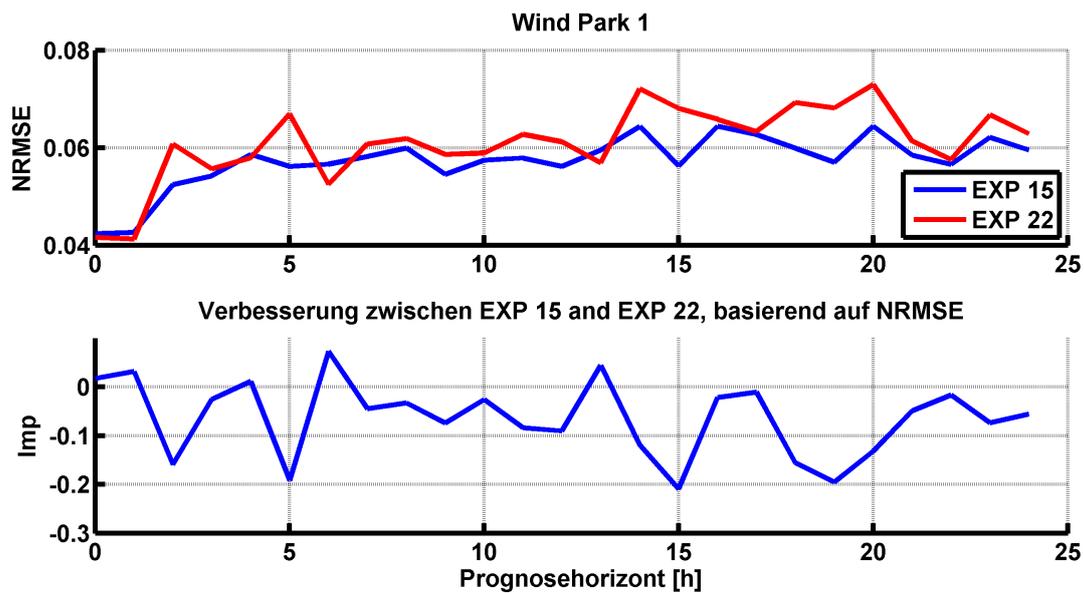


Abbildung 3.52: Vergleich Fehlerauswertung EXP 22 mit EXP 15

6,1033 % gegenüber 5,7297 % von EXP 15. Die mittlere Verschlechterung beträgt $-6,374$ %. Die Fehlerverteilung mit extremen Werten hat gegenüber EXP 15 zugenommen, vgl. Abbildung 3.53. Für einzelne Horizonte konnte eine Verbesserung erreicht werden. Diese fallen gegenüber den negativen Verbesserungen als zu gering aus. Die Periodogramme zeigen, dass sich in EXP 22 die Kurvenschar leicht vom weißen Rauschen wegbewegt.

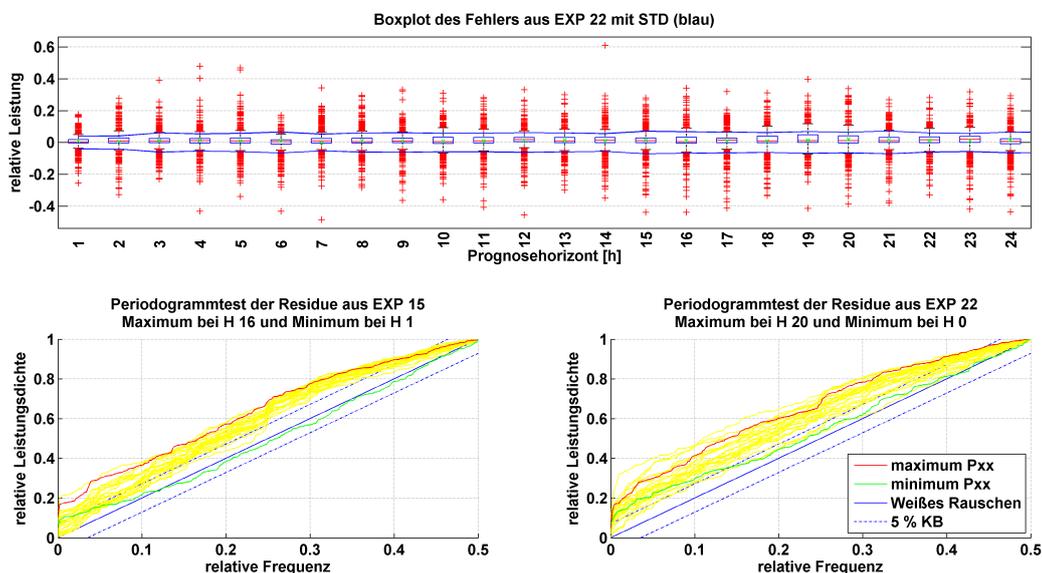


Abbildung 3.53: Validierung EXP 22 im Vergleich zu EXP 15

Das Experiment zeigt, dass mit dem gewählten Ansatz keine Verbesserung erzielt werden kann. Im EXP 22 wurde keine individuelle horizontabhängige Untersuchung vorgenommen. Ursache ist, dass alle individuell prognostizierten Horizonte die gleichen Datumsgrenzen für Training und Prognose verwenden. Zusätzlich würde die individuelle Berechnung den numerischen Rechenaufwand erheblich steigern. Weiterführende Untersuchungen sind in Folgearbeiten geplant.

3.4.6 Analyse Güteanteile zwischen Prognosemodellierung und Datenanalyse

Aktuell existiert kein bekanntes und allgemein gültiges Verfahren zur Ermittlung der Güteanteile zwischen dem Prognosemodell und dem Datenanalyseergebnis. Als Evaluierung wird folgende Vorgehensweise eingeführt. Die Persistenzanalyse wird als Ursprungsmodell verwendet. Es besitzt keinerlei Anforderungen bezüglich der Datenanalyse oder an dem Prognosealgorithmus. In dieser Arbeit bestimmt die Datenanalyse den relevanten Parameterdatensatz, die dem Prognosealgorithmus zugeführt werden. Diese werden mit einem einfachen ARX Modell erster Ordnung ohne höheren autoregressiven Anteil wie in EXP 4 angewendet, vgl. Abschnitt 3.4.1. Es erstellt aus den ermittelten Eingangsparametern in der Datenanalyse eine Prognose. Final wird das eingesetzte Prognosemodell berechnet. In diesem Fall ist es wie in EXP 14 ein RN.

Für den Vergleich wird die Verbesserung (3.1) zunächst zwischen dem ARX Modell und dem RN I_{ARX-RN} und anschließend zwischen Persistenz und RN $I_{Persistenz-RN}$ berechnet. Als Referenzwert dient der Fehler der Persistenz. Anschließend kann über die Verbesserungsgleichung der Güteanteil für die Datenanalyse $I_{Datenanalyse}$ mit Hilfe der Prozentrechnung ermittelt werden. Dabei sind 100 % die Verbesserung von Persistenz auf RN. Die Gleichung lautet:

$$I_{Datenanalyse} = \frac{I_{Final-Persistenz} - I_{Final-ARX}}{I_{Final-Persistenz}}. \quad (3.21)$$

In diesem Kapitel wurde die Persistenz für WP 1 in EXP 11 berechnet mit 9,0818 %, das ARX Modell in EXP 4 mit 6,2513 % NRMSE und das RN in EXP 15 mit 5,7297 % NRMSE. Somit hat in diesen Experimenten die Datenanalyse eine Güte von ca. 84 % am Gesamtgüteanteil. Mit den angegebenen Werten aus den Experimenten der Veröffentlichung [16] werden Werte von ca. 81 % und 77 % erreicht. Implizit ist die individuelle Horizontberechnung enthalten. Deren Einfluss wurde nicht gesondert herausgerechnet und wird als Anteil der Datenanalyse zugeordnet.

3.4.7 Metaprognose

Eine Prognose wird als Metaprognose bezeichnet, wenn sie sich aus mehreren Prognosen unterschiedlicher Anbieter zusammensetzt. Aus Abschnitt 3.3 stehen mehrere Datenmodelle auf Basis unterschiedlicher mathematischer Charakteristiken zur Verfügung. In dieser Arbeit werden für die Metaprognose unabhängige Einzelprognosen erstellt. Anschließend wird die Metaprognose auf Basis der Einzelergebnisse berechnet. Das Arbeitsprinzip wird in Abbildung 3.54 dargestellt. Anhand der bisherigen Arbeit wurde das RN als optimales Modell für die Einzelprognose festgestellt und daher verwendet. Für die Metaprognose wird ein FF verwendet.

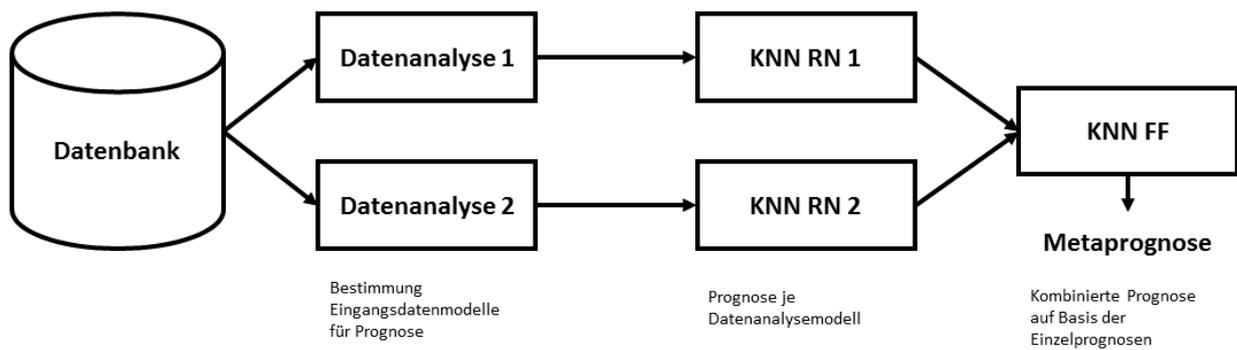


Abbildung 3.54: Arbeitsprinzip der Metaprognoze

Die besten Ergebnisse mit dem ARX Referenzmodell lieferten die multivariate Korrelationsanalyse EXP 4 und die bedingte Informationsanalyse EXP 9. Folgend werden die Prognosen miteinander als Metaprognoze berechnet. EXP 15 liefert das Prognoseergebnis für den MKK auf Basis eines RN. Analog wird in EXP 23 die Prognose mit einem RN für das Informationsanalysemodell durchgeführt. EXP 24 führt die Metaprognoze durch. Das FF KNN der Metaprognoze im EXP 24 hat zwei Eingänge für die Modellausgänge der Prognosen aus EXP 15 und EXP 23, drei Neuronen im HL und ein Neuron im OL.

Die Ergebnisse werden in den Abbildungen 3.55, 3.56 und C.14 visualisiert. Die Informationsanalyse hat mit dem ARX Modell in EXP 9 ein besseres Ergebnis gegenüber dem MKK mit EXP 4 gezeigt. Mit der Verwendung der RN als Prognosemodell ist das Ergebnis für EXP 23 mit einem mittleren NRMSE von 5,8955 % schlechter als für EXP 15 mit NRMSE von 5,7297 %. Die Ergebnisse haben einen geringen Abstand von ca. 0,16 %. Durch die Verknüpfung konnte die Metaprognoze den mittleren Fehler auf 5,5576 % senken. Das entspricht einer Verbesserung von 2,8967 % gegenüber EXP 15 und 5,5584 % gegenüber EXP 23. Die horizontscharfe Fehleranalyse zeigt, dass EXP 15 und EXP 23 wechselseitig bessere Ergebnisse für den jeweiligen Horizont erzielen. Durch das FF in der Metaprognoze konnten die Stärken beider Prognosen fast vollständig ausgenutzt werden. In fünf Horizonten war eines der anderen Modelle geringfügig besser. Die Verteilung der extremen Fehler ist in EXP 15 mit rund 45 % Betragsmaximum geringer und weniger häufig als in EXP 23 mit einem Betragsmaximum von rund 50 %.

Die Verteilung der Fehlerwerte konnte in EXP 24 gegenüber EXP 15 nicht wesentlich verbessert werden, vgl. Abbildungen C.14 mit 3.56. Die maximalen Fehler haben in etwa die gleiche Größe. Die Häufigkeit der extremen Fehler hat etwas abgenommen. Gegenüber EXP 23 stellt die Fehlerverteilung eine signifikante Verbesserung dar, vgl. Abbildungen C.14 mit 3.56. Die maximalen Fehler wie auch die Verteilung der Extremwerte konnte minimiert werden. Der Vergleich der Periodogramme zeigt, dass im EXP 24 die Kurvenschar sich in Richtung des weißen Rauschens bewegt.

Durch die Metaprognoze ist eine Verbesserung mit den Prognosen eines Ausgangsdatensatzes möglich. Dazu werden Eingangsdatenmodelle auf Basis unterschiedlicher mathematischer Charakteristiken gewählt. Der Einsatz ist individuell zu prüfen. Die fünf Horizonte, an

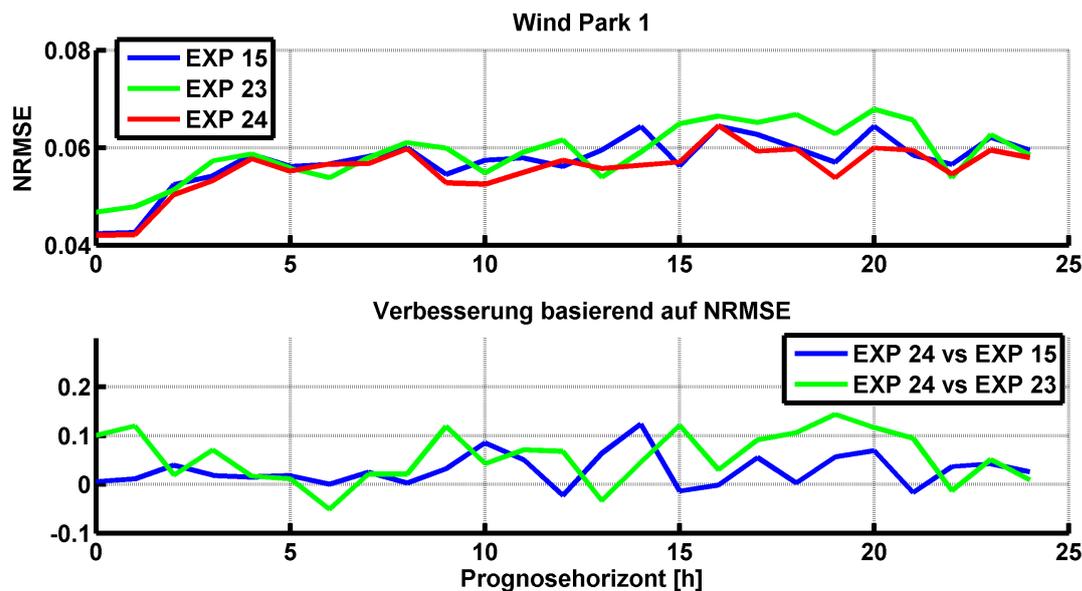


Abbildung 3.55: Vergleich Fehlerauswertung EXP 24 mit EXP 15 und EXP 23

denen die Einzelmodelle besser sind, lassen vermuten, dass keine pauschale Aussage über die Verwendung der Metaprognose getroffen werden kann. Das wird insbesondere durch die EXP 25 und EXP 26 deutlich. EXP 25 berechnet die Windleistungsprognose mittels eines RN auf Basis der nichtlinearen und linearen Information in EXP 10. EXP 26 berechnet die Metaprognose zwischen EXP 15 und EXP 25. Das FF KNN der Metaprognose im EXP 26 hat zwei Eingänge für die Modellausgänge der Prognosen aus EXP 15 und EXP 23, drei Neuronen im HL und ein Neuron im OL. Obwohl das Eingangsmodell in EXP 10 deutliche Verschlechterung gegenüber EXP 4 aufweist, wird in EXP 26 für die Metaprognose eine größere Verbesserung mit einem mittleren NRMSE von 5,4597 % gegenüber EXP 24 erreicht, vgl. Abbildung 3.57. Die Verbesserung gegenüber EXP 15 beträgt 4,6046 % und gegenüber EXP 25 9,4581 % und einem mittleren NRMSE von 6,0473 %.

Ein Vergleich der Boxplots der Abbildungen 3.56 und 3.58 zeigt, dass der Betrag der Ausreißer in etwa gleich ist. EXP 26 hat leicht größere Werte. Daraus folgt, dass die Häufigkeit der großen Fehler abgenommen hat. Das Periodogramm von EXP 26 zeigt, dass sich ein Großteil der Kurven im Konfidenzband bewegt. Von allen Experimenten befinden sich die Residuen am nächsten am weißen Rauschen. Die Experimente zur Metaprognose zeigen, dass sich schwer definieren lässt, welche Kombination an Eingangsmodellen zu der größten Verbesserung führt. Eindeutig konnte nachgewiesen werden, dass die Kombination von Eingangsmodellen auf Basis unterschiedlicher mathematischer Charakteristiken zu einer Verbesserung führen kann.

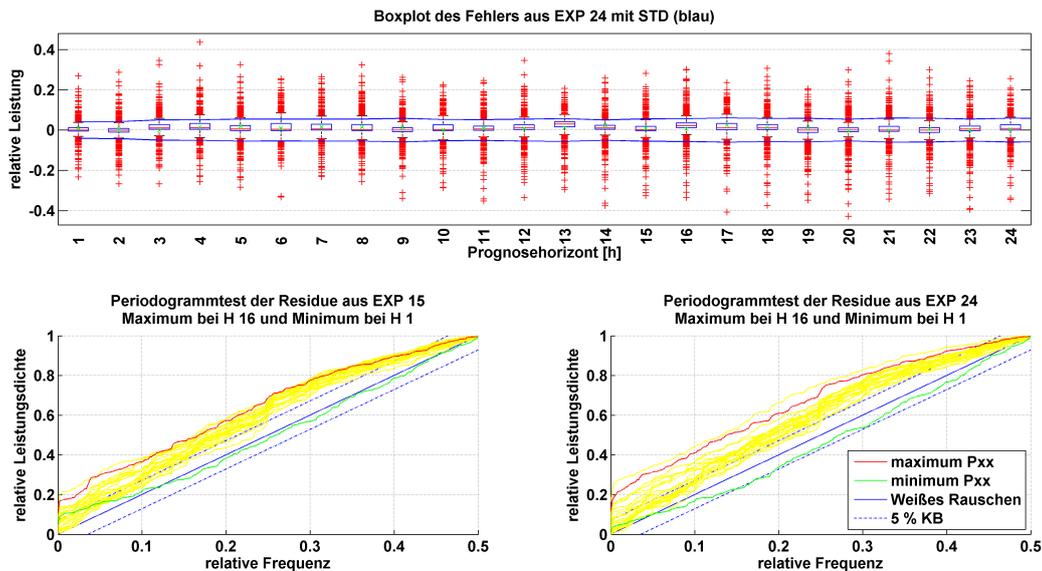


Abbildung 3.56: Validierung EXP 24 im Vergleich zu EXP 15

3.4.8 Zusammenfassung Prognosemodellierung

Im Abschnitt Prognosemodellierung wurden KNN als Prognosemodell untersucht. Diese wurden mit dem Persistenzmodell, einem einfachen Systemmodell und einem ARX-Modell verglichen. Als bestes Prognosemodell hat sich das RN erwiesen. Es konnte gegenüber den Referenzmodellen zu signifikanten Verbesserungen führen. Das untersuchte FF-Modell erwies sich nicht als dominant besseres Modell gegenüber dem ARX-Modell.

Es wurden Ansätze zur Strukturierung der HL durchgeführt. Es konnte kein dominierender Ansatz identifiziert werden. Die vorgestellte Methodik zur Bestimmung der Neuronenanzahl eignet sich als Verfahren bei nicht vorhandenem Expertenwissen. Dieses kostet jedoch einen hohen numerischen Aufwand. OTTOs Ansatz führt zu geringfügig besseren Ergebnissen und erspart einen hohen numerischen Rechenaufwand.

Die Untersuchungen zur automatischen Bestimmung des Trainingszeitraums führten zu keinen positiven Ergebnissen. Ergebnisse einzelner Horizonte lassen vermuten, dass weiterführende Untersuchungen zu einer Gütesteigerung führen könnten.

Der Güteanteil zwischen Datenanalyse und Prognosemodell wurde bewertet. Die Datenanalyse hat einen signifikant dominanten Anteil an dem Prognoseergebnis. Somit ist die Güte der Windleistungsprognose im Wesentlichen von der Datenbasis abhängig. Das nachfolgende Prognosemodell kann durch geeignete Auswahlprozesse entsprechend BOX-JENKINS optimale Ergebnisse erzielen.

Die Metaprognose angewandt auf die Datenanalyseergebnisse unterschiedlicher mathematischer Charakteristiken kann zu weiteren Verbesserungen des Prognoseergebnisses führen. Die Aussage kann nicht pauschalisiert werden. Diese gilt es im Einzelfall zu prüfen. Weiterhin

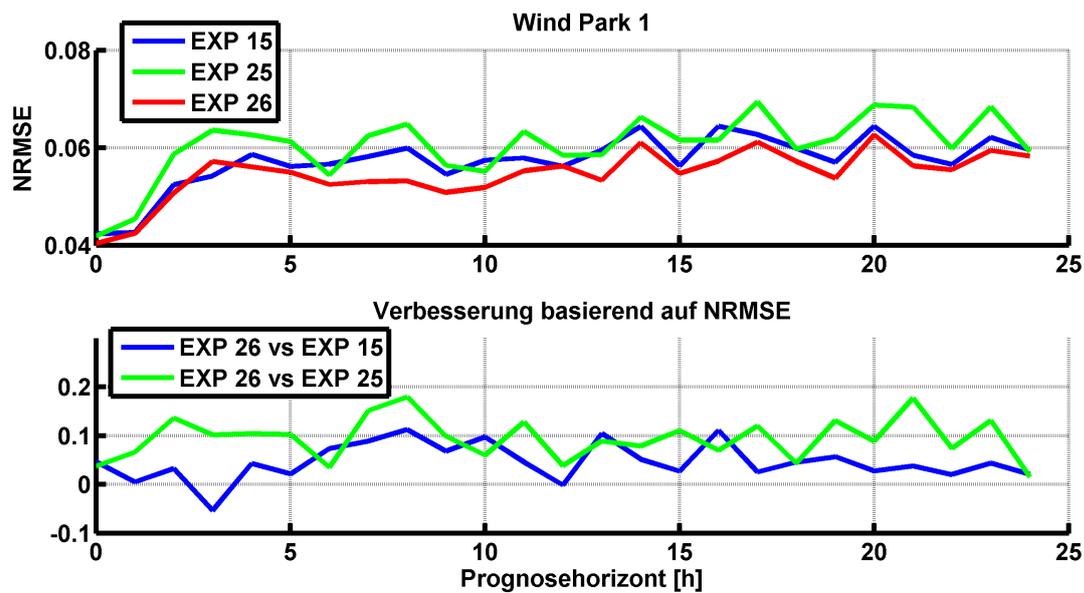


Abbildung 3.57: Vergleich Fehlerauswertung EXP 26 mit EXP 15 und EXP 25

sind unterschiedliche Kombinationen zu prüfen, um den maximalen Effekt zu erhalten.

Die Validierungsmethodik konnte mittels Periodogrammtest zeigen, dass sich die beste Prognose an das weiße Rauschen annähert aber nicht vollständig diesem entspricht. Unter den betrachteten Methoden liefert die Metaprognose auf Basis des MKK und der Kombination aus linearer und nichtlinearer Information das beste Ergebnis.

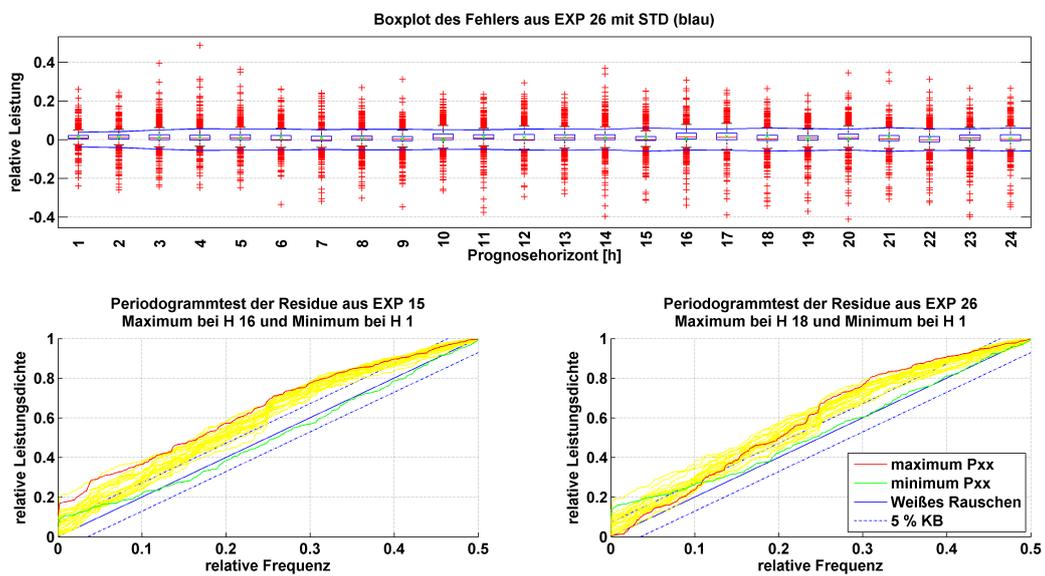


Abbildung 3.58: Validierung EXP 26 im Vergleich zu EXP 15

4 Softwareentwicklung

Dieses Kapitel stellt die im Rahmen der Arbeit entwickelte Softwaresysteme kurz vor. Für die Vorstellung werden drei Darstellungsformen gewählt, um die Inhalte zu präsentieren. Es handelt sich um ein Funktionsdiagramm, ein Sequenzdiagramm und eine Softwarearchitekturdarstellung in Blockform, vgl. Abbildung 4.1. Das Funktionsdiagramm definiert komplexe Funktionen, wie z.B. Prognosetraining, und setzt diese durch Abhängigkeiten in Bezug, vgl. Abbildung 4.2. Das Sequenzdiagramm definiert Prozesse, in die Funktionen des Funktionsdiagramms integriert werden sollen, vgl. Abbildung 4.3. Die Darstellung von Softwarearchitekturen ist freier. Häufig werden Themenkomplexe in thematischen Blöcken dargestellt. Diese Darstellungsform wurde in Abbildung 4.4 gewählt. Das Kapitel ist wie folgt untergliedert. Im ersten Abschnitt 4.1 wird das allgemeine Prototypenkonzept AProSy (**adaptives Prognosesystem**) vorgestellt. Der zweite Abschnitt 4.2 stellt eine erste konkrete Ausimplementierung des Konzeptes vor (**MATLAB®**basiertes **adaptives Prognosesystem**). Im letzten Abschnitt 4.3 wird ein selbst entwickeltes Klimadatenarchiv vorgestellt, welches verwendet wurde, um die passenden Klimaprognosedaten für die Untersuchungen abzuspeichern.

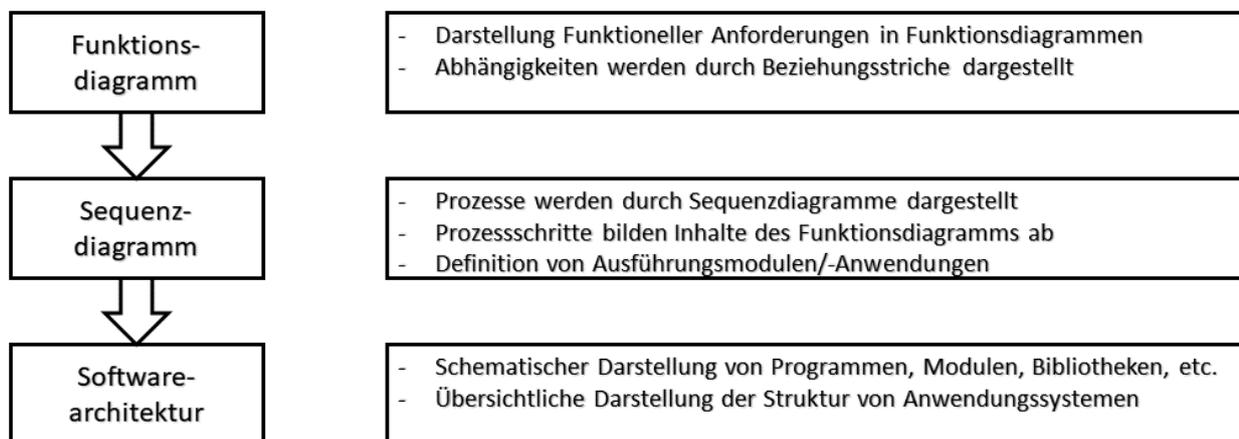


Abbildung 4.1: Zusammenhänge der Diagramme in der Softwareentwicklung

Die Entwicklungsarbeiten der Methoden wurden in MATLAB®durchgeführt. MATLAB®ist geeignet Prototypen zu entwickeln. Ist jedoch ungeeignet für einen Dauerhaften operativen Einsatz. Aus diesem Grund wurde basierend auf den Erkenntnissen der Methodenentwicklung und der experimentellen Untersuchungen im Rahmen dieser Arbeit das allgemeine Softwarearchitekturkonzept von AProSy entwickelt. Es ist Programmiersprachen unspezifisch, weil es die methodische Bearbeitung der Prognoseaufgabe fokussiert. Im Forschungsprojekt sMobliTy (smart Mobility Thüringen) [1] des BMWi IKT II Forschungsprogramms wurden die Ergeb-

nisse der Windleistungsprognose in die energiewirtschaftlichen Prozesse des Feldversuchs sowie der simulativen Marktstudien integriert. Für diesen Zweck wird das Konzept AProSy zunächst in MATLAB® als MAProSy (MATLAB®basiertes adaptives Prognosesystem) umgesetzt. Somit kann der Quellcode der Methodenentwicklung direkt zur Prozessmodellierung verwendet werden.

Die Datenaufbereitung der Klimaprognosen wird mit Hilfe des Klimadatenarchivs durchgeführt. Die Prognosen der Wetterdienste werden in einem speziellen Dateiformat, GRIB und GRIB2 geliefert. Diese Dateien beinhalten eine einzige Prognose in einer Art dreidimensionalen Wetterzustandskarte der Atmosphäre. Für den Prognoseprozess werden jedoch Zeitreihen benötigt. Das Klimadatenarchiv speichert die Klimaprognosen als eigenständige Anwendung je Koordinaten- und Höhenpunkt in einem Zeitreihen-kompatiblen Format ab. Alle softwaretechnischen Konzepte basieren auf datenbankorientierten Speicherkonzepten.

4.1 Prototypenkonzept für AProSy

AProSy wird in dreizehn Funktionsmodule untergliedert, vgl. Abbildung 4.2. Die Ausgangsbasis bilden zwei Speichermodule „Verknüpfung Klimadatenarchiv“ und „Verknüpfung ZRM 4 Messdaten“. Ersteres wird im Abschnitt 4.3 kurz vorgestellt. Letzteres entspricht einem OZM System und ist ausreichend für die Verwaltung von Messdaten. In ihm werden zum einen die Messungen der WP und zum anderen, wenn vorhanden, Messwerte klimatischer Größen, wie z.B. die Windgeschwindigkeit abgespeichert. Das dritte Modul beinhaltet die „Parametrierung Prognoseaufgabe“. Sie verknüpft die Klimaprognosen von einem oder mehreren Wettermodellen mit den Messwerten. Weiterhin werden in ihr die Datenanalysealgorithmen sowie die angedachten Prognosealgorithmen ausgewählt. Das Kapitel 3 „Modellierung“ ermittelte, welche Methoden am geeignetsten sind. Diese werden als Vorauswahl in die jeweiligen Masken eingetragen. Die Untersuchungsergebnisse zeigen auch, dass andere Methoden das Potential haben für andere WP bessere Ergebnisse zu liefern, wie z.B. das ARX-Modell neben den RN. Oder durch die Verknüpfung in einer Metaprognose insgesamt zu einem besseren Gesamtergebnis führen. Daher werden die untersuchten Methoden optional angeboten. Viertens wird die „Berechnung Numerischer Produkte“ ausgeführt und erstellt einen Datensatz für Folgeprozesse. Das Modul entlädt bzw. aktualisiert aus den Datenarchiven den aktiven Wertedatensatz. Zusätzlich werden weitere Größen z.B. die kinetische Energie nach Gl. (3.11) oder der Leistungsbeiwert berechnet, die nicht durch Messungen oder Klimagrößen bereitgestellt werden.

Das fünfte Modul berechnet die „automatische Datenanalyse“. Der Prozess der Datenanalyse wird mit Hilfe von Kennzahlen soweit automatisiert, dass am Ende Eingangsdatenmodelle für die Prognosemethode ermittelt werden. Der Anwender kann dabei zusätzliche Gütekriterien bestimmen die im sechsten Modul „Manuelle DA Überprüfung“ eingesehen und ggf. angepasst werden könnten. Modul sieben führt das Prognosetraining durch. Modul acht aktiviert die „Validierungsrechnung“. D.h. es wird für einen abgelaufenen Zeitbereich der Prognoseprozess so

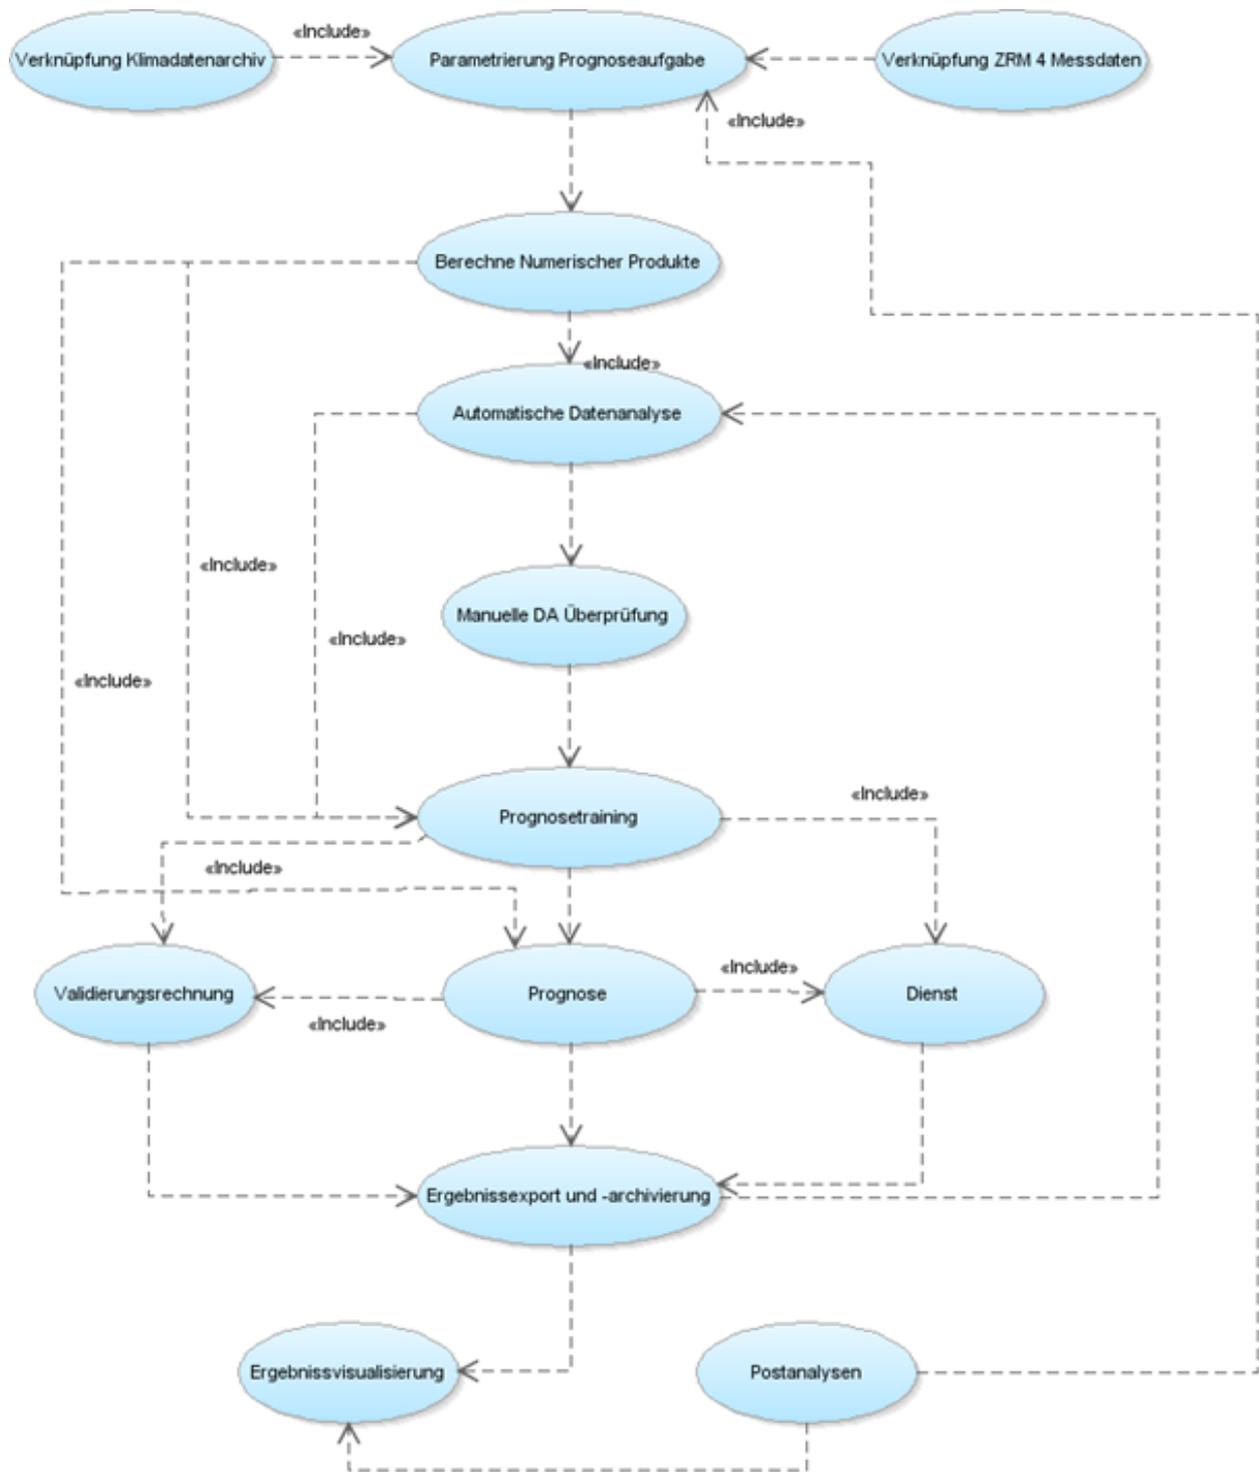


Abbildung 4.2: Funktionsdiagramm AProSy („include“ bedeutet, dass eine Funktion andere Funktionen als Unterfunktionen benötigt.)

simuliert, wie er in einem eingebundenen Prozess stattfinden würde. Modul neun berechnet die „Prognose“ manuell. Modul zehn ist eine „Prozessautomatisierung“. Sie führt die Datenanalyse, das Prognosetraining und die Prognose als Hintergrundprozess aus. Diese wird benötigt, um die Prognose in Prozessketten zu integrieren. Das elfte Modul „Ergebnisexport und -archivierung“ exportiert zum einen die Ergebnisse auf Zeitreihen und einem VDS. Zum anderen werden die Berechnungen archiviert, um jederzeit Berechnungsergebnisse rekonstruieren zu können. Modul zwölf „Ergebnisvisualisierung“ soll neben dem reinen Prognoseergebnis Kennwerte visualisieren. Das letzte Modul „Postanalysen“ erstellt automatisch Protokolle. Diese dienen der Qualitätsüberwachung.

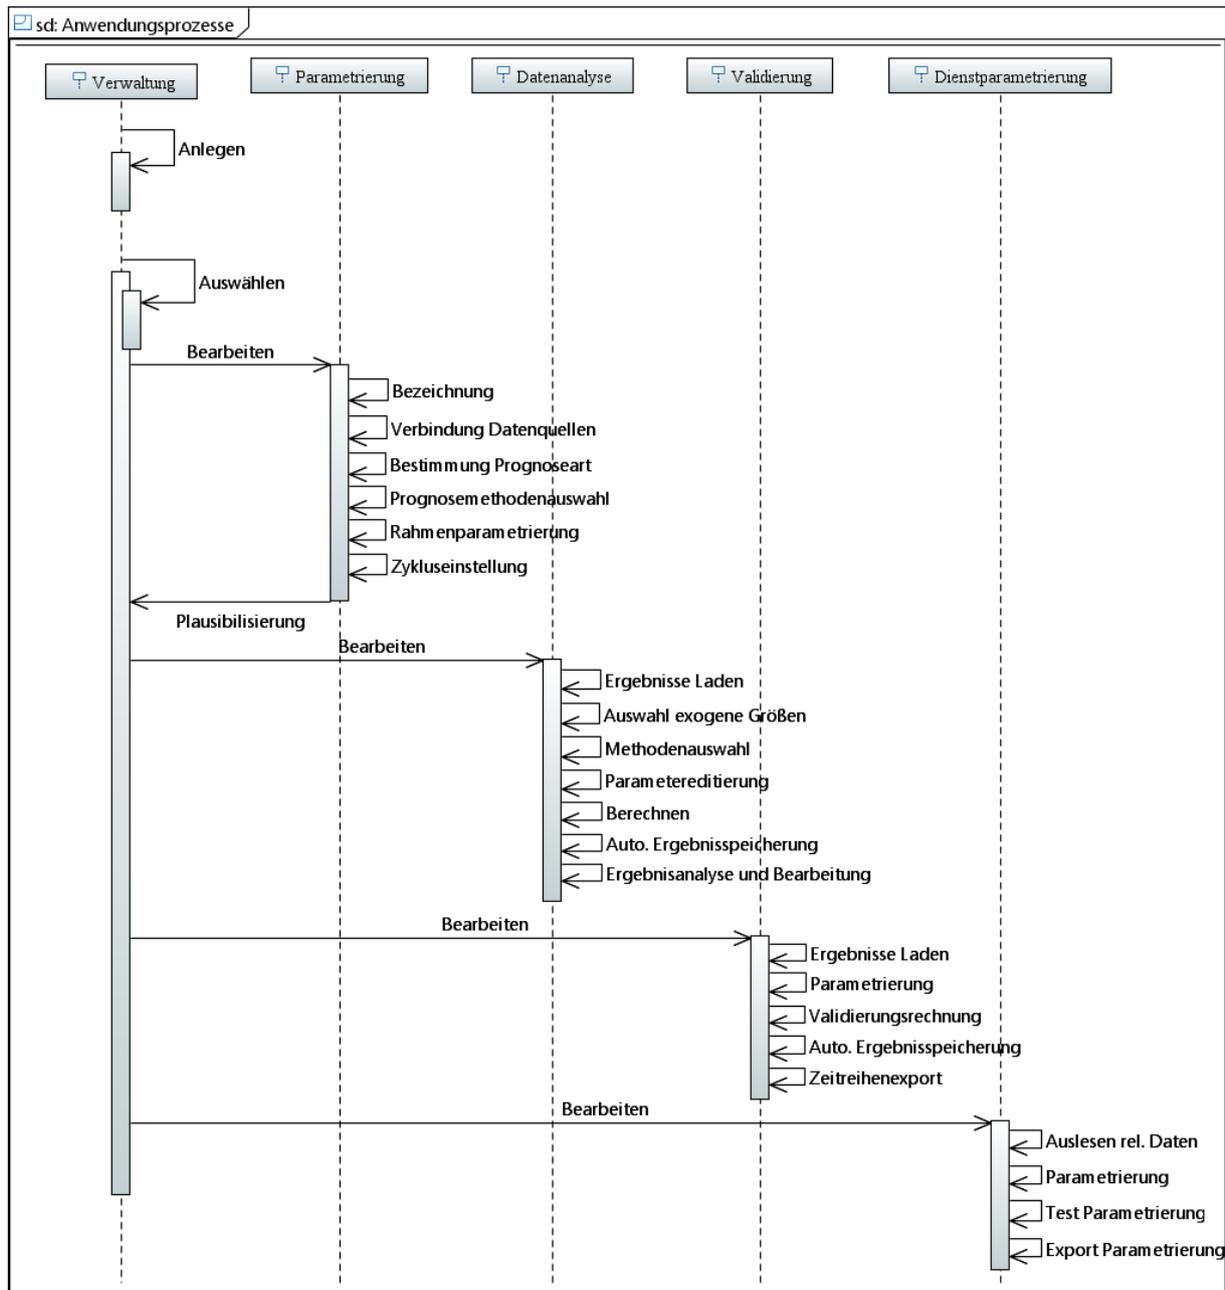


Abbildung 4.3: Sequenzdiagramm AProSy

Die Module lassen sich in fünf inhaltlichen Sequenzen zusammenfassen und durch eine übergeordnete Verwaltungsebene steuern, vgl. Abbildung 4.3. Die Datenspeicherung ist

in SQL-Datenbanken geplant. Das Konzept wurde auf Basis einer ORACLE®Datenbank entwickelt. Es verwendet keine produktspezifischen Anwendungen und kann daher das Konzept auf jede andere SQL basierte Datenbank überführen. Für die Plattformunabhängigkeit wurde JAVA als Programmiersprache ausgewählt.

4.2 Softwareprototyp MAProSy

Die methodischen Untersuchungen wurden in MATLAB®durchgeführt. Im Projekt sMobiliTy wurde die Prognose in die Prozessführung zur Überwachung der Netzstabilität integriert. Dafür wurden die vorgestellten Methoden in Prozessskripte überführt. Durch die Ausführung der MATLAB®Konsolenanwendung können die Prozesse über Batchdateien in einem Automatisierungsprozess gestartet werden. Die MAProSy Module setzen viele Aspekte aus dem AProSy Konzept um. Diese werden in den drei Modulen „Datenanalyse“, „Prognose“ und „JDBC API“ gebündelt, vgl. Abbildung 4.4. Das „Datenanalyse“ und „Prognose“ Modul beinhalten die vorgestellten Methoden aus Kapitel 3. Das „JDBC API“ Modul greift auf Datenbankinhalte zu. Die Datenbank speichert die Prognosen, das Klimadatenarchiv (siehe Abschnitt 4.3) und das OZM. Das OZM wurde nicht entwickelt. Es verwendet das Zeitreihenmanagement der Softwarelösung EMS-EDM PROPHET®. Des Weiteren sind alle Experimente und nachfolgenden Untersuchungen mit der Methodenbibliothek von MAProSy durchgeführt wurden.

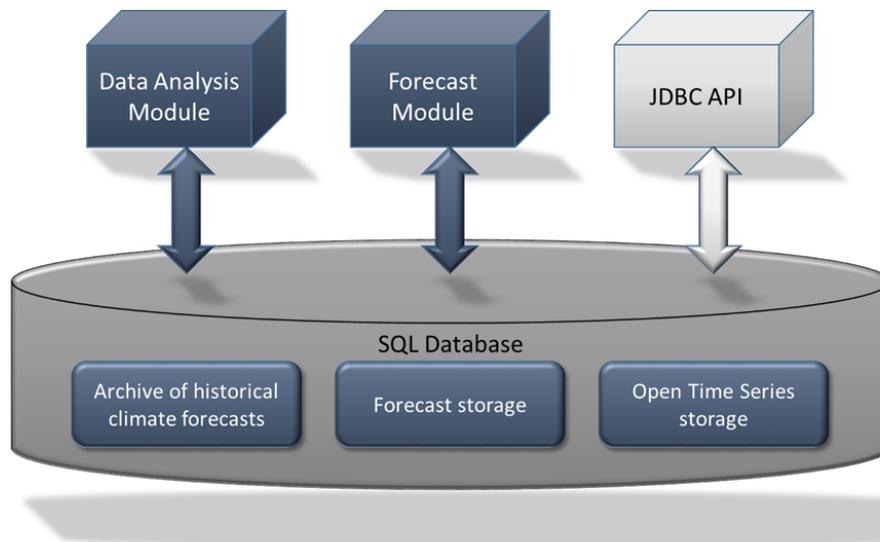


Abbildung 4.4: Module MAProSy

4.3 Softwareprototyp Klimadatenarchiv

Das Klimadatenarchiv dient dem Zweck numerische Wetterprognosen in einem prozessorientierten Zeitreihenformat abzuspeichern und über Schnittstellen die Daten Folgesystemen zur

Verfügung zu stellen, im konkreten Anwendungsfall der Windleistungsprognose. Die NWP werden im GRIB bzw. im GRIB2 Format geliefert. Die atmosphärischen Karten stellen immer einen Zeitpunkt bzw. Prognosehorizont dar. Unter Zuhilfenahme der Bibliothek NetCDF (Network Common Data Form) der Unidata Organisation wurde eine datenbankbasierende Java-Anwendung konzipiert und im Rahmen des Projekts sMobiliTy umgesetzt. NetCDF ist eine Java-Bibliothek, die GRIB und GRIB2 Binärdateien und weitere Formate decodieren kann.

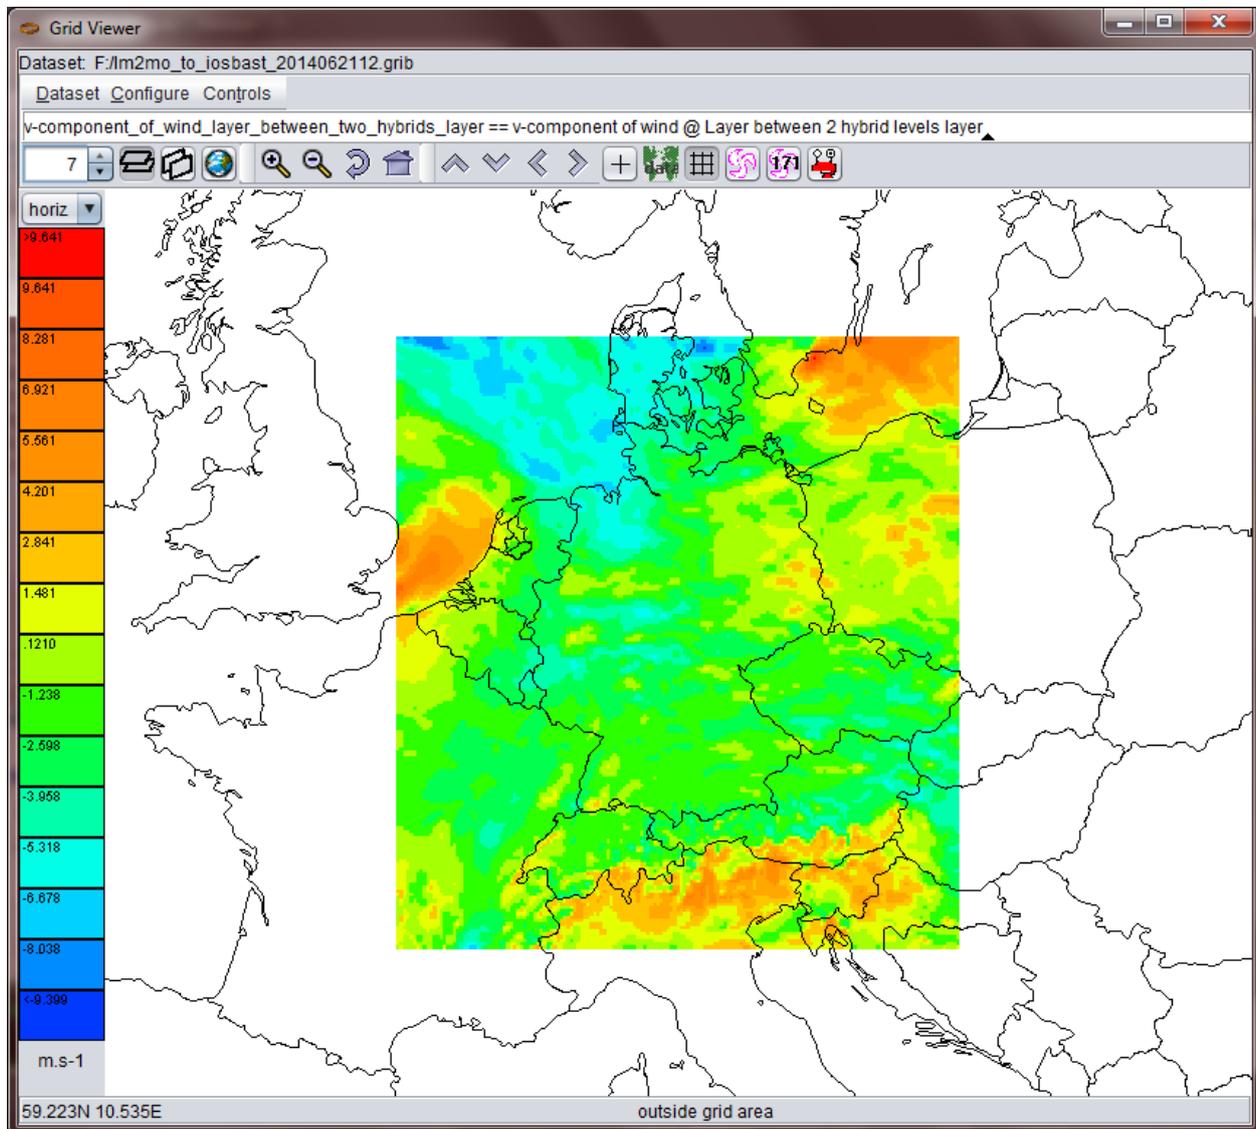
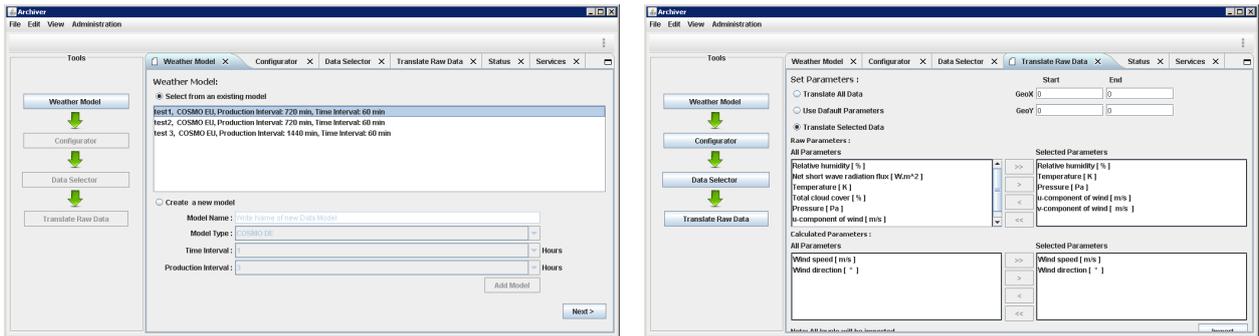


Abbildung 4.5: Beispiel Inhaltsdarstellung einer GRIB Datei für die u-Komponente der Windgeschwindigkeit

Die originalen Ausgangsdateien im GRIB 1-2 Format enthalten einen Prognoselauf mit den Felddaten eines ganzen geografischen Gebiets, Beispiel in Abbildung 4.5. Für den Prozess würde sich ein Leistungsnighteil ergeben, wenn für jedes Training erst alle Dateien entladen werden müssten, um die lokalen Informationen eines WPs zu entnehmen. Daher unterstützt das Klimadatenarchiv den entwickelten Prognoseansatz, indem es die Klimaparameter verlustfrei je Koordinatenpunkt abspeichert. Im Ergebnis werden Datenmatrizen erstellt, die den historischen Verlauf der Klimaprognosen je Parameter skizzieren. Die Archivierungsfunktion wird in der Abbildung 4.6 a) und b) dargestellt. Für den Nutzer des Klimaarchivs gibt es eine

4.3 Softwareprototyp Klimadatenarchiv

separate Nutzeranwendung mit deren Hilfe auf die gespeicherten Daten zugegriffen werden kann, um diese mit anderen Folgeprozessen zu verknüpfen, vgl. Abbildung 4.7.



(a) Wettermodelle

(b) Parameterauswahl

Abbildung 4.6: Klimaarchiv UI

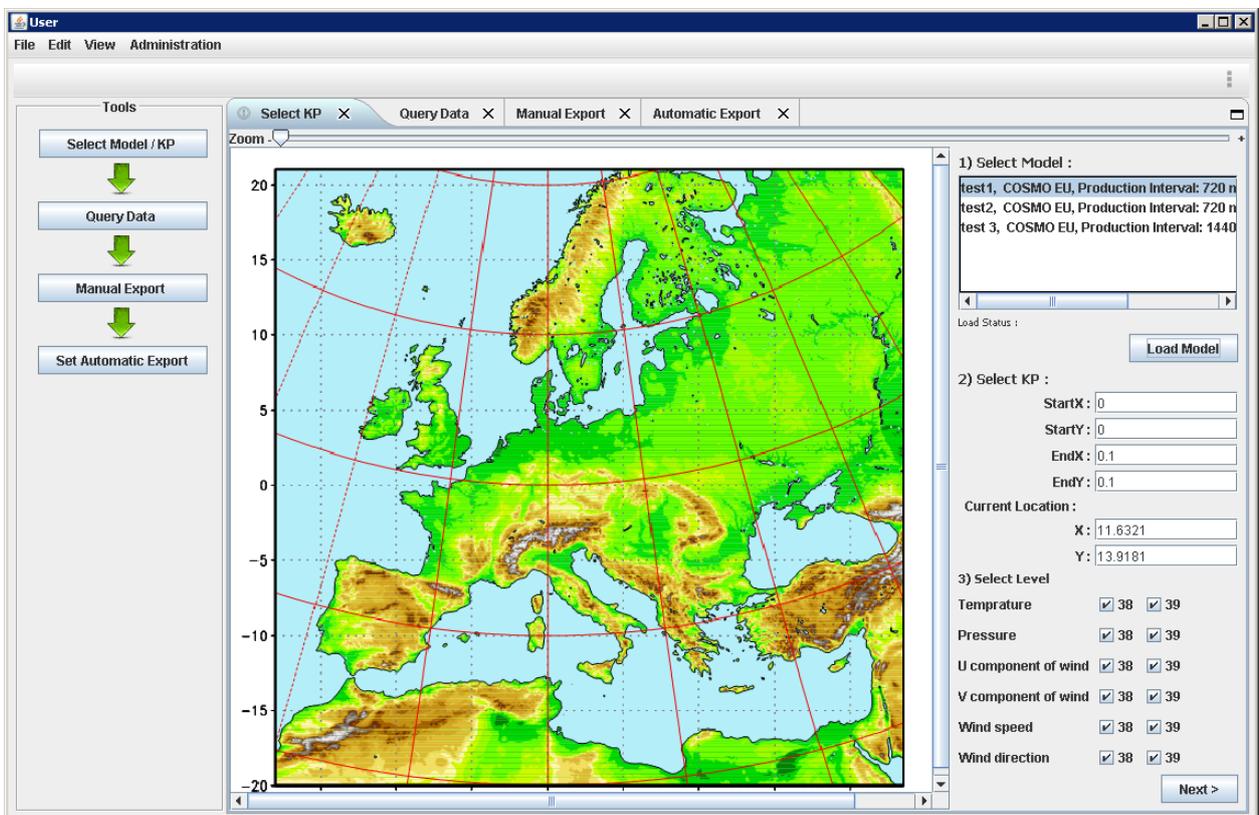


Abbildung 4.7: Nutzeranwendung zum Exportieren der Daten in Folgeprozesse

5 Ergebnisse

In diesem Kapitel werden vergleichende Untersuchungen durchgeführt. Dazu werden in den Abschnitten 5.1 bis 5.3 die Windparks WP 2 bis WP4 untersucht. Die Details der Datensätze wurden in Abschnitt 3.2 vorgestellt. Anschließend wird in Abschnitt 5.4 die Übertragbarkeit an zwei Photovoltaik-Anlagen untersucht. Das Kapitel schließt mit einer Zusammenfassenden Auswertung in Abschnitt 5.5 ab.

Die eingesetzte Methodik wurde im Kapitel 3 vorgestellt. Aus den dort untersuchten Methoden wurden die am meisten Erfolg versprechen für die Vergleichsuntersuchungen ausgewählt. In Tabelle 5.1 werden die Verwendeten Experimente überblickend zusammengefasst. Die Tabelle ist wie folgt zu lesen. Alle Experimente werden mit „EXP x.y“ bezeichnet. Der Buchstabe „x“ steht für den Windpark und der Buchstabe „y“ für das jeweilige Experiment. In den Experimenten EXP x.1 bis EXP x.3 werden RN KNN eingesetzt. Diese haben jeweils fünf Neuronen im HL. Die Experimente EXP x.4 und EXP x.5 verwenden die vorgestellte Methodik der Metaprognose in Abschnitt 3.4.7. In dieser werden die jeweiligen Einzelprognosen mit den RN KNN aus den Experimenten EXP x.1 bis EXP x.3 berechnet. Anschließend wird die jeweiligen zwei Eingangsmodelle mit einem FF KNN kombiniert. Die jeweils verwendeten Datenanalysemethoden sind in der Tabelle 5.1 verwiesen.

Tabelle 5.1: Übersicht Experimentbezeichnungen im Kapitel

Bezeichnung	Inhalt
EXP x.1	RN KNN Prognose basierend auf Datenanalyseergebnissen des MKK nach Gleichung (3.6)
EXP x.2	RN KNN Prognose basierend auf Datenanalyseergebnissen der Entropie nach Gleichung (3.18)
EXP x.3	RN KNN Prognose basierend auf Datenanalyseergebnissen des linearen nichtlinearen Informationsmaßes nach Gleichung(3.19)
EXP x.4	Metaprognose gemäß Methodik in Abschnitt 3.4.7 basierend auf den Datenanalyseergebnissen des MKK und der Entropie
EXP x.5	Metaprognose gemäß Methodik in Abschnitt 3.4.7 basierend auf den Datenanalyseergebnissen des MKK und des linearen nichtlinearen Informationsmaßes

Im Abschnitt 5.3 wird zusätzlich der Mehrwert der Prozessoptimierung untersucht. Dazu werden die EXP 4.1 bis EXP 4.5 mit der angewendeten Prozessoptimierung wiederholt. Die zusätzlichen Experimente werden mit EXP 4.6 bis 4.10 bezeichnet, entsprechen den inhaltlich angewendeten Methoden den Experimenten EXP x.1 bis x.5. Im Abschnitt 5.4 werden zwei unterschiedliche Photovoltaik Anlagen untersucht. Dementsprechend werden die Experimente

für die erste Anlage als EXP SP 1.1 bis EXP SP 1.5 bezeichnet und für die zweite Anlage als EXP SP 2.1 bis EXP SP 2.5. Das entspricht jeweils den angewendeten Methoden in den Experimenten EXP x.1 bis EXP x.5.

5.1 Windpark 2

Die Auswertung für WP 2 ergab, dass für die Einzelprognosen die auf dem MKK (EXP WP 2.1) basierende Prognose das beste Ergebnis mit einem NRMSE von 11,93% lieferte. EXP WP 2.2 erzielte 11,94 NRMSE mit einer Verschlechterung von $-0,11\%$ gegenüber EXP WP 2.1 und EXP WP 2.3 11,95% NRMSE in Abbildung D.18 mit $-0,17\%$ Verschlechterung gegenüber EXP WP 2.1.

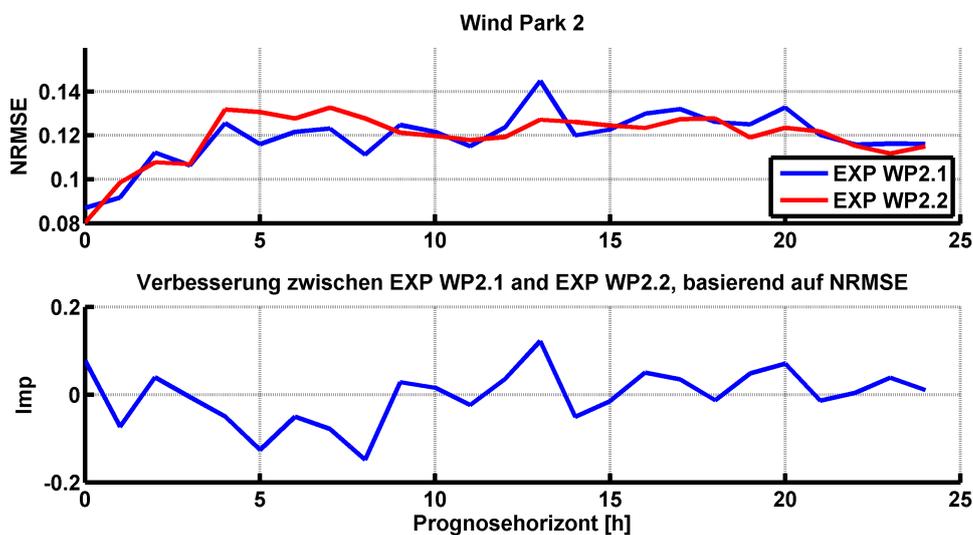


Abbildung 5.1: Vergleich Fehlerauswertung EXP WP 2.2 mit EXP WP 2.1

Aus den durchgeführten Metaprognosen erreichte die Kombination EXP WP 2.5 aus MKK und linearer, nichtlinearer Information mit 12,00% NRMSE das beste Ergebnis, vgl. Abbildung 5.2. Somit erreichte die Einzelprognose basierend auf dem MKK, EXP WP 2.1, ein besseres Ergebnis. Die zweite Metaprognose EXP WP 2.4 erlangte 12,07% NRMSE.

Die Periodogrammanalyse in Abbildung 5.3 mit dem Test auf das Rauschverhalten ergibt, dass beide Methoden ein ähnliches Verhalten der Kurvenscharen aufweisen. Die Streuung der Scharen ist in EXP WP 2.5 etwas breiter gefächert als in EXP WP 2.1. Beide Methoden haben noch einen signifikanten Restinformationsgehalt.

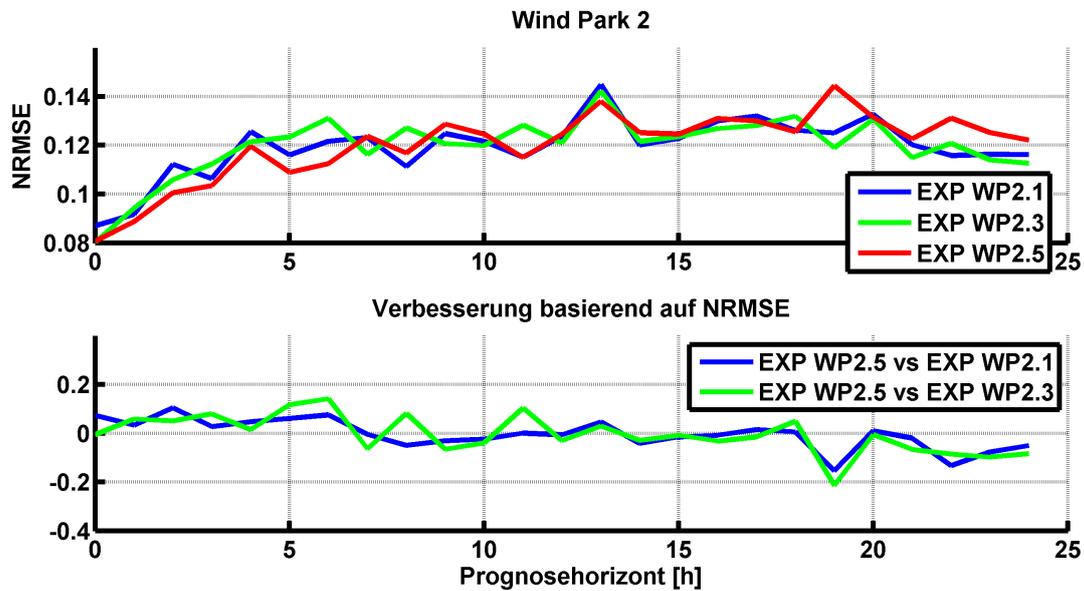


Abbildung 5.2: Vergleich Fehlerevaluation EXP WP 2.5 mit EXP WP 2.1 und WP 2.3

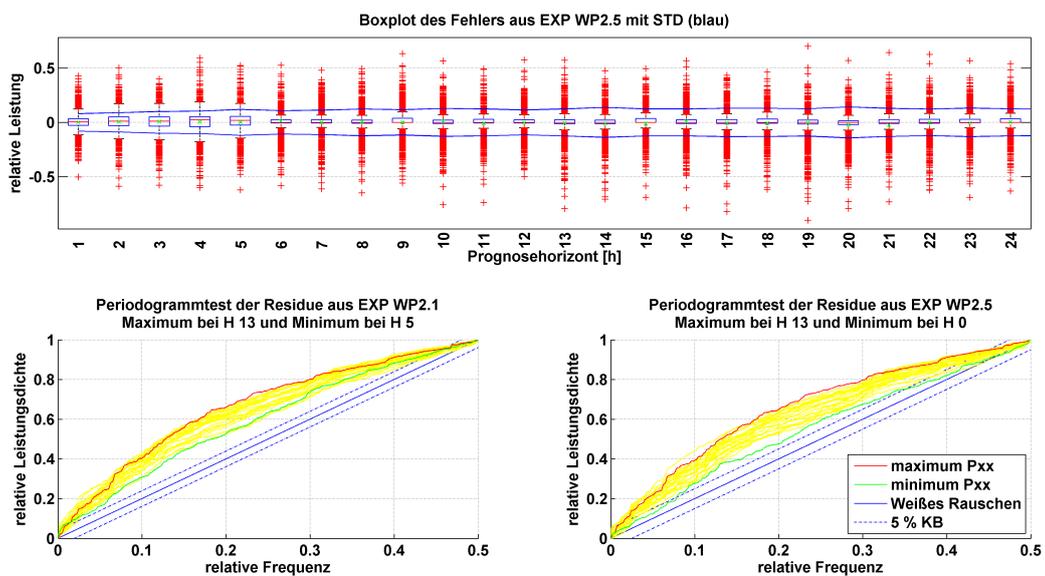


Abbildung 5.3: Validierung EXP WP 2.5 mit EXP WP 2.1

5.2 Windpark 3

Für Windpark 3 ermittelte die MKK basierende Methode in EXP WP 3.1 mit 17,33% NRMSE den niedrigsten Fehlerwert für die Einzelprognose. Die Experimente erzielten für EXP WP 3.2 20,63% NRMSE mit einer Verschlechterung von $-18,69\%$ gegenüber EXP WP 3.1 und EXP WP 3.3 18,48% mit einer Verschlechterung von $-7,15\%$, vgl. Abbildung 5.4.

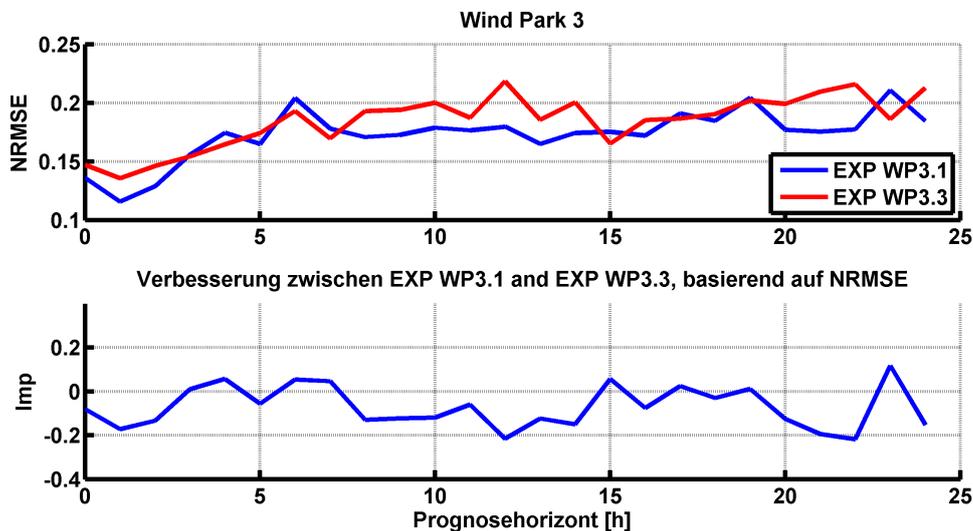


Abbildung 5.4: Vergleich Fehlerauswertung EXP WP 3.3 mit EXP WP 3.1

Für die Metaprognosen erzielte EXP WP 3.5 mit 15,10% NRMSE das beste Ergebnis. Somit erreichte es eine Verbesserung von 9,49% gegenüber EXP WP 3.1, vgl. Abbildung 5.5. EXP WP 3.4 erzielte 16,3% NRMSE und damit eine Verbesserung von 5,43% gegenüber EXP WP 3.1.

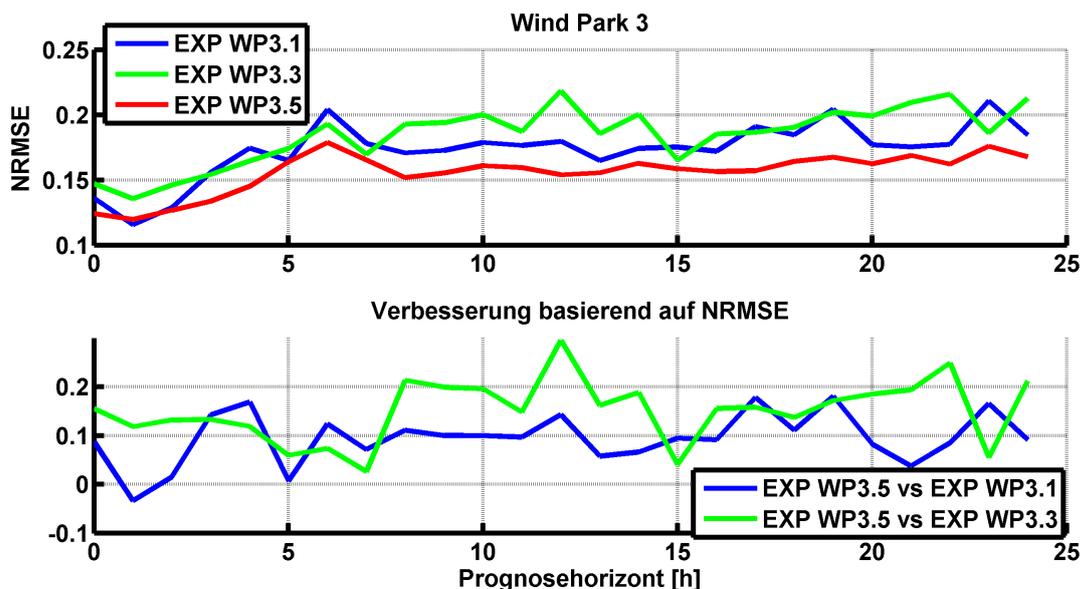


Abbildung 5.5: Vergleich Fehlerauswertung EXP WP 3.5 mit EXP WP 3.1 und WP 3.3

Die Periodogrammanalyse zwischen EXP WP 3.5 und EXP 3.1 in Abbildung 5.6 zeigt, dass für beide Methoden bleibende Restinformation vorhanden ist. Sie verfügen über mehrere

Kurvenscharen, die innerhalb des Bandes für das weiße Rauschen bleiben. Zwei Unterschiede werden anhand der Grafiken sichtbar. Erstens zeigt EXP WP 3.5 ein leicht stärkeres Überschreiten des Rauschbandes als EXP WP 3.1 im mittleren Frequenzbereich von 0,2 bis 0,3. Zweitens ist die Kurvenschardichte für EXP WP 3.5 innerhalb des Rauschbands deutlich stärker als bei EXP WP 3.1.

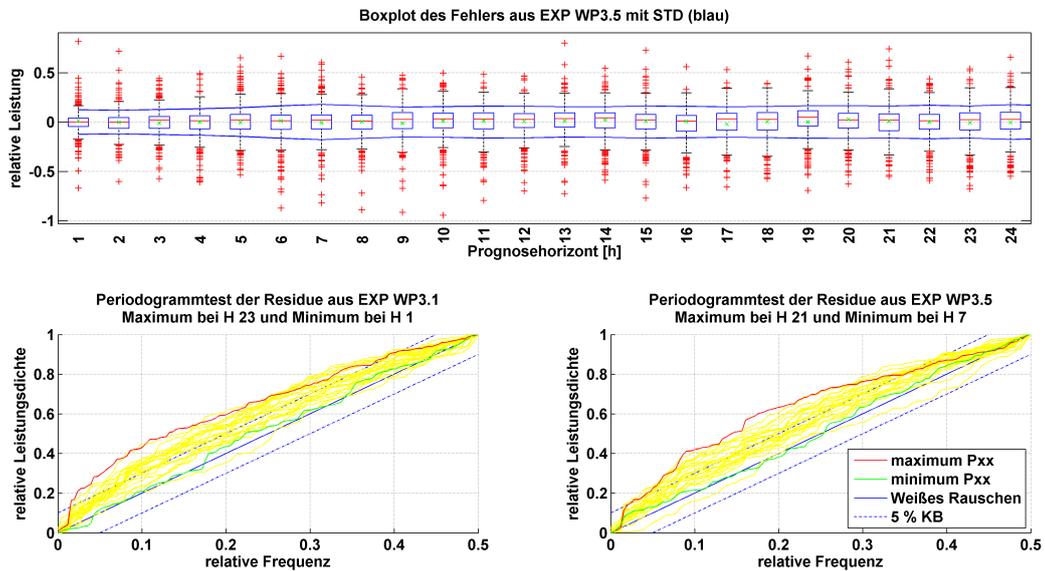


Abbildung 5.6: Validierung EXP WP 3.5 mit EXP WP 3.1

5.3 Windpark 4

Für WP 4 werden zwei Versuchsreihen untersucht. Zuerst wird wie in der bisherigen Arbeit die Datenanalyse und Prognose mit den vorgegebenen Zeitparametern berechnet. Anschließend wird der Prognoseprozess optimiert, indem für jeden Monat im Validierungszeitraum erneut eine Datenanalyse mit Prognosemodellbildung erstellt wird. Dadurch soll der Prozess Veränderungen saisonaler Zusammenhänge folgen können.

5.3.1 Prognose

Für die Einzelprognosen in Abbildung 5.7 zeigte die auf dem MKK (EXP WP4.1) basierende Prognose das beste Ergebnis mit 20,15% NRMS, gefolgt von der linearen, nichtlinearen Information (EXP WP4.2) mit 21,44% NRMSE und der bedingten Entropie (EXP WP4.3) mit 31,72% NRMSE, vgl. Abbildungen D.29 bis D.31.

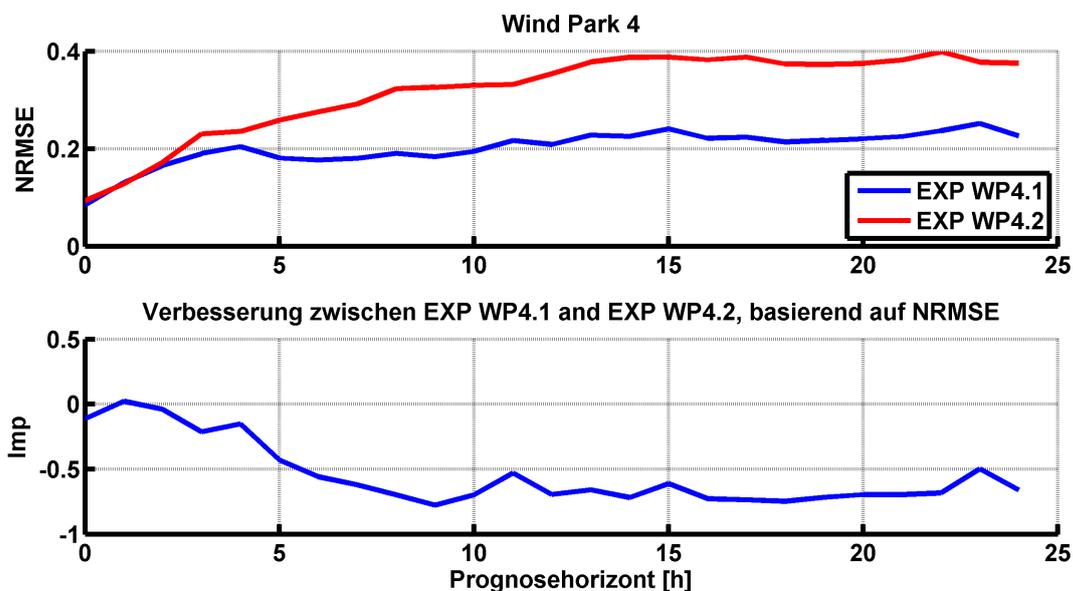


Abbildung 5.7: Vergleich Fehlerauswertung EXP WP 4.2 mit EXP WP 4.1

Für die Metaprognosen erzielte die Kombination (EXP WP4.5) aus MKK und linearer, nichtlinearer Information das beste Ergebnis mit 18,62% NRMSE, vgl. Abbildungen 5.8 und 5.9. Die Residuenanalyse zeigt leichte Verbesserungen gegenüber EXP WP 4.1. Die Metaprognose mit der Kombination (EXP WP4.5) MKK und bedingter Entropie erzielte 18,85% NRMSE und hat damit leicht schlechtere Ergebnisse, vgl. Abbildungen D.32 und D.33.

Die Metaprognose aus EXP WP 4.5 zeigt eine durchgehende Verbesserung gegenüber den Einzelprognosen. Einzige Ausnahme sind die Horizonte 0 und 1 gegenüber EXP WP 4.1 dem MKK basierten Ansatz. Hier konnte keine Verbesserung erreicht werden.

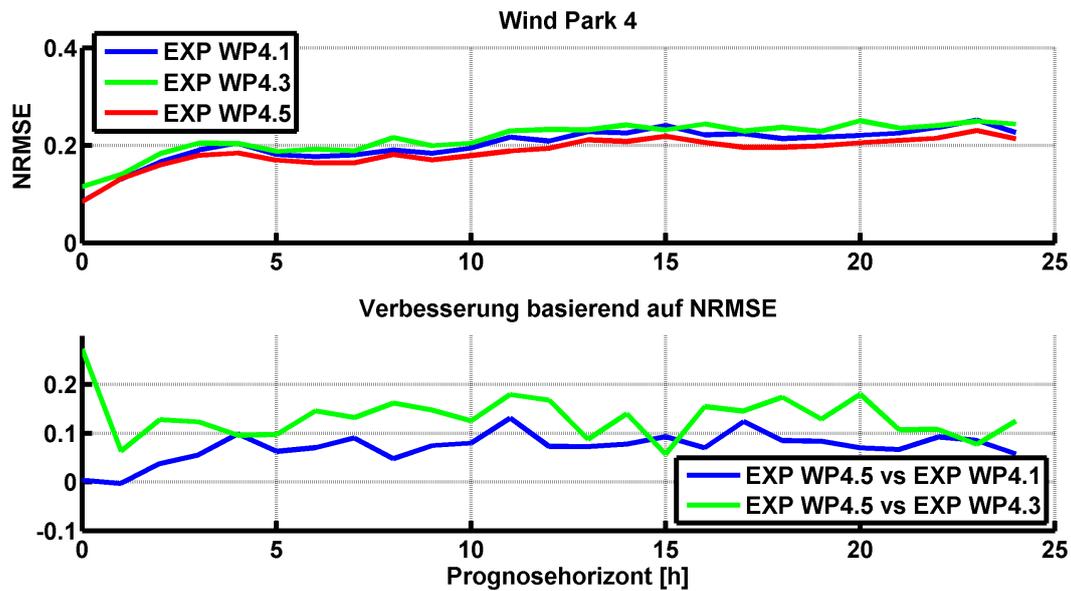


Abbildung 5.8: Vergleich Fehlerauswertung EXP WP 4.5 mit EXP WP 4.1 und WP 4.3

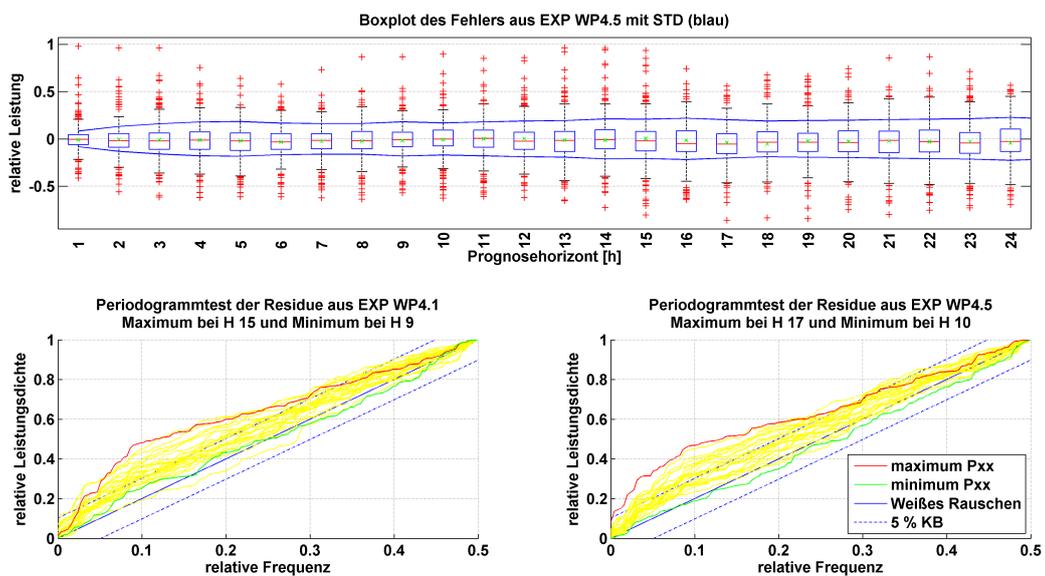


Abbildung 5.9: Validierung EXP WP 4.5 mit EXP WP 4.1

5.3.2 Prozessoptimierung

Neben der Selektion der idealen Methoden wurde die prozesstechnische Abhängigkeit untersucht. Das bisher gewählte Vorgehen beinhaltete eine Datenanalyse und Anwendung deren Ergebnisse auf den gesamten Validierungszeitraum. Für die Prozessoptimierung wurde nach jedem Monat eine neue Datenanalyse simuliert. Mit den neuen Ergebnissen wurden neue Prognosen trainiert. Nachfolgend werden ausgewählte Ergebnisse vorgestellt.

EXP WP 4.6 ist die monatliche MKK basierende Prognosemethode, EXP WP 4.7 die Entropie und EXP WP 4.8 die lineare, nichtlineare Information. Die Metaprognosen EXP WP 4.9 basieren auf EXP WP 4.6 und 4.7 und EXP WP 4.10 auf 4.6 und 4.8. Für die Einzelprognosen änderte sich das Ergebnis nicht. EXP WP 4.6 erzielte das beste Ergebnis und verbesserte das Ergebnis von EXP WP 4.1 auf 19,46% NRMSE mit einer Verbesserung von 3,45%. EXP WP 4.7 erreichte 28,29% NRMSE und EXP WP 4.8 20,92% NRMSE.

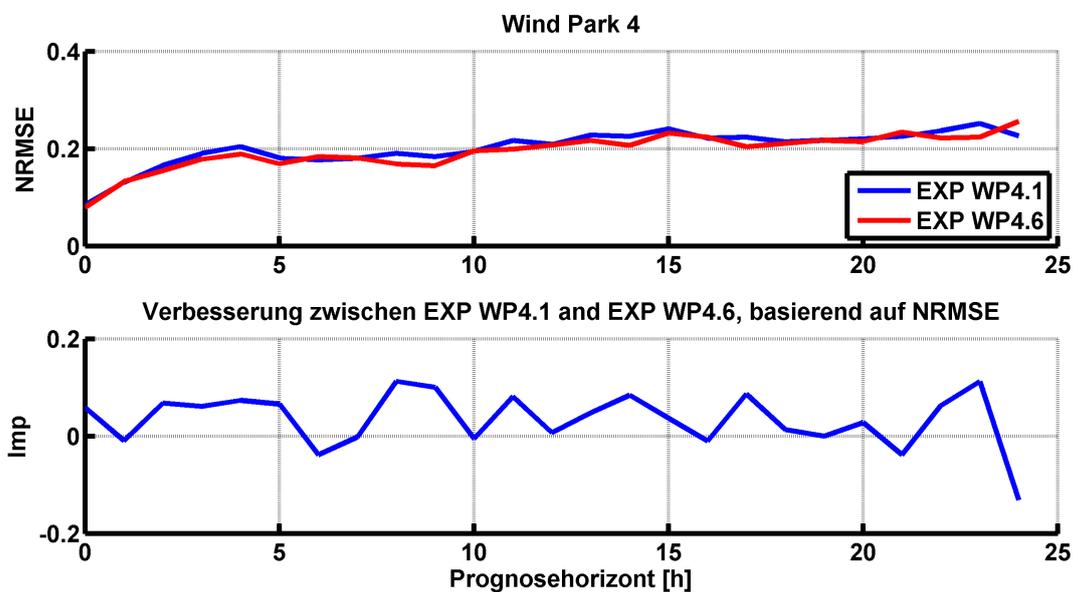


Abbildung 5.10: Vergleich Fehlerauswertung EXP WP 4.6 mit EXP WP 4.1

Aus allen Experimenten für WP 4 wies EXP WP 4.10 das beste Ergebnis mit 18,11% NRMSE und einer Verbesserung von 6,51% gegenüber EXP WP 4.6. auf. EXP WP 4.9 erzielte mit 18,21% NRMSE eine Verbesserung von 6,0% gegenüber EXP WP 3.6.

Die Periodogrammanalyse zeigt bei beiden Experimenten EXP WP 4.6 und 4.10 in Abbildung 5.12 keine signifikanten Unterschiede zwischen den Ansätzen. Beide zeigen verbleibende Information der Residuen. Ein leichter Unterschied ist im Verhalten der Kurvenschar bei einer Frequenz von ca. 0,25 zu erkennen. Für EXP WP 4.10 dringen die Kurven etwas früher in das Rauschband ein als in EXP WP 4.6.

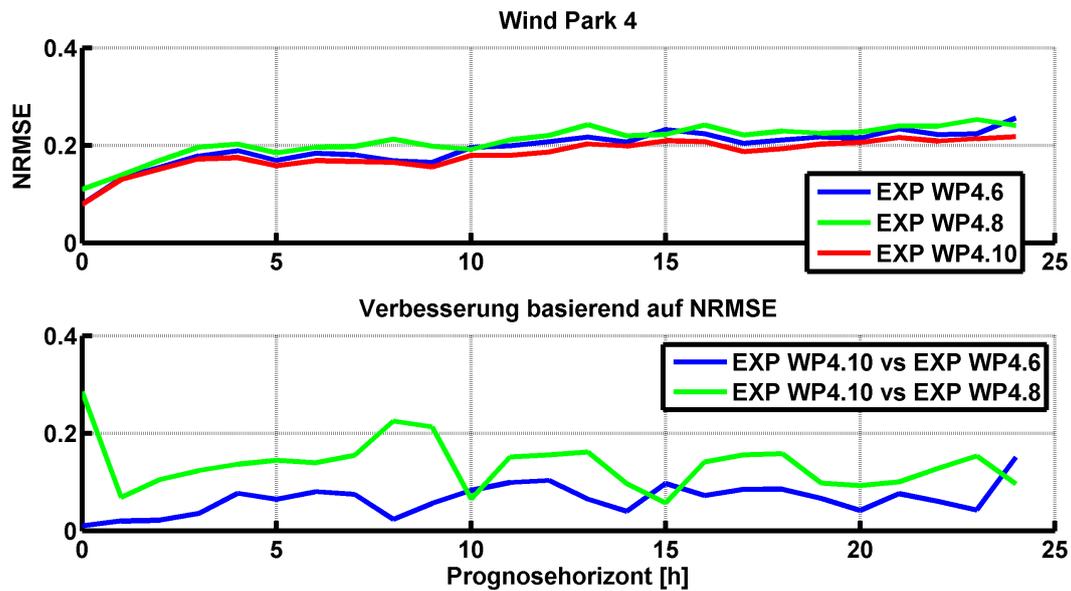


Abbildung 5.11: Vergleich Fehlerauswertung EXP WP 4.10 mit EXP WP 4.6 und WP 4.8

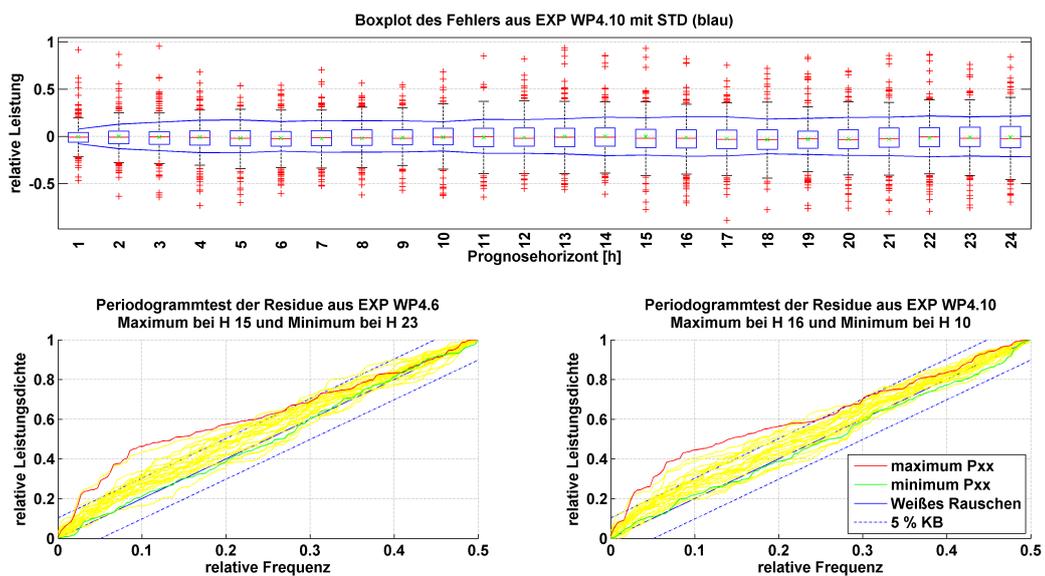


Abbildung 5.12: Validierung EXP WP 4.10 mit EXP WP 4.6

5.4 Übertragbarkeit auf Photovoltaik-Anlagen

Die Übertragbarkeit der Prognosemethodik wurde anhand der Photovoltaik (PV) untersucht. Zwei Datensätze von jeweils einer stationären PV-Anlage (SP1) und einer mitgeführten PV-Anlage (SP2) wurden zusammengestellt. Die Datenvorverarbeitung verlief analog wie für die Windleistungsprognose. Es wurden keine PV spezifischen Anpassungen an den Algorithmen vorgenommen. Beide Datensätze umfassen den Zeitraum vom 1.7.2014 bis 31.1.2015 für das Training und vom 1.2.2015 bis zum 1.5.2015 für die Evaluierung. Der Datenanalyse stand ein Datensatz bestehend aus den Messwerten und den prognostizierten Klimagrößen eines DWD Wettermodells zur Verfügung. Die Klimagrößen sind die Globalstrahlung, die Temperatur, der Luftdruck, der Wolkenbedeckungsgrad und die Windgeschwindigkeit. Die Ergebnisse der Analysen zeigen, dass die Windgeschwindigkeit und die Lufttemperatur neben der Globalstrahlung und dem Wolkenbedeckungsgrad einen signifikanten Einfluss haben. Für die Prognose wurde das ARX-Modell verwendet. Die Experimente sind bezeichnet mit EXP SP1.x bzw. EXP SP2.x für die jeweilige PV-Anlage. EXP SPx.1 verwendet die Datenanalyse für den Multiplen Korrelationskoeffizienten, EXP SPx.2 das lineare und nichtlineare Informationsmaß, EXP SPx.3 die Entropie und EXP SPx.4 den Korrelationskoeffizienten.

Das beste Ergebnis für die stationäre PV-Anlage erzielte EXP SP1.3 mit einem NRMSE von 14,35% mit der Entropieanalyse gefolgt von EXP SP1.4 mit einem NRMSE von 14,56% mit der Analyse des Korrelationskoeffizienten. Die mittlere Verbesserung zwischen beiden Ergebnissen beträgt 0,93%, vgl. Abbildung 5.13. Der Fehler beider Prognosen liegt sehr dicht beieinander. In den Prognosehorizonten 6 und 20 war das EXP SP1.4 besser.

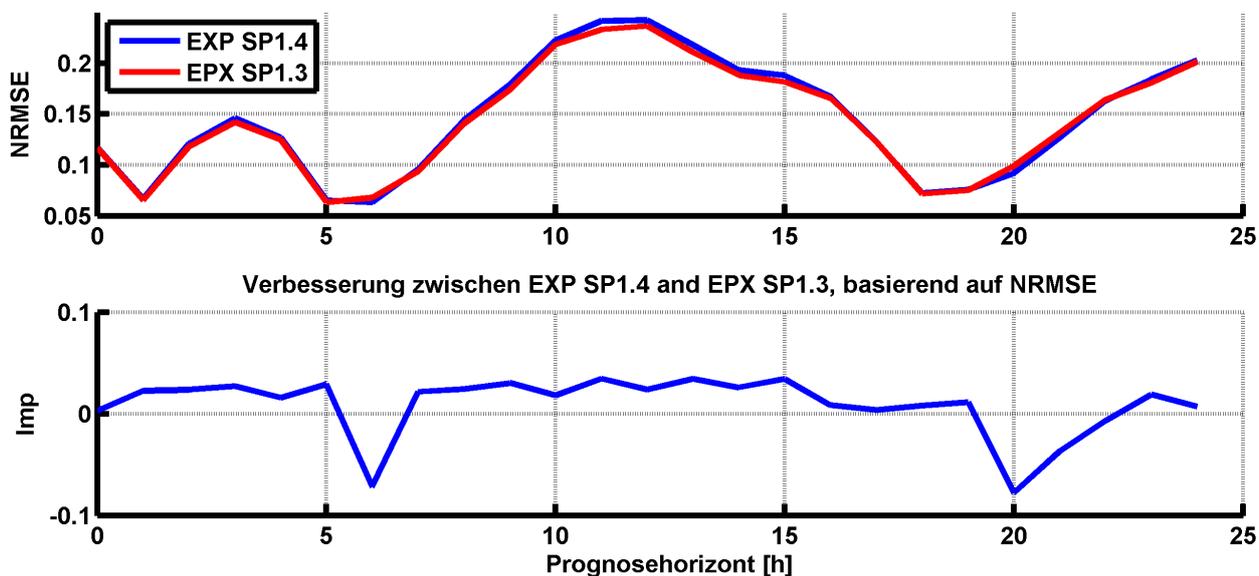


Abbildung 5.13: Vergleich Fehlerauswertung EXP SP1.3 gegenüber EXP SP1.4

Beide Experimente zeigen in den Periodogrammtests der Abbildung 5.14 verbleibende Informationen in den Residuen. Der Unterschied zwischen beiden Experimenten ist, dass EXP SP1.4 über größere Bereiche Verletzungen des Konfidenzbandes zeigt.

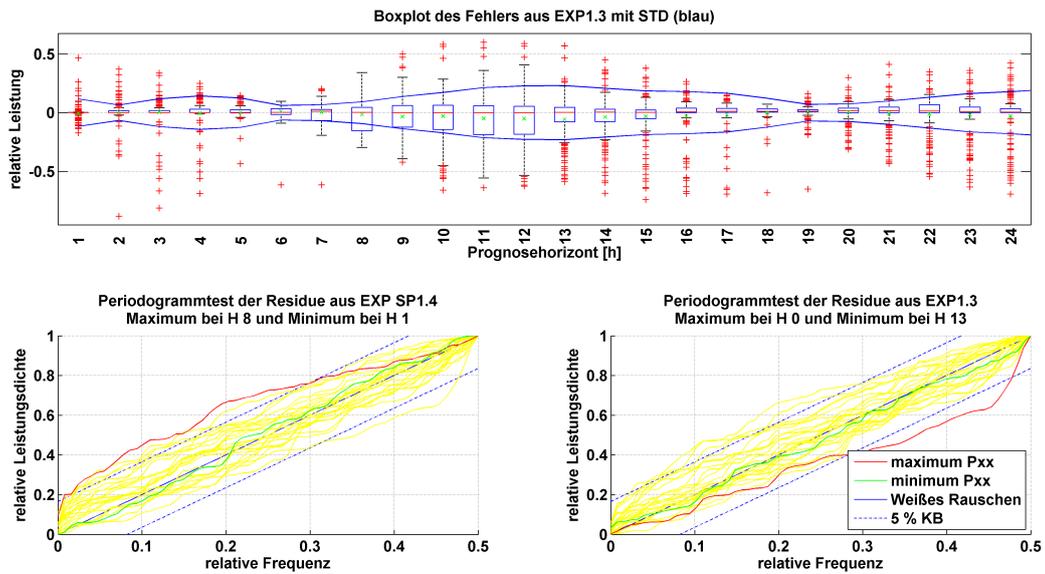


Abbildung 5.14: Validierung EXP SP1.3 mit EXP SP1.4

Das beste Ergebnis für die nachgeführte PV-Anlage erzielte EXP SP2.3 mit einem NRMSE von 20,21% mit der Entropieanalyse gefolgt von EXP SP2.1 mit einem NRMSE von 20,27%. Die Verbesserung zwischen beiden Experimenten beträgt 0,21%, vgl. Abbildung 5.15. Gegenüber der stationären PV-Anlage ist die Dominanz der jeweiligen Prognose wechselhafter.

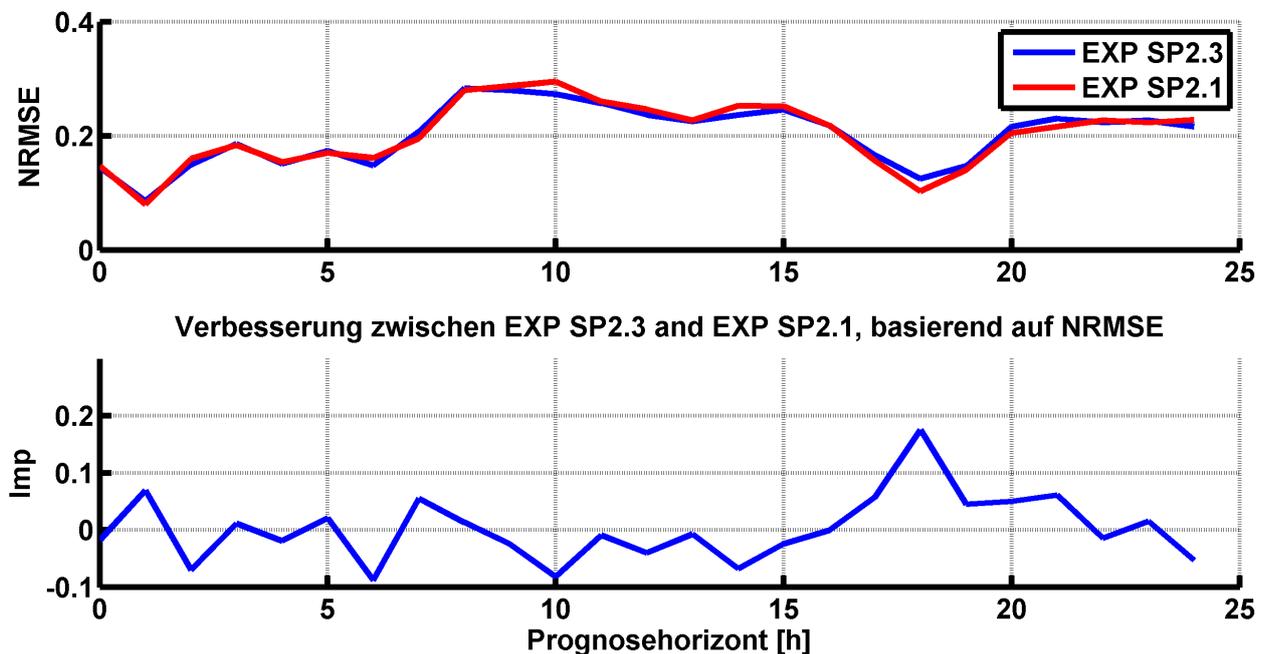


Abbildung 5.15: Vergleich Fehlerevaluation EXP SP2.3 gegenüber EXP SP2.1

Die Periodogrammtests in Abbildung 5.16 zeigen größere Unterschiede untereinander. Die maximale Abweichung ist für beide Experimente etwa gleich groß. EXP SP2.3 hat mehr Kurvenscharen, die aus dem Konfidenzband ausbrechen. Dem gegenüber entfernen sich die Kurvenscharen des EXP SP2.1 weiter vom Konfidenzband. Die Ergebnisse der restlichen Experimente befinden sich im Anhang unter Abschnitt D.4. Die Diskussion der vorgestellten Ergebnisse wird im anschließenden Kapitel 6 durchgeführt.

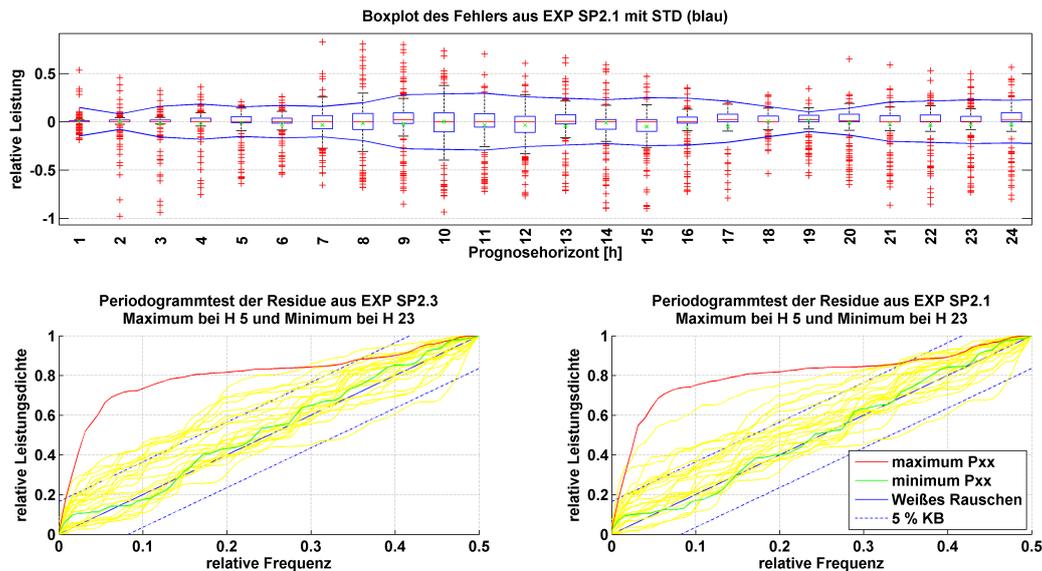


Abbildung 5.16: Validierung EXP SP2.3 mit EXP SP2.1

5.5 Zusammenfassung exemplarischer Untersuchungen

In diesem Kapitel wurde die Anwendbarkeit der entwickelten Methodik auf unterschiedliche Windparks sowie als Übertragbarkeitsuntersuchung auf Photovoltaik-Anlagen untersucht. Anhand der verfügbaren Beispiele sind die hier vorgestellten Beispiele empirische Untersuchungen, die nicht generelle Aussagen liefern. Die Ergebnisse dieser Untersuchungen liefern jedoch Tendenzen, die in fortführenden Arbeiten berücksichtigt werden sollten.

Aus technischer Sicht lassen sich beliebige Prognoseaufgaben mit ähnlicher Datenstruktur und -abhängigkeiten berechnen. Es wird vorausgesetzt, dass das Prognoseziel als äquidistante Messwertzeitreihe vorliegt. Die exogenen Größen müssen entweder als kontinuierliche Zeitreihe oder als Einzelprognosen in gleicher Struktur der DWD-Wetterprognosen vorliegen. Weiterhin wird vorausgesetzt, dass alle Daten in gleicher Abtastzeit vorliegen. Sind diese Voraussetzungen erfüllt, können beliebige Prognoseaufgaben mit den entwickelten Methoden ausgeführt werden.

Die Ergebnisse sind nicht eindeutig, weisen aber starke Tendenzen auf. Bei den Prognosen basierend auf einer Datenanalysemethode, hat die MKK Methode in den vergleichenden Analysen die besten Ergebnisse erzielt. Im Modellierungskapitel 3 wurde das beste Ergebnis mittels der Entropie erzielt. Die Metaprognose führte nur für die Windparks WP 3 und WP 4 zu Verbesserungen. Für alle Windparks führte die Metaprognose basierend auf dem MKK und dem linearen nichtlinearen Informationsmaß zu den besten Ergebnissen. In den Übertragbarkeitsuntersuchungen erzielte eindeutig die Einzelprognose basierend auf den Entropie-Datenanalysen die besten Ergebnisse. Die Metaprognose führte zu keiner Verbesserung. Für die erste PV-Anlage wurde die Metaprognose basierend auf dem MKK und der

Entropie das bessere Ergebnis. Aufgrund der Tatsache, dass keine Methode immer das beste Ergebnis erzielte, wird empfohlen, dass bei einer Einrichtung einer neuen Prognose alle fünf Varianten aus Tabelle 5.1 untersucht werden. Anschließend kann das beste Ergebnis operativ eingerichtet werden.

Die Auswertung des Fehlermaßes NRMSE zeigt, dass die Fehler deutlich größer als in Kapitel 3 sind. Es liegen nicht ausreichend Informationen über die Qualität der punktuellen Prognosedaten aus dem NWP System der untersuchten Windparks vor. Daher könnte über die Ursache an dieser Stelle ausschließlich spekuliert werden. Aus technischer Sicht wurden die identischen Algorithmen eingesetzt. Daher kann das abweichende Verhalten ausschließlich an der Qualität und Umfang der zur Verfügung stehenden Daten liegen. Es würde größere Datensätze und Referenzmessungen der Klimagrößen benötigen, damit dieser Sachverhalt weiter untersucht werden kann.

Das Ergebnis der Prozessoptimierung in Abschnitt 5.3.2 zeigt, dass es sich empfiehlt die trainierten Prognosen iterativ neu zu trainieren, um die Wissensbasis der trainierten Prognosemethode aktuell zu halten.

6 Diskussion und Zusammenfassung

6.1 Diskussion

Zu Beginn der Arbeit wurden im Abschnitt 1.3 mehrere Fragen gestellt, die durch die Bearbeitung des Themas beantwortet werden können. Dieser Abschnitt geht auf die Fragestellungen ein und reflektiert sie mit den Rechercheergebnissen.

Die erste Fragestellung lautet welche Methoden des Data Mining geeignet sind. Es wurden die Methoden basierend auf der Varianz, des Korrelationskoeffizienten und dem Informationsmaß untersucht. Es stellte sich heraus, dass die HKA ein sehr effektives Mittel ist, um große Datenmengen zu bearbeiten. Mit Hilfe ihrer identifizierten Parameter konnten Prognosen erstellt werden. Die Ergebnisse empfehlen nicht den Einsatz der HKA als Datenanalyseverfahren für die Windleistungsprognose. Als stärkste Methode der Korrelationskoeffizienten hat sich der MKK mit einer Gradientenoptimierung präsentiert. Mit nur leicht schlechteren Werten präsentierte sich die Berechnung der Korrelationskoeffizientenmatrix. Das Ergebnis ist insofern bedeutend, wenn es notwendig ist zeitlich hoch performante Prognosen zu entwickeln. Auf Grund des geringeren algorithmischen Aufwandes kann die Korrelationsmatrix in Sekundenbruchteilen ermittelt werden. Das beste Ergebnis in Abschnitt 3.3 lieferte die bedingte Entropie Berechnung. Ihr Ergebnis liegt mit dem MKK sehr dicht beieinander. Im Falle von Einzelprognosen ist zu prüfen, welche beiden Methoden das bessere Ergebnis liefern. In den Vergleichsrechnungen mit WP 4 war die bedingte Entropie mit Abstand die schlechteste Prognose. Die Methoden wurden anhand eines Windparks entwickelt und mit drei weiteren getestet. Somit liefern sie eine Tendenz, können aber keine pauschalisierte Aussage für alle Windparks treffen. Weiterhin zeigen die Ergebnisse, dass für jeden Windpark individuell zu prüfen ist, welche Analyseverfahren die optimalen sind. Mit dem gemeinsamen Informationsmaß wie auch dem linearen und nichtlinearen Informationsmaß konnte keine Verbesserung erzielt werden. Letztere zeigte jedoch erhebliches Verbesserungspotential, wenn sie in einer Metaprognose kombiniert wird. WP 2 zeigt, dass die Metaprognose nicht pauschal immer bessere Ergebnisse liefern muss. Speziell für diesen WP gab es auch Prognosehorizonte, in denen keine Verbesserung erzielt werden konnte. Die Tendenz mit den Experimenten der WP 3 und 4 ist gegeben, dass die Verwendung der Metaprognose zu einer Güteverbesserung führt.

Die zweite Frage hatte zur Aufgabe herauszufinden, welche Modellklassen sich zur Windleistungsprognose eignen. In dieser Arbeit wurden auf Grund der Informationslage die stochasti-

schen Signalmodelle untersucht. Für die Systemmodelle wurde ein sehr einfacher Vertreter auf Basis der Windertragungsgleichung (1.1) verwendet. Außer dem technischen Datenblatt standen keine weiteren Informationen für eine genauere Modellierung zur Verfügung. Sein Einsatz als Referenzmethode im Abschnitt 3.4.1 konnte kein überzeugendes Ergebnis liefern. Das soll die Modellklasse jedoch nicht abwerten. Viele erfolgreiche Windprognoseanbieter arbeiten mit Systemmodellen. Das Ergebnis macht jedoch die Schwächen der Klasse deutlich. Mit unzureichender Modellierung auf Grund von mangelnden Informationen kann die Modellklasse keine guten Ergebnisse liefern. Als Vertreter der linearen stochastischen Signalmodelle wurde das ARX(1)-Modell im Abschnitt 3.4.2 identifiziert. Es wurde mit einem ARX(3)-Modell gegengeprüft. Auf Grund mangelnder signifikanter Verbesserung wurde letzteres als Prognosemodell verworfen. Das ARX(1)-Modell lieferte so gute Ergebnisse, dass erst ein RN als Vertreter der nichtlinearen stochastischen Signalmodelle seine Prognoseergebnisse verbessern konnte, vgl. Abschnitt 3.4.3. Das Ergebnis zeigt, dass durch die Maximierung des funktionalen Zusammenhangs der Eingangsdaten in das Prognosemodell die linearen Modelle so stark werden, dass nur mit optimierten RN bessere Ergebnisse erzielt werden konnten. Unter der Voraussetzung, dass die funktionalen Zusammenhänge in zukünftigen Arbeiten weiter gesteigert werden können, sollte es möglich sein die linearen Modelle als Prognosemodelle zu verwenden. Der Vorteil wäre, dass sie einfacher beschreibbar sind und zu nachvollziehbaren Ergebnissen führen. Sollte das nicht gelingen, sind die RN die geeignete Prognosemethode. Es wurden Ansätze untersucht, wie die Ergebnisse von RN zu besseren Ergebnissen führen können. Anhand dieser Ergebnisse wird empfohlen, dass bei Prognosen für neue Windparks weiterhin entsprechend BOX-JENKINS geprüft wird welche der identifizierten Modelle sich besser eignet.

Als dritter Punkt wurde die Frage gestellt mit welchen Mitteln die optimale Prognose erreicht werden kann. Entsprechend dem Modellbildungsprozess nach BOX-JENKINS können die Einzelprognosen erstellt und ihre Parameter optimiert werden. Die Periodogrammanalysen nach Abschnitt 3.1 zeigen jedoch, dass nie alle Horizonte einem weißen Rauschen entsprechen. Angeregt durch den Stand der Wissenschaft wurde eine Metaprognose eingeführt. Weil sie nicht wie in anderen Arbeiten auf Basis unterschiedlicher NWP-Modelle durchgeführt werden konnte, ist sie auf Basis unterschiedlicher mathematischer Charakteristiken realisiert wurden. Das erste Experiment vereinte den MKK mit der bedingten Entropie. Das sind die besten Einzelprognosen, demnach hätte ihre Metaprognose das beste Gesamtergebnis liefern müssen. Die nicht abschätzbare Kombination aus MKK mit der linearen, nichtlinearen Information erwies sich als beste Prognose. Durch die Metaprognose wurden die Periodogramme der jeweiligen Horizonte in das Konfidenzband des weißen Rauschens gezogen. Somit stellt sie das Optimum dieser Arbeit dar. Die Abweichungen deuten an, dass es noch weiteres Optimierungspotential gibt. Im Rahmen dieser Arbeit wurde mit den untersuchten Mitteln das Optimierungspotential ausgeschöpft. Demzufolge müssen weitere hier nicht aufgeführte Techniken untersucht werden, um die Prognose weiter zu verbessern.

Viertens stellte sich die Frage inwiefern der Fehler vorgelagerter Klimaprognosen das Ergebnis beeinflusst. Die Sensitivitätsanalyse in Abschnitt 3.3.2 zeigt, dass neben der Windgeschwindigkeit die Lufttemperatur und der Luftdruck entscheidenden Einfluss auf die Ertragungsgleichung

(1.1) haben. Eine Fehleranalyse der Windgeschwindigkeit von einer Messstation zu den zwei nächstgelegenen Gitterpunkten des NWP-Modells der 10 m Höhengschicht zeigt, dass Fehler im Mittel 1,5 m/s und in Extremfällen von über 10 m/s auftreten können. Dazu wurde der Fehler prognosehorizontabhängig analysiert. Mit Experiment 6 gab es eine Konstellation in dem der Fehler bedingt durch die Klimaprognose schlecht ausgeglichen werden konnte. Die Fehlercharakteristik aus Abbildung 3.31 ist im Fehlersignal von EXP 6 in Abbildung 3.27 wiederzufinden. Die Kombination aus individueller Modellbildung für jeden einzelnen Prognosehorizont und die jeweilige Datenanalyse schaffte es die Zusammenhänge der dargebotenen Signale so zu nutzen, dass der Einfluss der Fehlercharakteristik minimiert werden konnte.

Fünftens wurde sich die Frage gestellt ob die entwickelte Methodik übertragbar ist. Zu diesem Zweck wurde je eine stationäre und nachgeführte PV-Anlage untersucht. Es wurden keinerlei Anpassungen an den Algorithmen oder der Datenvorverarbeitung unternommen. Beide Prognosen erzielten ihre besten Resultate mit der Entropieanalyse. Mit Fehlern von 14,35% und 20,21% NRMSE liegen sie in einem vergleichbaren Bereich der Windleistungsprognosen. Die exemplarischen Untersuchungen zeigen, dass die Übertragbarkeit der grundlegenden mathematischen Algorithmen gegeben ist. Weitere Untersuchungen werden empfohlen, um PV spezifisches Optimierungspotential zu identifizieren und auszunutzen.

Als letzter Punkt war von Interesse wie sich diese Arbeit in den Stand der Wissenschaft einordnet. Mittels statistischer Analysen wurden stochastische Signalmodelle erstellt. Diese verwenden vorgelagerte Klimaprognosen für die Prognose der Windleistungsprognose. Somit ist die entwickelte Methodik den Hybridmodellen zuzuordnen, wobei selbst kein Systemmodell verwendet wird.

In den recherchierten Arbeiten aus Abschnitt 1.2 und aktuellen wissenschaftlichen Reviews [160] und [200] wurde kein Ansatz gefunden der Informationstheorie mit Korrelationsanalysen verbindet. Insbesondere die bedingte Entropie ist hervorzuheben. Sie löst aufgrund ihrer Berechnungsmethode zeitliche Zusammenhänge auf. Stattdessen werden die Zusammenhänge in den Verteilungsfunktionen der Parameter gesucht und maximiert. Ebenso wurde gezeigt, dass mittels der linearen, nichtlinearen Information eine Prognose erstellt werden kann. Das stellt ein weiteres Novum in der Windleistungsprognose dar. Somit wurden gezielt die mathematischen Charakteristiken der Varianz, der Information, der Entropie und der linearen Funktion zur Datenanalyse eingesetzt.

Die Datenverarbeitung wurde in vielen Arbeiten nicht näher betrachtet. Mehrere Ansätze arbeiten mit Flächen bzw. Regionen-Betrachtungen. Sie skalieren von einem großen Modell ihre Ergebnisse auf einzelne Windparks. Der Ansatz dieser Arbeit ist entgegengesetzt. Es wird explizit ein Windpark modelliert und es wird nicht pauschal oder gewichtet alle zur Verfügung stehenden Daten verwendet. Vielmehr werden mittels Datenanalyseverfahren, die geeignetsten Datensätze für die Prognose identifiziert und angewendet. Somit werden stark fehlerbehaftete Informationen nicht berücksichtigt und der Prognose eine stärkere Ausgangsbasis gegeben. Entsprechend des Stands der Technik werden in der Energieindustrie mehrere Windleistungsprognosen miteinander vermischt. Eine weitere Technik verbindet mehrere Klimaprognosen unterschiedlicher Anbieter miteinander. Eine Dokumentation einer Metaprognose auf Basis unterschiedlicher Datenanalysemodelle, wie sie in dieser Arbeit entwickelt wurde, konnte

nicht gefunden werden.

Die entwickelte Methodik und die daraus gewonnenen Erkenntnisse wurden im Prototyp MAProSy umgesetzt. Auf dieser Basis wurde ein Softwarekonzept für operative Anwendungen entwickelt. Diese beiden beruhen auf einer entwickelten Datenbanklösung zur Speicherung der Klimaprognosen, dass die entwickelte Methodik unterstützt.

6.2 Zusammenfassung

Im Rahmen dieser Arbeit wurde der Stand der Wissenschaft aufgearbeitet. Anhand der Analyse konnte festgestellt werden, dass Windleistungsprognosen auf Basis unterschiedlicher Modellkategorien basieren. Ein in über zehn Jahren wenig bis gar nicht veröffentlichtes Thema ist der Einfluss der Datenanalyse insbesondere des Data Minings auf die Prognose. Im Laufe der Bearbeitung des Themas und durch die Erkenntnisse der Literaturrecherche wurde der Fokus auf die Datenanalyse gerichtet. Als Innovation wurden die Daten auf ihre unterschiedlichen statistischen Eigenschaften untersucht und diese miteinander kombiniert. Als geeignete Methoden haben sich die MKK-, die bedingte Entropie-Analyse und die Verwendung des linearen, nichtlinearen Informationsmaßes herausgestellt. Nicht geeignet sind die Methoden HKA und Faktorenanalyse. Die Verwendung des MKK sowie des linearen, nichtlinearen Informationsmaßes wurde in keiner recherchierten Quelle verwendet. Mit Hilfe des BOX-JENKINS-Verfahrens wurde das ARX Modell als geeignetes Prognosemodell identifiziert und getestet. Nur durch die Verwendung eines RN konnte deren Güte verbessert werden. Für die eingesetzten NN wurden Experimente durchgeführt, wie Verfahrensweisen zur weiteren Verbesserung führen können. Abschließend wurde die Metaprognose in innovativer Form eingesetzt und konnte zusätzliche Gütesteigerungen erzielen. Weiterhin wurde eine Kennzahl eingeführt, um den Güteanteil der Datenanalyse und des Prognosemodells in der Prognose zu messen. Dieser zeigt, dass die Datenanalyse ca. 80% Güteanteil an der Prognose besitzt. Die Prognosemethodik wurde erfolgreich an zwei PV-Anlagen getestet. Neben der Datenanalyse wurde der Einfluss der Datenstruktur auf die Prognosequalität bewertet. Ein verlustfreies Speicherformat für Integration historischer Klimaprognosen ist unabdingbar, damit qualitativ performante Prognosemodelle trainiert werden können. Schließlich wurden die Erkenntnisse dieser Arbeit in einen Prototypen MaProSy integriert, mit Hilfe dessen produktive Prognosen umgesetzt werden können.

6.3 Ausblick

Für die Fortführung der Arbeiten empfiehlt es sich nicht berücksichtigte Methoden des Stands der Technik und Wissenschaft zu integrieren. Es wird unter anderem eine Verbesserung der Prognoseleistung erwartet, wenn mehrere unterschiedliche Wettermodelle in den Prognoseprozess integriert werden können. Ein weiterer Punkt ist die Integration probabilistischer Prognosen. Eine Variante ist es die probabilistischen Szenarien von Klimaprognosen zu

berücksichtigen. Diese werden von einigen meteorologischen Institutionen angeboten. Eine andere Möglichkeit ist es mit Hilfe der Analog Ensemble Methode oder der Quantilen Regression eigene probabilistische Prognosen zu erstellen. Schließlich ist der Prototyp MaProSy in ein Produktivsystem zu überführen. Weiterhin empfiehlt es sich die Methode auf die Solarstromprognose anzuwenden. Als solche ist sie gleichfalls von Klimagrößen abhängig und lässt eine Eignung vermuten.

Anhang

A Übersicht der Experimente aus Kapitel 3

Die folgende Tabelle A.1 gibt einen Überblick über alle durchgeführten Experimente im Modellierungskapitel 3. Es wird der verwendete Bezeichner und die jeweiligen, zusammengefassten Inhalte des jeweiligen Experiments angegeben.

Tabelle A.1: Übersicht Experimentebezeichnungen im Kapitel 3 und deren Aufbau

Bezeichnung	Inhalt
EXP 1	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Korrelationskoeffizientenanalyse durchgeführt. Die exogenen Größen mit den jeweils stärksten Koeffizienten werden ausgewählt.
EXP 2	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Hauptkomponentenanalyse durchgeführt. Es werden die exogenen Größen gewählt, die die größten Anteile an der beschreibenden Gesamtvarianz enthalten.
EXP 3	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einem Gradientenanstiegsverfahren.
EXP 4	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 5	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells auf Basis des EXP 4 durchgeführt. Die Datenanalyse erfolgt mit einem angepassten Datensatz, der einem OZM Datenspeichersystem entspricht. Die eigentliche Prognose wird mit Hilfe eines VDS Datenspeichersystems durchgeführt.
EXP 6	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells auf Basis des EXP 4 durchgeführt. Die Datenanalyse und die Prognose wird mit einem angepassten Datensatz durchgeführt, der einem OZM System entspricht. Die im Training verwendeten Daten entstammen noch einem VDS Datenspeichersystem.
EXP 7	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells auf Basis des EXP 4 durchgeführt. Die Datenbasis wird entsprechend eines OZM Datenspeichersystems angepasst. Anschließend wird Datenanalyse, Prognosetraining und die Evaluierung der Prognose mit diesem komplett transformierten Datensatz durchgeführt.
EXP 8	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Analyse basierend auf dem gemeinsamen Informationsmaß durchgeführt.

Bezeichnung	Inhalt
EXP 9	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Analyse basierend auf der bedingten Entropie durchgeführt.
EXP 10	Es wird eine Prognose mit Hilfe des deklarierten ARX(1)-Modells durchgeführt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Analyse basierend auf dem linearen nichtlinearen Informationsmaß durchgeführt.
EXP 11	Es wird die Prognose der Persistenzmethode untersucht. Dazu wird ausschließlich das autoregressive Signal die Leistungsmessung verwendet
EXP 12	Es wird die Prognose basierend dem Systemmodell der Leistungsentnahme für Windkraftanlagen berechnet, vgl. Gl. (1.1). Für die Prognose werden die Klimaprognosewerte ohne identifizierender Datenanalyse verwendet.
EXP 13	Es wird eine Prognose mit Hilfe des eines ARX(e)-Modells durchgeführt. Die Ordnung des ARX-Modells wurde entsprechend des BOX-JENKINS-Verfahren ermittelt. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 14	Es wird eine Prognose mit Hilfe eines FF KNN durchgeführt. Der HL hat fünf Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 15	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Der HL hat drei Neuronen und der OL ein Neuron. Die Ermittlung der Neuronenanzahl im HL erfolgt über eine Strukturoptimierung. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 16	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Durch Vorgabe hat der HL drei Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 17	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Durch Vorgabe hat der HL fünf Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 18	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Durch Vorgabe hat der HL zehn Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 19	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Durch Vorgabe hat der HL elf Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 20	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Durch Vorgabe hat der HL 15 Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 21	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Durch Vorgabe hat der HL 44 Neuronen und der OL ein Neuron. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.

Bezeichnung	Inhalt
EXP 22	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Der HL hat zwei Neuronen und der OL ein Neuron. Die Ermittlung der Neuronenanzahl im HL erfolgt über eine Strukturoptimierung. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der MKK-Analyse durchgeführt, basierend auf einer Permutation zur Maximierung des linearen Gesamtzusammenhangs.
EXP 23	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Der HL hat drei Neuronen und der OL ein Neuron. Die Ermittlung der Neuronenanzahl im HL erfolgt über eine Strukturoptimierung. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Analyse basierend auf der bedingten Entropie durchgeführt.
EXP 24	Es wird die Metaprognose mit einem FF KNN durchgeführt. Durch Vorgabe hat der HL drei Neuronen und der OL ein Neuron. Die Eingangsdaten des FF KNN sind die Ausgänge der Prognosemodelle des EXP 15 und EXP 23.
EXP 25	Es wird eine Prognose mit Hilfe eines RN KNN durchgeführt. Der HL hat drei Neuronen und der OL ein Neuron. Die Ermittlung der Neuronenanzahl im HL erfolgt über eine Strukturoptimierung. Die Identifizierung der Eingangsdatenbelegung des Prognosemodells wird mit Hilfe der Analyse basierend auf dem linearen nichtlinearen Informationsmaß durchgeführt.
EXP 26	Es wird die Metaprognose mit einem FF KNN durchgeführt. Durch Vorgabe hat der HL drei Neuronen und der OL ein Neuron. Die Eingangsdaten des FF KNN sind die Ausgänge der Prognosemodelle des EXP 15 und EXP 25.

B Analyse der Literaturrecherche

Die folgende Tabelle B.3 listet die aktuellen Ergebnisse zum Stand der Wissenschaft über die Windleistungsprognose in alphabetischer und zeitlicher Sortierung auf. Jede Methode wurde kurz beschrieben und in eine Kategorie eingeordnet. Die Kategorien sind in Abschnitt 1.2 beschrieben.

Übersicht aller Arbeiten mit grober Kategorisierung

Tabelle B.2: Übersicht aller erfassten Arbeiten zur Windleistungs- und Windgeschwindigkeitsprognose

Kategorie	Windleistungsprognose	Windgeschwindigkeitsprognose	Σ
Physikalisch	2012: [105]; 2007: [36]	2010: [118]; 2009: [212]	4
Stochastisch	2015: [201], [199], [198], [147], [40] 2014: [176], [132], [94], [54] 2013: [202], [93], [53] 2012: [175], [124], [206], [187]; 2011: [51], [50], [119], [87], [49], [14], [210], [69], [31]; 2010: [55]; 2009: [104], [29], [98], [208], [109], [85], [26], [174]; 2008: [169], [47]; 2007: [140]; 2006: [8], [138], [4], [134], [168]; 2005: [67], [173]; 2003: [186]; 2001: [122]; 1999: [11]; 1998: [144]	2011: [13], [192], [158], [97], [203]; 2010: [149], [121], [56]; 2009: [123], [137], [148], [44], [191]; 2008: [127], [182], [181]; 2007: [25]; 2006: [151], [153]; 2005: [66], [188], [143]; 2002: [84]	71
Hybrid	2015: [9] 2013: [10], [150]; 2012: [129], [30], [52], [207], [178], [126], [205], [179]; 2011: [204], [91], [15]; 2010: [28]; 2009: [157], [82], [7], [58], [156], [70], [185]; 2008: [27]; 2007: [180], [35], [61], [142], [167]; 2006: [114], [130], [141], [34], [102], [80]; 2004: [154], [102]; 2003: [103], [163], [164]; 2002: [116], [76]; 2001: [75], [77]; 2000: [74]; 1999: [111]	2012: [48]; 2011: [194]; 2009: [166], [135], [6]; 2008: [170]; 2006: [37]; 1972: [83]	53

Auswertung aktueller Arbeiten

Tabelle B.3: Detailübersicht wissenschaftlicher Arbeiten von 2011 bis 2013

Titel	Referenz	Kategorie	Güte	Datenbasis
A novel application of an analog ensemble for short-term wind power forecasting	[9, 2015]	Hybrid	<i>NRMSE</i> 14,0 – 17,0%	NWP, MD
A Novel Wind Power Forecast Model: Statistical Hybrid Wind Power Forecast Technique (SHWIP)	[147, 2015]	Stochastisch	<i>NRMSE</i> 13,0 – 24%	NWP, MD
A Short-Term Wind Power Forecasting Approach With Adjustment of Numerical Weather Prediction Input by Data Mining	[199, 2015]	Stochastisch	<i>NRMSE</i> 5,0 – 15,0%	NWP, MD

Titel	Referenz	Kategorie	Güte	Datenbasis
Multi-Stage Wind-Electric Power Forecast by Using a Combination of Advanced Statistical Methods	[40, 2015]	Stochastisch	<i>NMAE</i> 11,0%	NWP, MD
Multistep Wind Power Forecast Using Mean Trend Detector and Mathematical Morphology-Based Local Predictor	[198, 2015]	Stochastisch	<i>NRMSE</i> 2,0 – 13,0%	MD
Support-Vector-Machine-Enhanced Markov Model for Short-Term Wind Power Forecast	[201, 2015]	Stochastisch	<i>NMAE</i> 2,0 – 9,0%	MD
A Hybrid Intelligent Model for Deterministic and Quantile Regression Approach for Probabilistic Wind Power Forecasting	[94, 2014]	Stochastisch	<i>MAPE</i> 12,0%	...
Hybrid Forecasting Model for Very-Short Term Wind Power Forecasting Based on Grey Relational Analysis	[176, 2014]	Stochastisch	<i>MAPE</i> 1,5 – 3,5%	MD
Probabilistic wind power forecasts with an inverse power curve transformation and censored regression	[132, 2014]	Stochastisch	unübliche Fehlermaße	NWP, MD
Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction	[54, 2014]	Stochastisch	<i>NRMSE</i> 11,5%	NWP, MD
A comparison between the ECMWF and COSMO Ensemble Prediction Systems applied to short-term wind power forecasting on real data	[10, 2013]	Hybrid	<i>NRMSE</i> 12,0 – 20,0%	NWP, MD
A hybrid strategy of short term wind power prediction	[150, 2013]	Hybrid	<i>NRMSE</i> 3,66 – 5,31%	NWP, MD
An RBF Neural Network Combined with OLS Algorithm and Genetic Algorithm for Short-Term Wind Power Forecasting	[53, 2013]	Stochastisch	<i>MAE</i> 2,0 – 39,0%	MD
GARCH in mean type models for wind power forecasting	[93, 2013]	Stochastisch	<i>NRMSE</i> 4,2%	MD
Probabilistic Short-Term Wind Power Forecast Using Componential Sparse Bayesian Learning	[202, 2013]	Stochastisch	<i>NMAE</i> 3,5 – 19,0%	NWP, MD
A Method for Short-Term Wind Power Prediction With Multiple Observation Points	[105, 2012]	Physikalisch	<i>NRMSE</i> 3,27%	NWP, MD
A Wind Power Forecasting System to Optimize Grid Integration	[129, 2012]	Hybrid	<i>NMAE</i> 8 – 17%	NWP, MD
AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network	[30, 2012]	Hybrid	<i>NRMSE</i> 1h - 2,849%; 12h - 8,752%; 24h - 13,040%; 30h - 16,090%	NWP, MD

Titel	Referenz	Kategorie	Güte	Datenbasis
Cerebellar Model Controller Applied in Wind Power Prediction	[175, 2012]	Stochastisch	$RMSE$ 1,89% (unklarer Prognosehorizont)	NWP
Generalized feed-forward based method for wind energy prediction	[52, 2012]	Stochastisch	MAE (Ist-Werte) 3,9 – 4,2%	MD
Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China	[207, 2012]	Hybrid	$NRMSE$ 24h - 16,47%	NWP, MD
Probabilistic Wind Power Forecasting Using Radial Basis Function Neural Networks	[178, 2012]	Hybrid	$NMAE$ 1h - 6%; 41h - 9%	NWP, MD
Regional Wind Power Forecasting Based on Smoothing Techniques, With Application to the Spanish Peninsular System	[126, 2012]	Hybrid	$NRMSE$ 1h - 1,3%; 12h - 4,9%; 24h - 5,2%; 48h - 6%	NWP, MD
Short-Term Wind Power Prediction Using a Wavelet Support Vector Machine	[205, 2012]	Hybrid	$MAPE$ 20min - 1%; 120min - 8%	NWP, MD
Short-Term Wind-Power Prediction Based on Wavelet Transform - Support Vector Machine and Statistic-Characteristics Analysis	[124, 2012]	Stochastisch	MRE 1h - 7,97%; 2h - 4,08%; 3h - 4,76%	MD
The assessment of the contribution of short-term wind power predictions to the efficiency of stand-alone hybrid systems	[183, 2012]	Stochastisch	$NRMSE$ 1st step 0,614m/s; 3rd step 0,926m/s Minutenbereich	MD
Wind Park Power Forecasting Models and Comparison	[206, 2012]	Stochastisch	$MAPE$ (Ist-Werte) 12,23%	MD
Wind Power Forecasting Focused on Extreme Power System Events	[179, 2012]	Hybrid	$NRMSE$ 1h - 9%; 12h - 13%; 24h - 15%; 48h - 17%	NWP, MD
Wind Power Forecasting in the Absence of Historical Data	[187, 2012]	Stochastisch	MRAN $NRMSE$ 1h - 11%; 24h - 21%; 40 - 23% GGAP $NRMSE$ 1h - 16%; 24h - 24%; 40h - 26%	MD
Hybrid intelligent approach for short-term wind power forecasting in Portugal	[51, 2011]	Stochastisch	$MAPE$ 3,08%	MD
Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal	[50, 2011]	Stochastisch	$MAPE$ 6,58% Jahresmittel	MD
Short Term Wind Power Prediction Using Evolutionary Optimized Local Support Vector Regression	[69, 2011]	Stochastisch	$MAPE$ 1% - 13%	MD
Short-Term Prediction of Wind Farm Output Using the Recurrent Quadratic Volterra Mode	[119, 2011]	Stochastisch	MSE 0,0371% - 0,0785%	MD

Titel	Referenz	Kategorie	Güte	Datenbasis
Short-term Wind Generation Forecasting and Confidence Interval Estimation Based on Neural Networks Trained by Extended Kalman Particle Filter	[87, 2011]	Stochastisch	<i>MAPE</i> 11,94% - 45,06%	MD
Short-term wind power forecasting in Portugal by neural networks and wavelet transform	[49, 2011]	Stochastisch	<i>MAPE</i> 6,97%	MD
Short-term wind power forecasting using ridgelet neural network	[14, 2011]	Stochastisch	<i>MAPE</i> 7,75% - 16,06%	MD
Short-term Wind Power Prediction Based on Statistical Clustering	[211, 2011]	Stochastisch	N.A.	MD
Support Vector Machine-Based Short-Term Wind Power Forecasting	[204, 2011]	Hybrid	N.A.	NWP, MD
Tabu Search Algorithm Optimized ANN Model for Wind Power Prediction with NWP	[91, 2011]	Stochastisch	<i>RMSE</i> 16,05%	NWP
Very short-term wind power forecasting with neural networks and adaptive Bayesian learning	[31, 2011]	Stochastisch	<i>NRMSE</i> 5min - 2,9%; 30min - 16,9%	MD
Wind Power Prediction by a New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization	[15, 2011]	Stochastisch	<i>NMAE</i> 2,21%	NWP, MD
ARIMA-Based Time Series Model of Stochastic Wind Power Generation	[55, 2010]	Stochastisch	N.A.	MD
Information Theoretic Learning applied to Wind Power Modeling	[28, 2010]	Hybrid	<i>NMAE</i> 11% - 21%	NWP, MD
Comparison of two new short-term wind-power forecasting systems	[157, 2009]	Hybrid	<i>NRMSE</i> 7% - 25%	NWP, MD
Data Mining For Multi-Criteria Energy Predictions	[82, 2009]	Hybrid	monatlich <i>RMSE</i> 0,053 - 0,064	NWP, MD
Day-ahead wind speed forecasting using f-ARIMA models	[104, 2009]	Stochastisch	<i>NRMSE</i> 5,35%	NWP, MD
Entropy and Correntropy Against Minimum Square Error in Offline and Online Three-Day Ahead Wind Power Forecasting	[29, 2009]	Stochastisch	<i>NMAE</i> 11% - 21%	NWP, MD
ESTIMATION OF WIND POWER PRODUCTION THROUGH SHORT-TERM FORECAST	[7, 2009]	Hybrid	<i>MAPE</i> 12% - 29%	NWP, MD
Forecast of Wind Speed and Power of Wind Generator based on Pattern Recognition	[98, 2009]	Stochastisch	<i>MAPE</i> 29,8%	MD

Titel	Referenz	Kategorie	Güte	Datenbasis
FORECASTING FOR UTILITY-SCALE WIND FARMS - THE POWER MODEL CHALLENGE	[58, 2009]	Hybrid	<i>NMAE</i> 10,5% - 16%	NWP, MD
From Probabilistic Forecasts to Statistical Scenarios of Short-term Wind Power Production	[156, 2009]	Hybrid	N.A.	NWP, MD
Research on wind power forecasting method using phase space reconstruction and artificial neural network	[208, 2009]	Stochastisch	relativer Fehler zu Ist-Werten -10% - 20%	MD
Short-Term Prediction of Wind Farm Power: A Data Mining Approach	[109, 2009]	Stochastisch	<i>MRE</i> 10min - 6,613%	MD
Wind energy prediction using a two-hidden layer neural network	[85, 2009]	Stochastisch	<i>MSE</i> 0,0156	MD
Wind Farm Power Prediction: A Data-Mining Approach	[110, 2009]	Hybrid	<i>MAE</i> 6% - 14%	NWP, MD
Wind power and photovoltaic prediction tools for balancing and grid operation	[70, 2009]	Hybrid	<i>NRMSE</i> 4%	NWP, MD
Wind Power Density Forecasting Using Ensemble Predictions and Time Series Models	[185, 2009]	Hybrid	<i>MAE</i> in [kW]	NWP, MD
Wind Power Forecast Using RBF Network and Culture Algorithm	[26, 2009]	Stochastisch	<i>MAE</i> in [kW]	MD
Wind Power Forecasting and Error Analysis using the Autoregressive Moving Average Modeling	Quelle einbinden	Stochastisch	N.A.	MD
Wind Speed Forecast for Wind Farms Based on ARMA-ARCH Model	[174, 2009]	Stochastisch	<i>MAE</i> 29,3762%	NWP, MD
Adaptive combination of forecasts with application to wind energy	[169, 2008]	Stochastisch	<i>MSPE</i> 1h - < 1%; 18h - > 5%	NWP, MD
Analysis of wind power generation and prediction using ANN: A case study	[47, 2008]	Stochastisch	N.A.	MD
Improvement in Wind Power Forecasting Based on Information Entropy-Related Concepts	[27, 2008]	Hybrid		NWP, MD
An Advanced Statistical Method for Wind Power Forecasting	[180, 2007]	Hybrid	<i>NRMSE</i> 1h - 7%; 42h - 14%	NWP, MD
Combination of Deterministic and Probabilistic Meteorological Models to enhance Wind Farm Power Forecasts	[35, 2007]	Hybrid	<i>NRMSE</i> 1h - 12%; 48h - 18%	NWP, MD
Detecting, Categorizing and Forecasting Large Ramps in Wind Farm Power Output Using Meteorological Observations and WPPT	[61, 2007]	Hybrid	<i>NRMSE</i> 1h - 9%; 36h - 25%	NWP, MD

Titel	Referenz	Kategorie	Güte	Datenbasis
Enhanced regional forecasting considering single wind farm distribution for upscaling	[36, 2007]	Physikalisch	<i>NRMSE</i> 1h - 2,5%; 72h - 9%	NWP, MD
Optimal Combination of Wind Power Forecasts	[142, 2007]	Hybrid	<i>RMSE</i> in [kW]	NWP, MD
Short Term Wind Power Forecasting Using Adaptive Neuro-Fuzzy Inference Systems	[100, 2008]	Hybrid	<i>NRMSE</i> 1,98%	NWP, MD
Short term wind power forecasting using hybrid intelligent systems	[140, 2007]	Hybrid	N.A.	NWP, MD
Short-Term Wind Energy Forecasting	[46, 2007]	Stochastisch	N.A.	MD
Wind power forecast error smoothing within a wind farm	[167, 2007]	Hybrid	<i>MSE</i> 10% - 18%	NWP, MD
Physical Approach to Short-Term Wind Power Prediction	[114, 2006]	Hybrid	<i>RMSE</i> 30% - 40% Jahresmittel Windgeschwindigkeit	NWP, MD
Evaluation of Advanced Wind Power Forecasting Models - Results of the Anemos Project	[130, 2006]	Hybrid	<i>NRMSE</i> 1h - 5%; 5h - 12%; 12h - 14%; 24h - 15%; 48h - 17%	NWP, MD
Fuzzy short-term electric load forecasting using Kalman filter	[8, 2006]	Stochastisch	<i>MAPE</i> 0,70	MD
IMPROVING WASP PREDICTIONS IN (TOO) COMPLEX TERRAIN	[138, 2006]	Stochastisch	N.A.	MD
Innovative Short-Term Wind Generation Prediction Techniques	[141, 2006]	Hybrid	N.A.	MD
Meteorological Models for Prediction and Simulation of Wind Power	[34, 2006]	Hybrid	<i>NRMSE</i> intra-day 3,5%; day-ahead 4,5%	NWP, MD
Next Generation Short-Term Forecasting of Wind Power - Overview of the ANEMOS Project	[102, 2006]	Hybrid	<i>NRMSE</i> 5% - 10%	NWP, MD
Short-term Forecasting Using Advanced Physical Modelling - The Results of the Anemos Project	[80, 2006]	Hybrid	<i>NRMSE</i> 5% - 10%	NWP, MD
Short-term prediction of wind energy production	[168, 2006]	Stochastisch	<i>MSPE</i> $1 * 10^6$ - $14 * 10^6$	NWP, MD
Short-term Wind Power Forecasting Using Advanced Statistical Method	Quellenachfragen	Hybrid	<i>NRMSE</i> 1h - 5,5%; 72h - 11%	NWP, MD
Short-term wind power prediction based on AR models	[67, 2005]	Stochastisch	<i>RMSE</i> in [kW]	MD
Time Series Forecasting of Averaged Data With Efficient Use of Information	[173, 2005]	Stochastisch	<i>MAPE</i> 12,33% - 15,13%	MD
Rechenmodelle und Informationssysteme zur Integration großer Windleistungen in die elektrische Energieversorgung	[163, 2003]	Hybrid	Absolute Fehlermaße	NWP, MD

B Analyse der Literaturrecherche

Titel	Referenz	Kategorie	Güte	Datenbasis
Statistical Wind Power Forecasting Models: Results for U.S. Wind Farms	[2, 2003]	Statistical	<i>RMSE</i> in [kW]	MD
Using medium-range weather forecasts to improve the value of wind energy production	[164, 2003]	Physikalisch	N.A.	NWP, MD
Previento - REGIONAL WIND POWER PREDICTION WITH RISK CONTROL	[116, 2002]	Hybrid	N.A.	NWP, MD
Short-term prediction of the aggregated power output of wind farms Fa statistical analysis of the reduction of the prediction error by spatial smoothing effects	[76, 2002]	Hybrid	N.A.	NWP, MD
A statistical analysis of the reduction of the wind power prediction error by spatial smoothing effects	[75, 2001]	Hybrid	<i>STD</i> 6h - 12%; 12h - 14%; 24h - 14%; 48h - 16%	NWP, MD
Previento - A Wind Power Prediction System with an Innovative Upscaling Algorithm	[77, 2001]	Hybrid	<i>NRMSE</i> der mittleren Leistung 4,7% - 7%	NWP, MD
Using neural networks to estimate wind turbine power generation	[177, 2001]	Stochastisch	Fehler in [kW]	MD
Räumliche Ausgleichseffekte bei der Vorhersage der Leistungsabgabe von Windkraftanlagen	[74, 2000]	Hybrid	<i>NRMSE</i> 6h - 33,4%; 12h - 33,4%; 18h - 38,2%; 24h - 40%; 36h - 36,5%; 48h - 41,8%	NWP, MD
Short-term prediction of the power production from wind farms	[111, 1999]	Hybrid	Fehler in [kW]	NWP, MD
Wind Speed and Power Forecasting based on Spatial Correlation Models	[11, 1999]	Stochastisch	Fehler 2,39% - 6,2%	MD
A New Reference for Wind Power Forecasting	[144, 1998]	Stochastisch	<i>RMSE</i> in [kW]	MD

C Validierungsanalysen der Modellierung

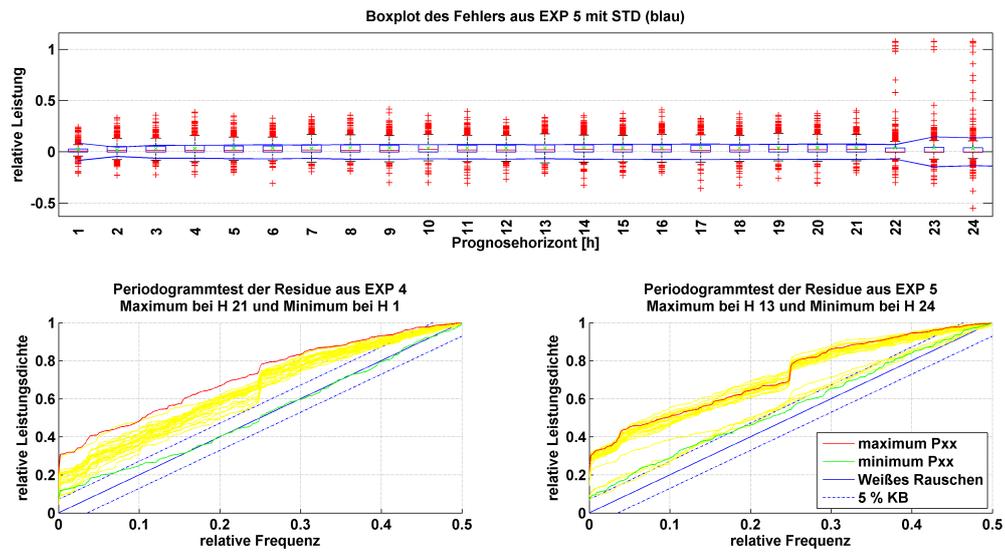


Abbildung C.1: Validierung EXP 5 mit Boxplot und Periodogramm gegen EXP 4

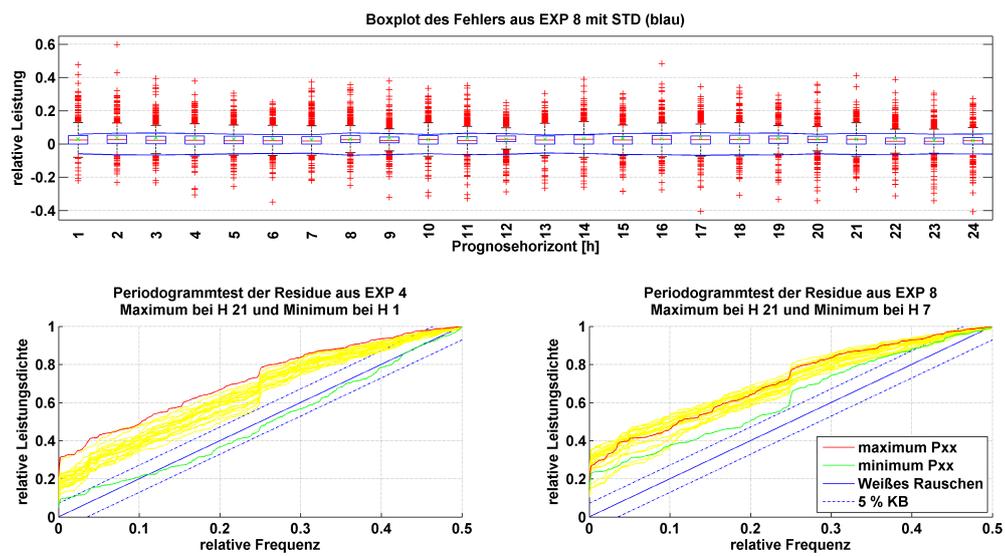


Abbildung C.2: Validierung EXP 8 im Vergleich zu EXP 4

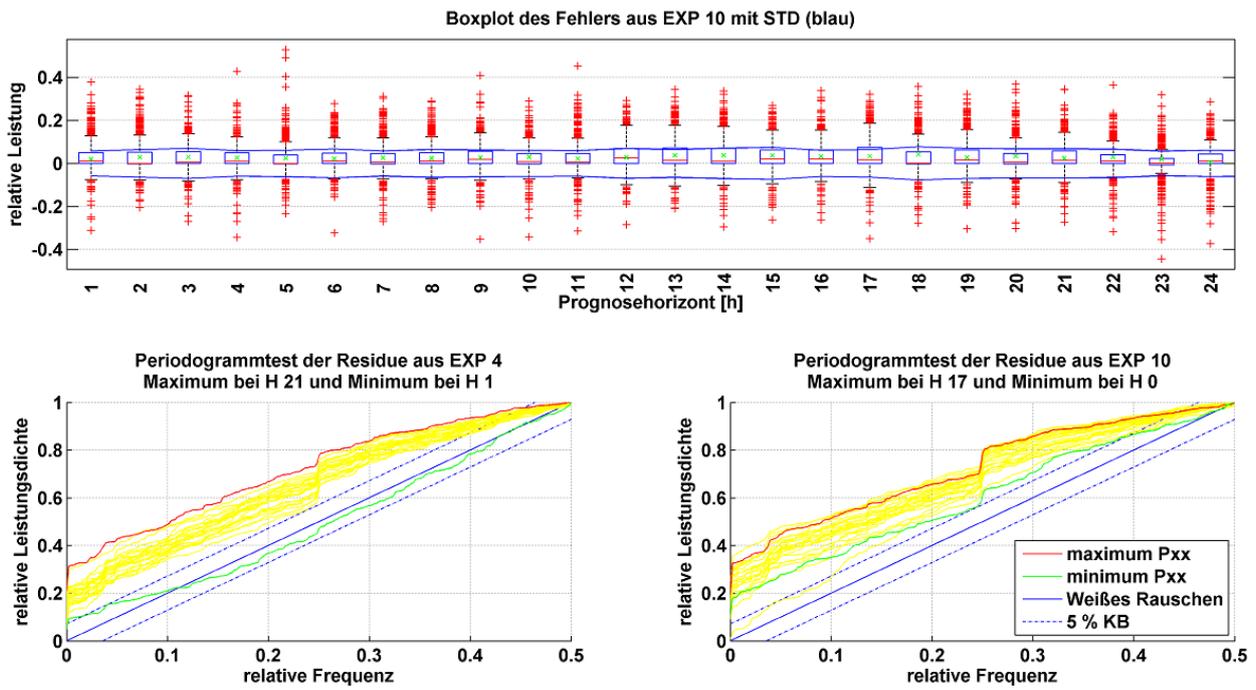


Abbildung C.3: Validierung EXP 10 im Vergleich zu EXP 4

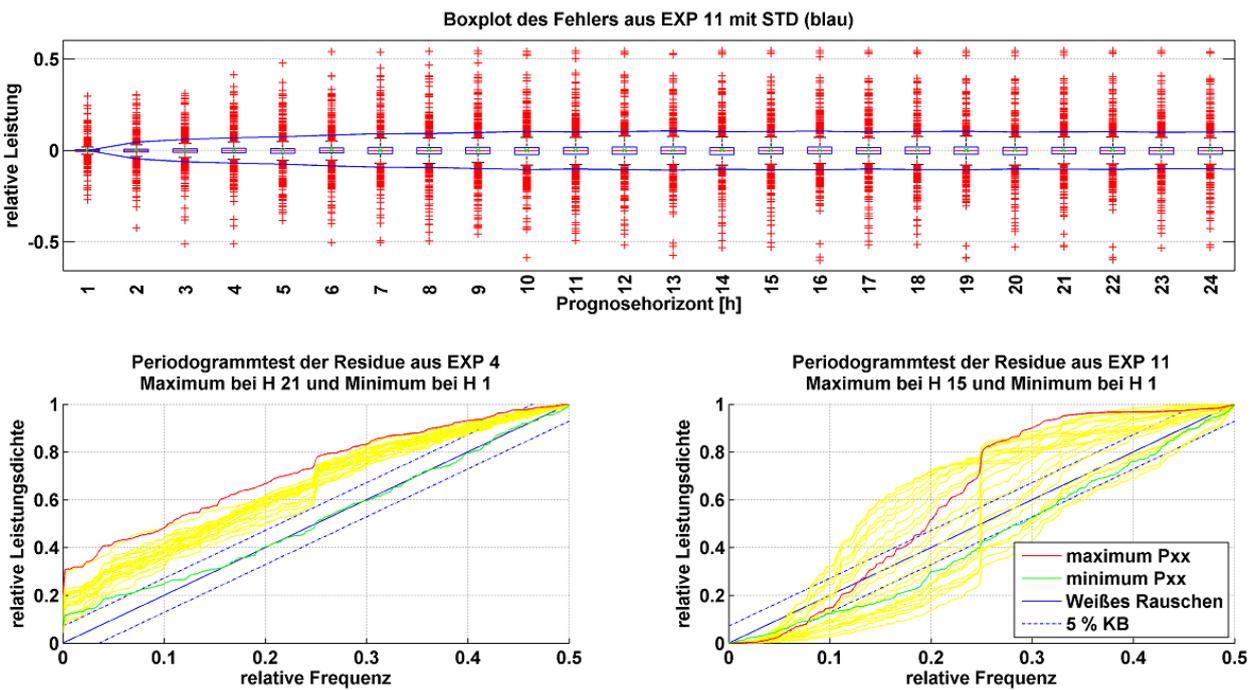


Abbildung C.4: Validierung EXP 11 im Vergleich zu EXP 4

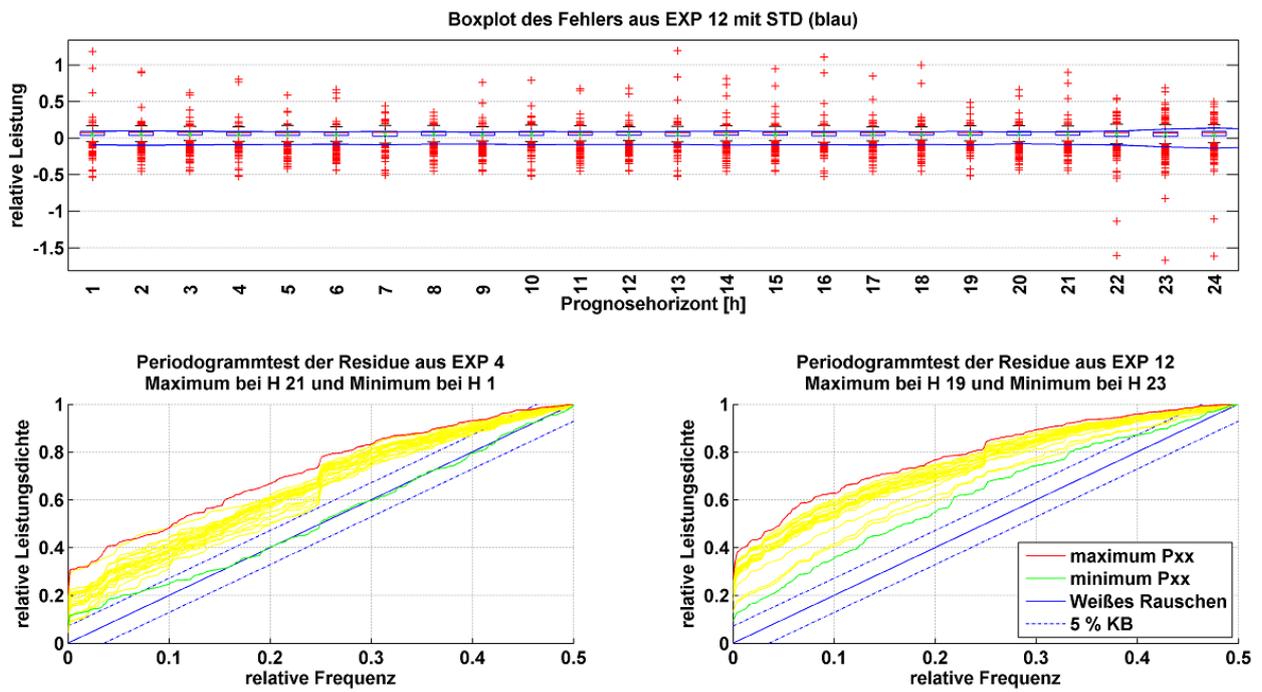


Abbildung C.5: Validierung EXP 12 im Vergleich zu EXP 4

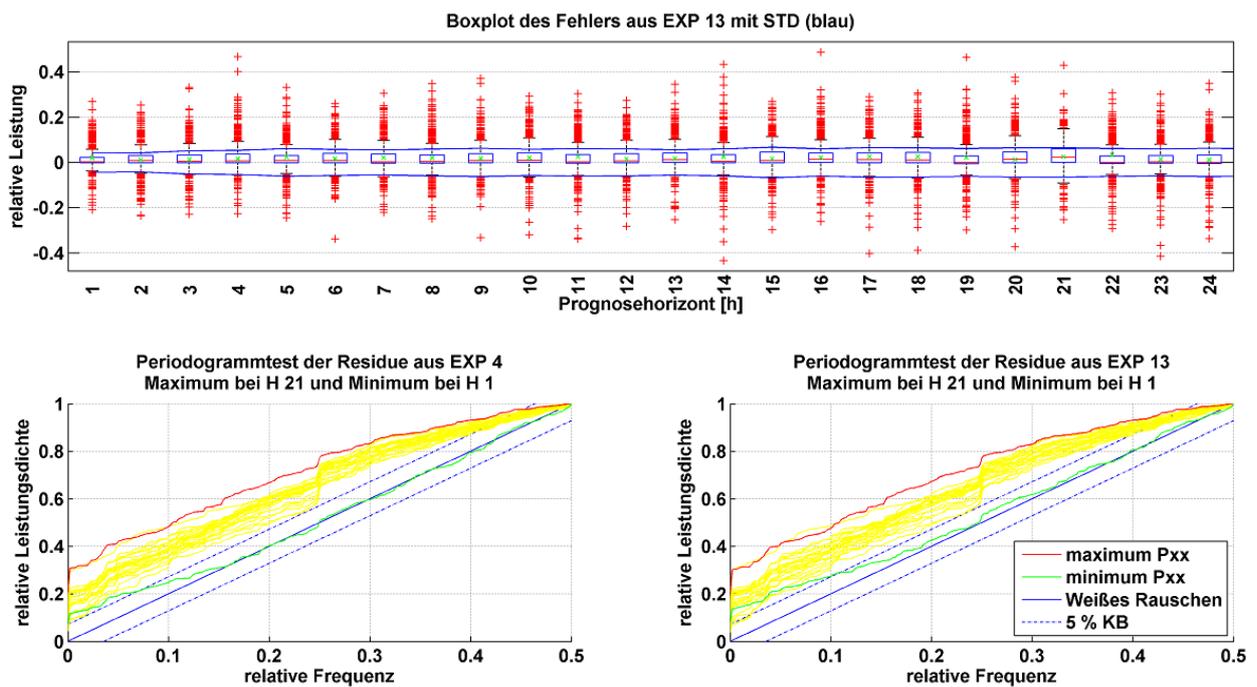


Abbildung C.6: Validierung EXP 13 im Vergleich zu EXP 4

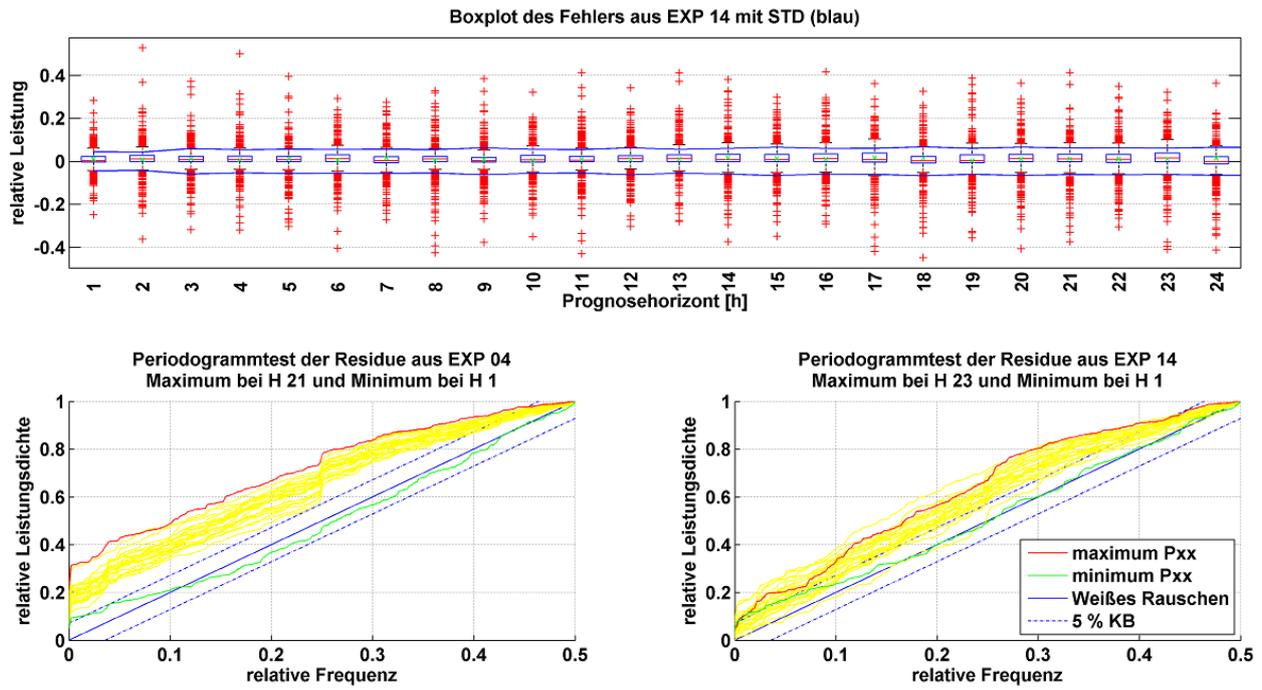


Abbildung C.7: Validierung EXP 14 im Vergleich zu EXP 4

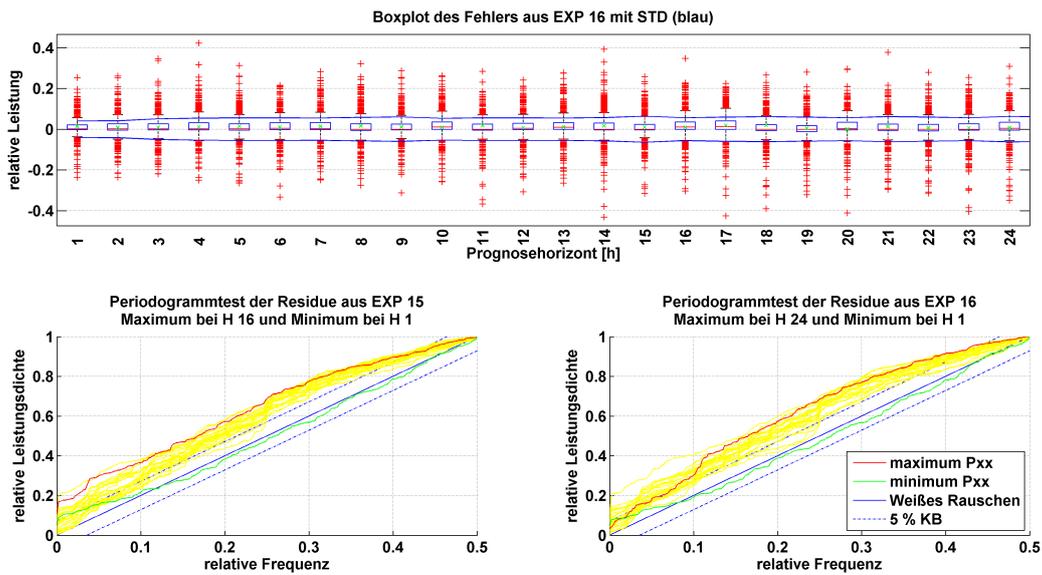


Abbildung C.8: Validierung EXP 16 im Vergleich zu EXP 15

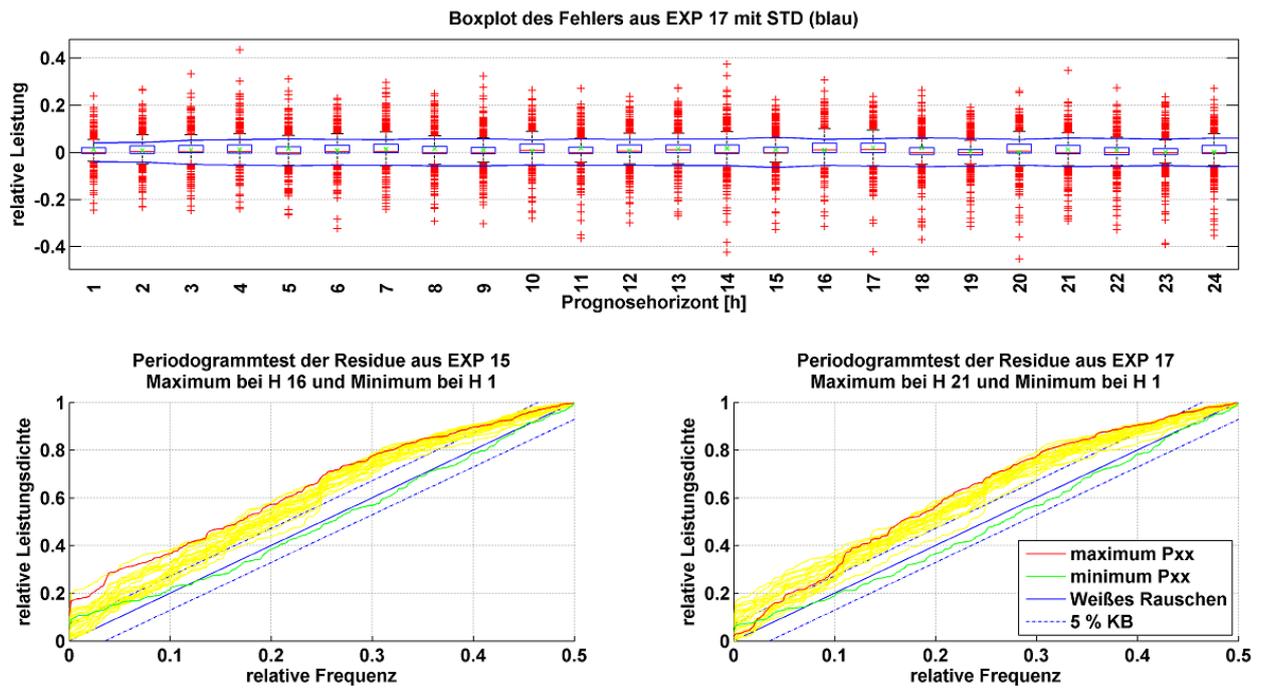


Abbildung C.9: Validierung EXP 17 im Vergleich zu EXP 15

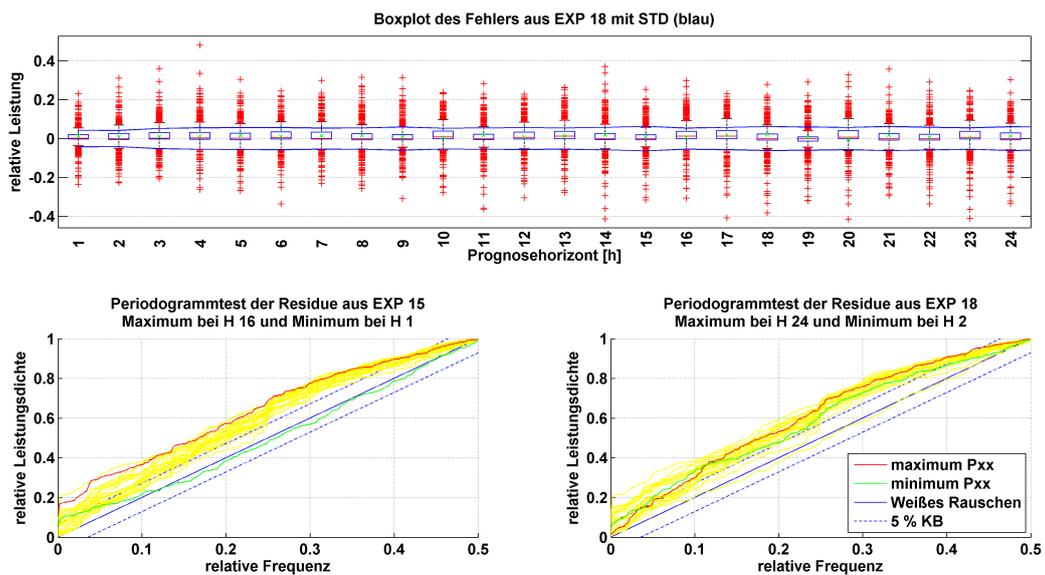


Abbildung C.10: Validierung EXP 18 im Vergleich zu EXP 15

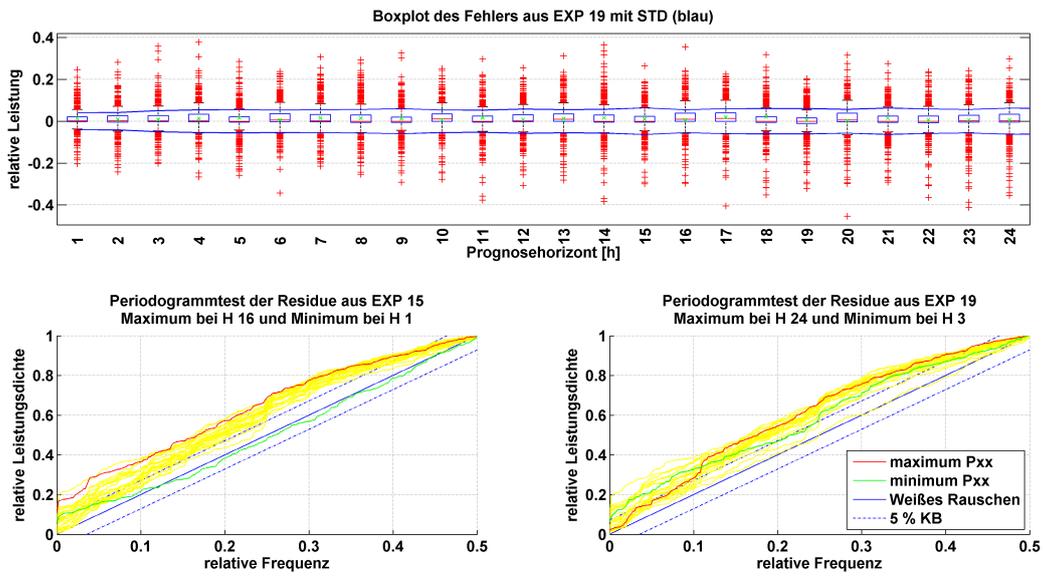


Abbildung C.11: Validierung EXP 19 im Vergleich zu EXP 15

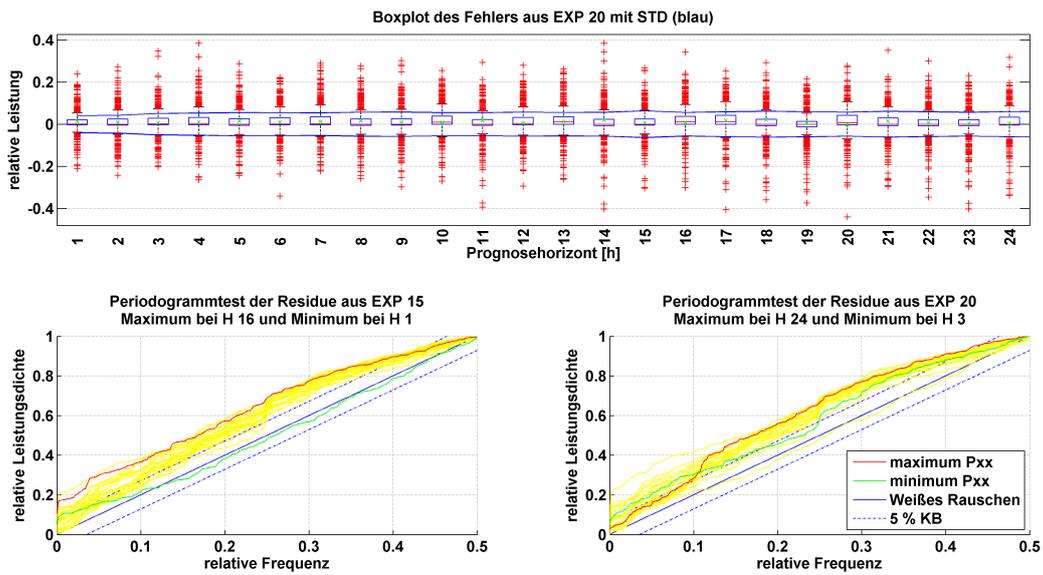


Abbildung C.12: Validierung EXP 20 im Vergleich zu EXP 15

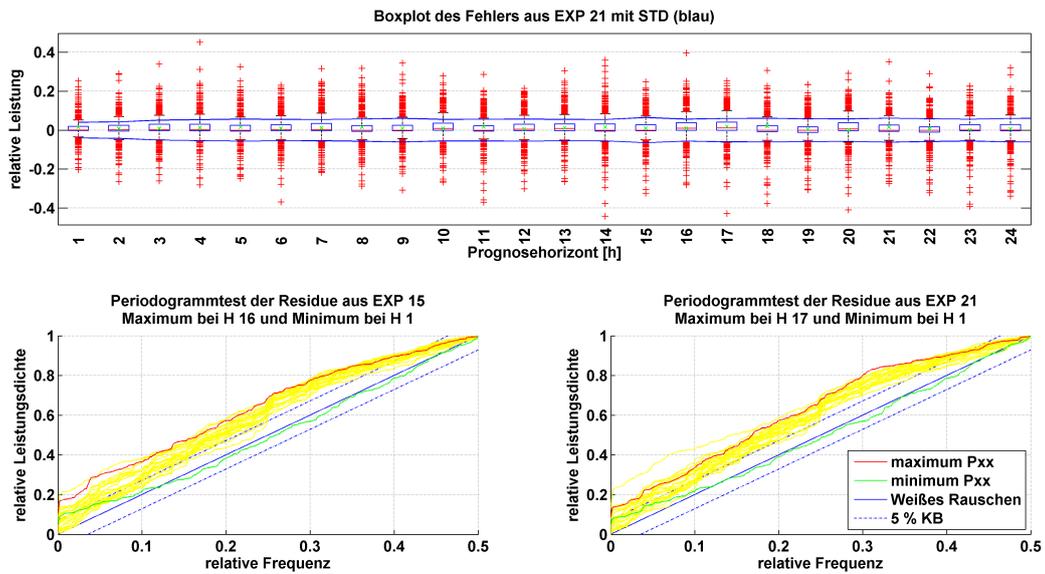


Abbildung C.13: Validierung EXP 21 im Vergleich zu EXP 15

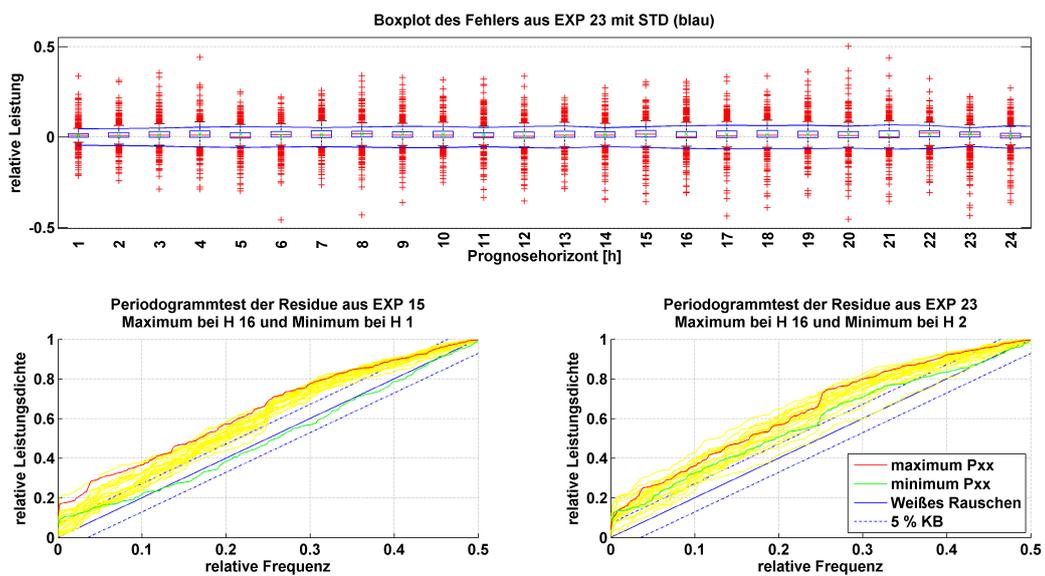


Abbildung C.14: Validierung EXP 23 im Vergleich zu EXP 15

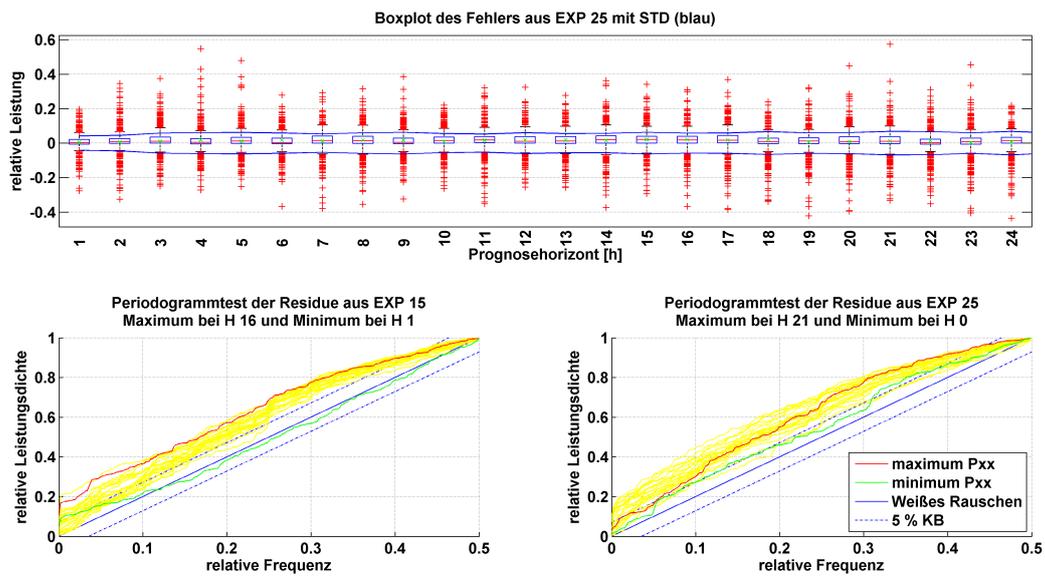


Abbildung C.15: Validierung EXP 25 im Vergleich zu EXP 15

D Auswertungsgrafiken der Ergebnisse

D.1 Windpark 2

Nachfolgend sind alle vollständigen Auswertef Grafiken für den WP 2 in den Abbildungen D.16 bis D.21 eingefügt.

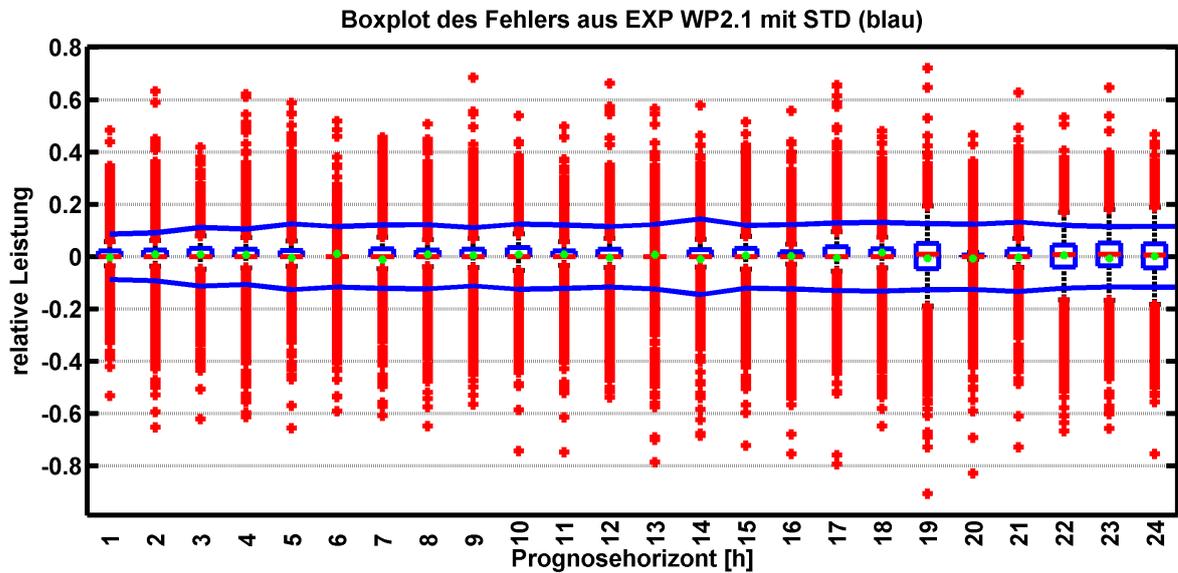


Abbildung D.16: Boxplot zu EXP WP 2.1

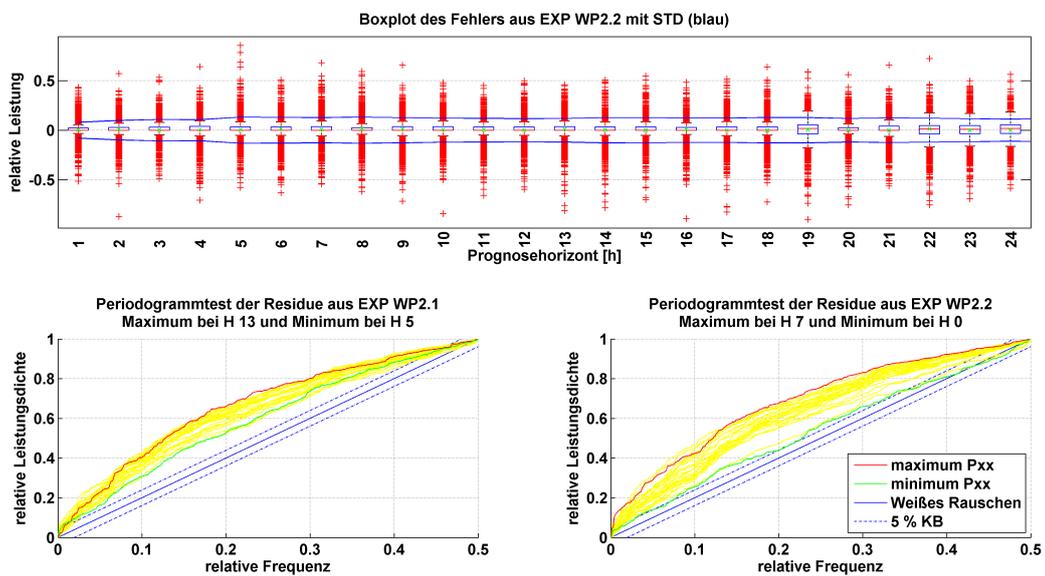


Abbildung D.17: Validierung EXP WP 2.2 im Vergleich zu EXP WP 2.1

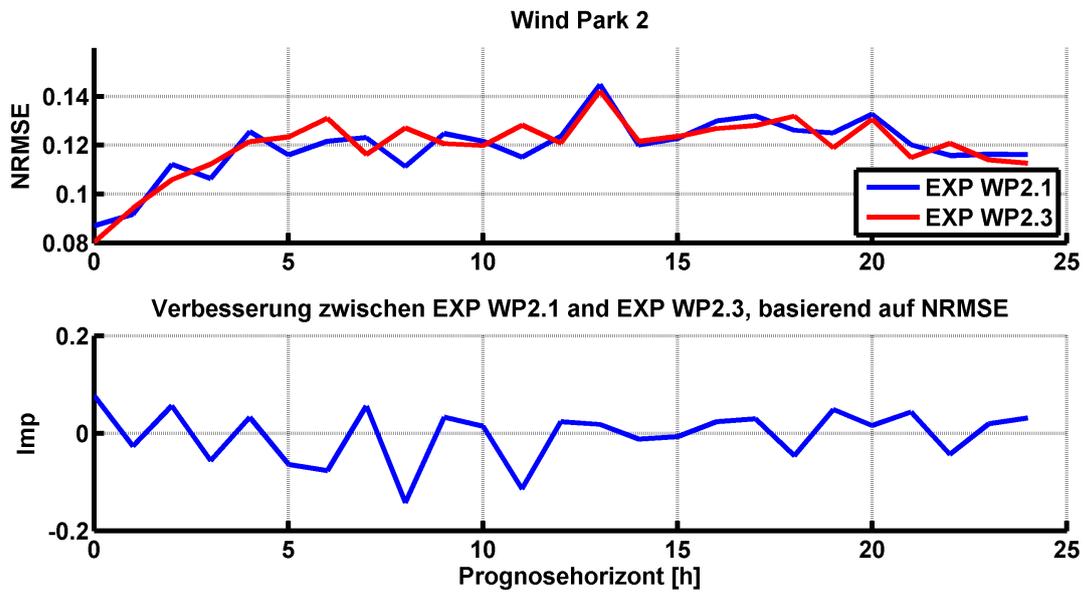


Abbildung D.18: Vergleich Fehlerauswertung EXP WP 2.3 mit EXP WP 2.1

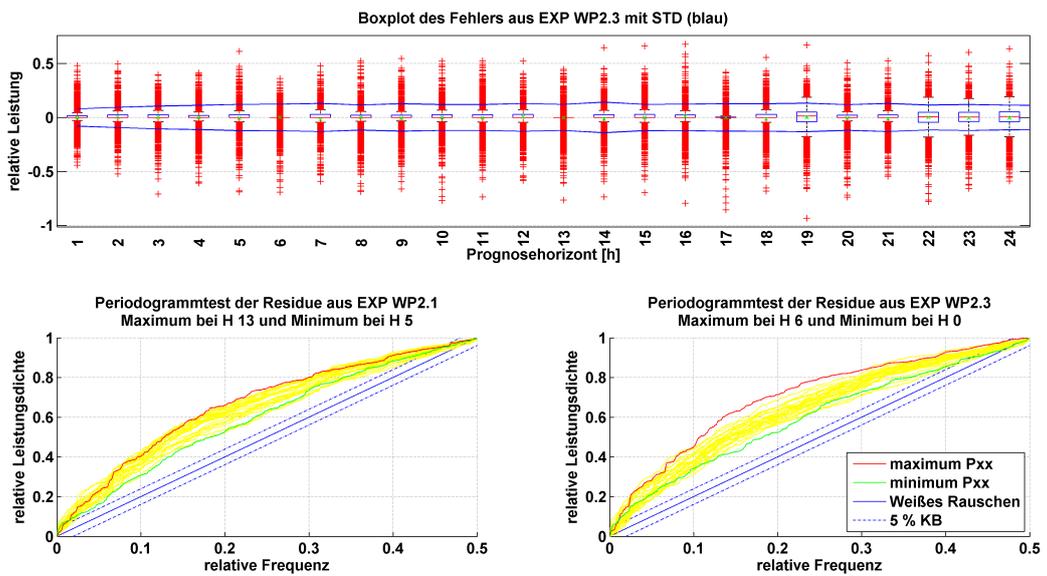


Abbildung D.19: Validierung EXP WP 2.3 im Vergleich zu EXP WP 2.1

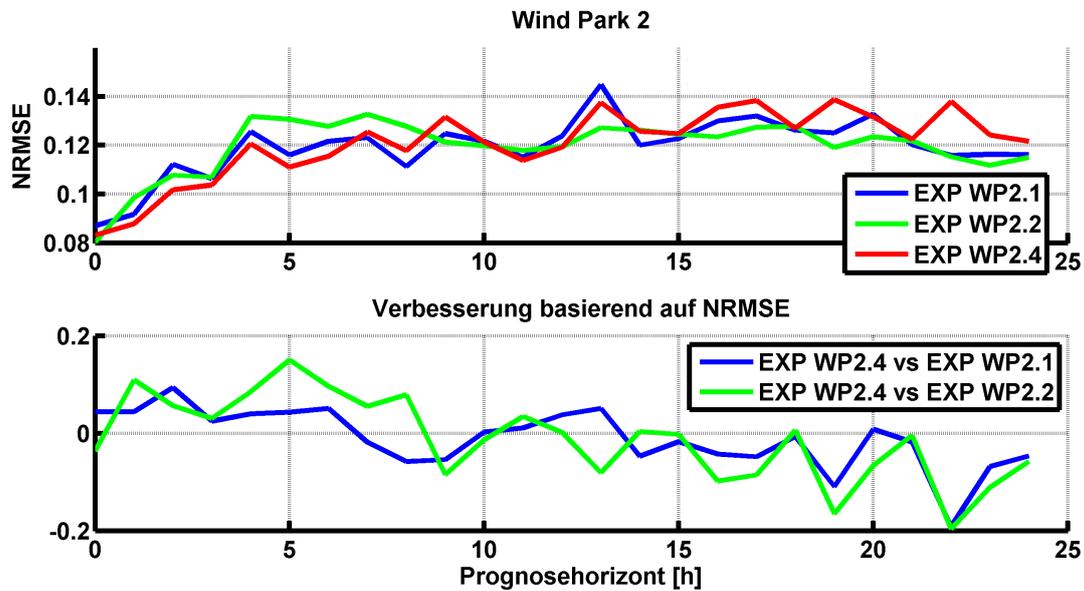


Abbildung D.20: Vergleich Fehlerauswertung EXP WP 2.4 mit EXP WP 2.1 und WP 2.2

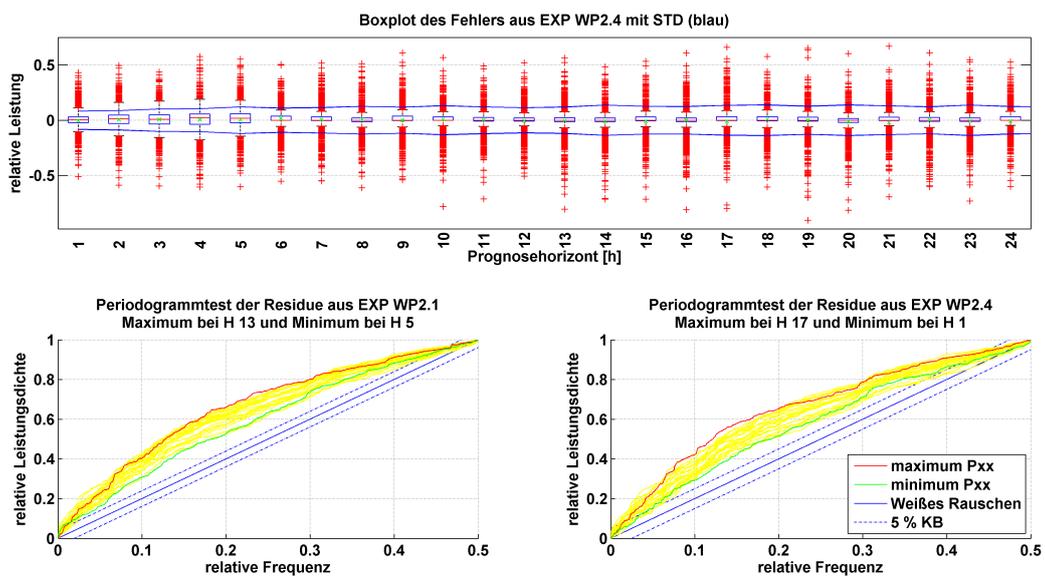


Abbildung D.21: Validierung EXP WP 2.4 mit EXP WP 2.1

D.2 Windpark 3

Nachfolgend sind alle vollständigen Auswertegrafiken für den WP 3 in den Abbildungen D.22 bis D.27 eingefügt.

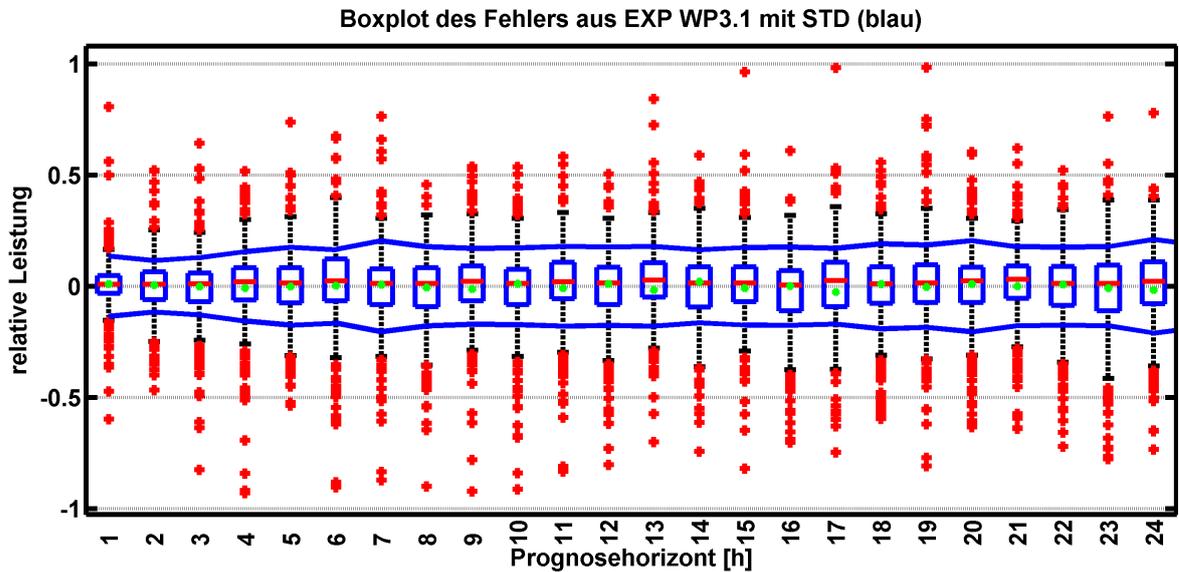


Abbildung D.22: Boxplot zu EXP WP 3.1

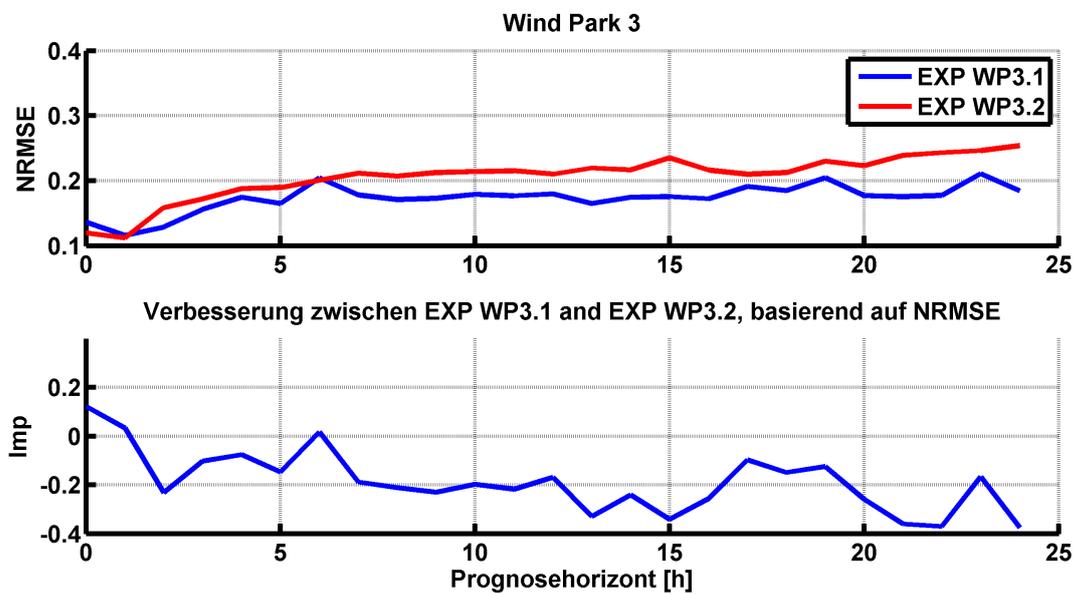


Abbildung D.23: Vergleich Fehlerauswertung EXP WP 3.2 mit EXP WP 3.1

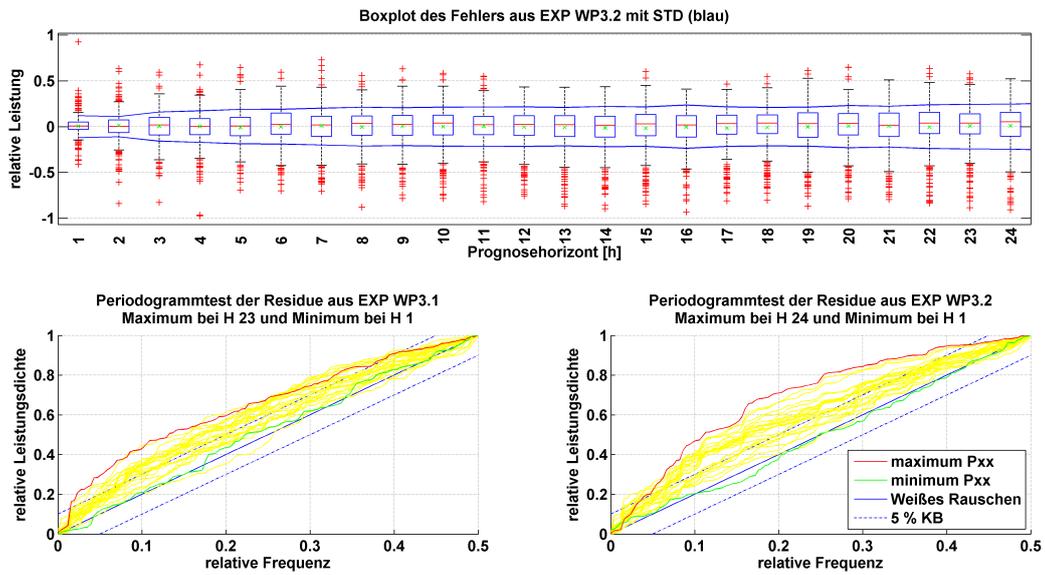


Abbildung D.24: Validierung EXP WP 3.2 im Vergleich zu EXP WP 3.1

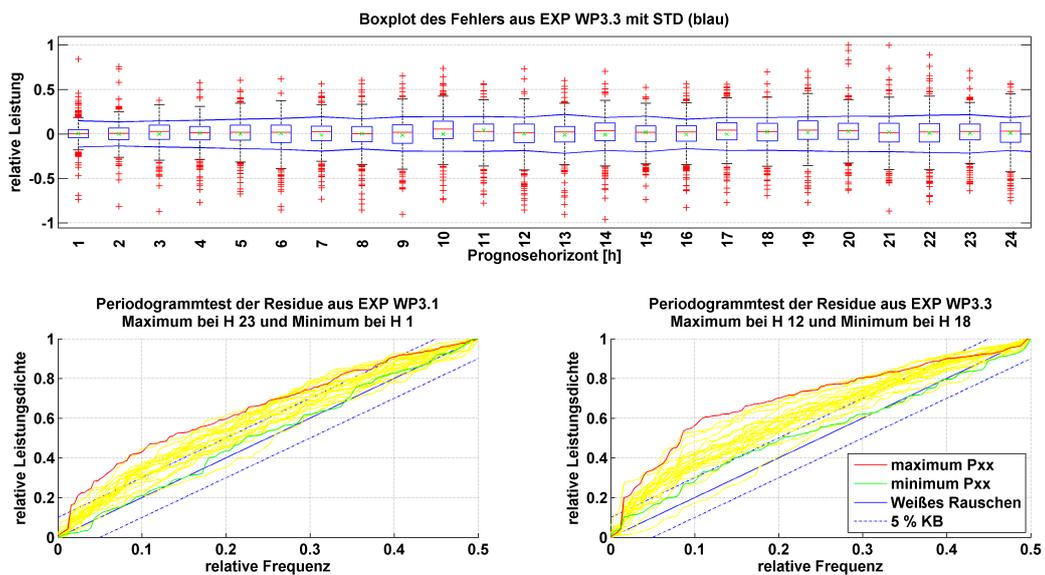


Abbildung D.25: Validierung EXP WP 3.3 im Vergleich zu EXP WP 3.1

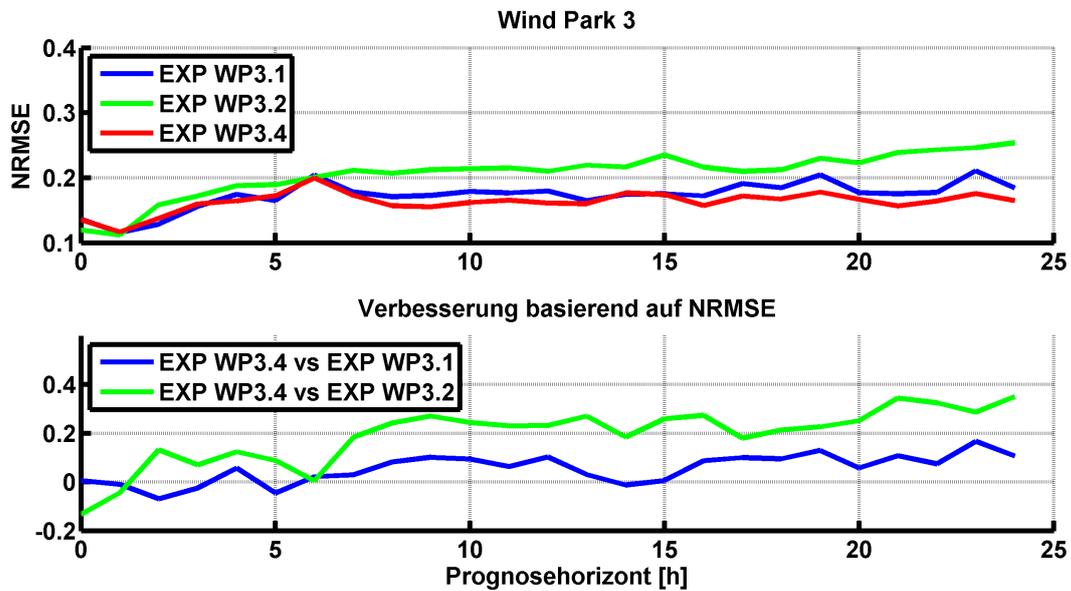


Abbildung D.26: Vergleich Fehlerauswertung EXP WP 3.4 mit EXP WP 3.1 und WP 3.2

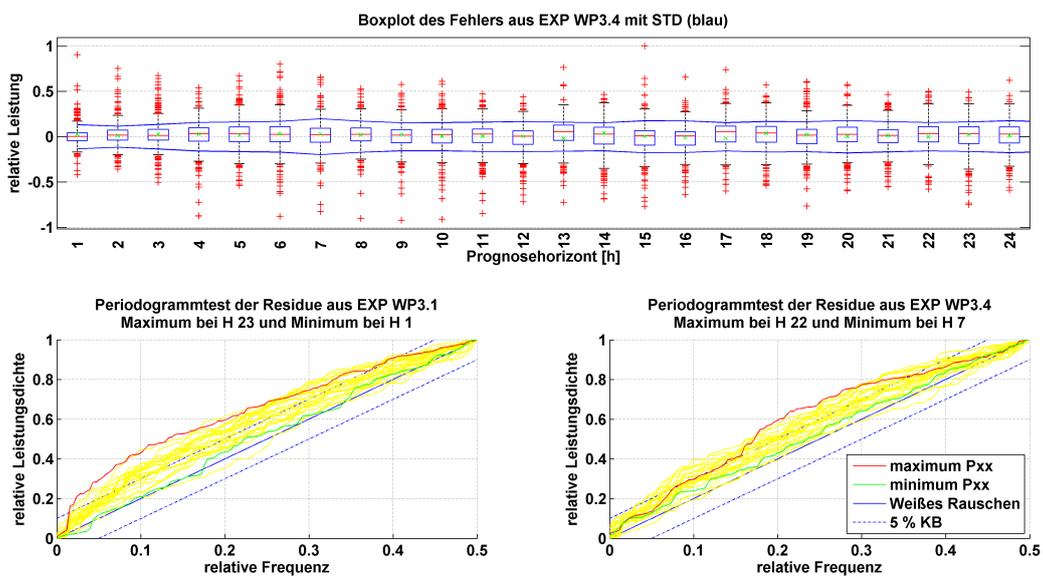


Abbildung D.27: Validierung EXP WP 3.4 mit EXP WP 3.1

D.3 Windpark 4

Nachfolgend sind alle vollständigen Auswertefrafiken für den WP 4 in den Abbildungen D.28 bis D.33 eingefügt.

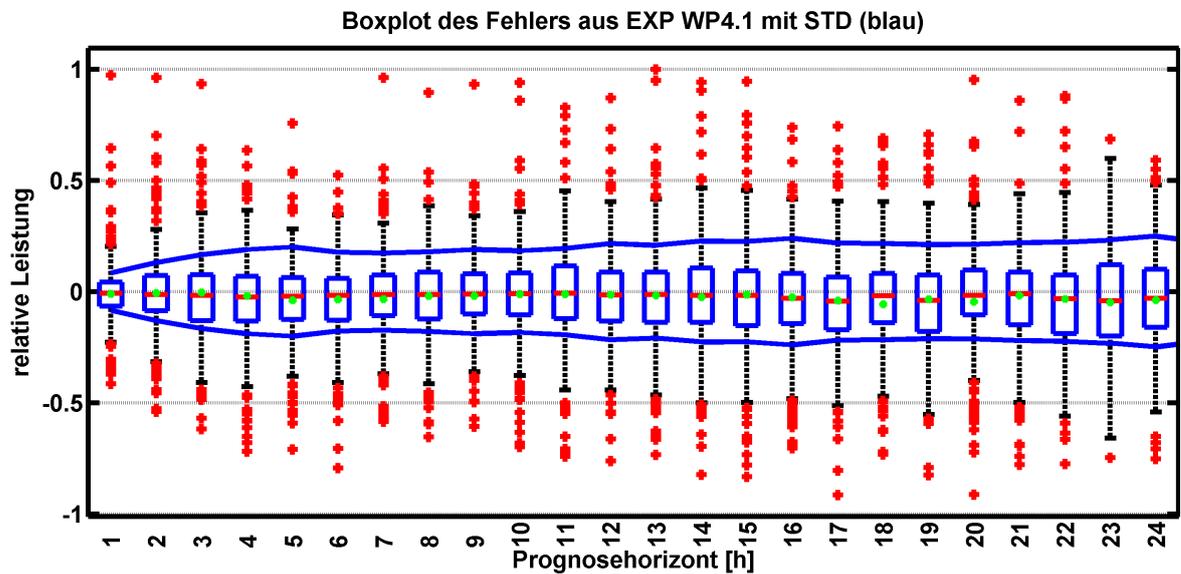


Abbildung D.28: Boxplot zu EXP WP 4.1

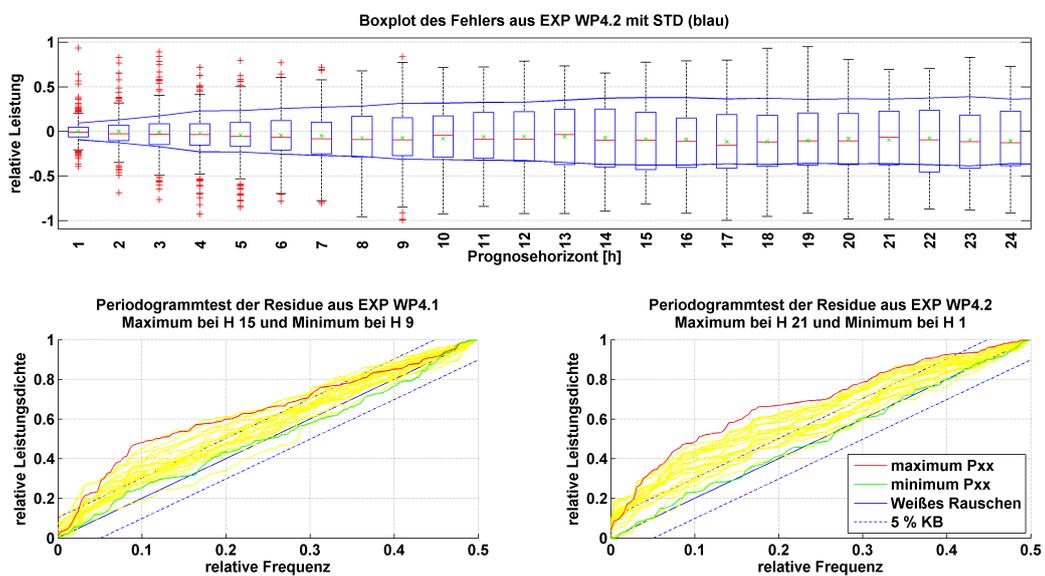


Abbildung D.29: Validierung EXP WP 4.2 im Vergleich zu EXP WP 4.1

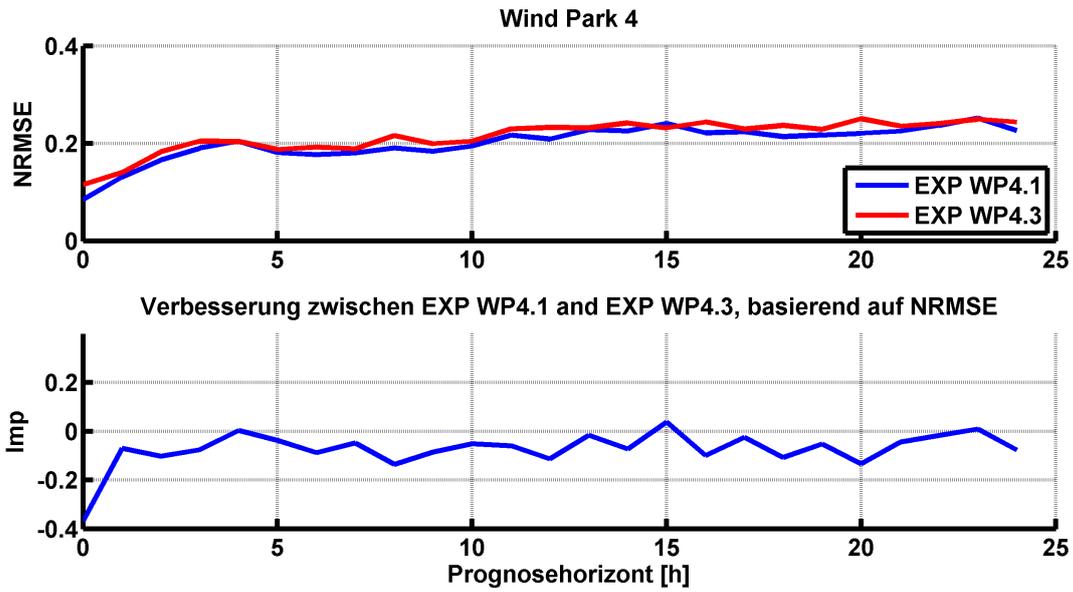


Abbildung D.30: Vergleich Fehlerauswertung EXP WP 4.3 mit EXP WP 4.1

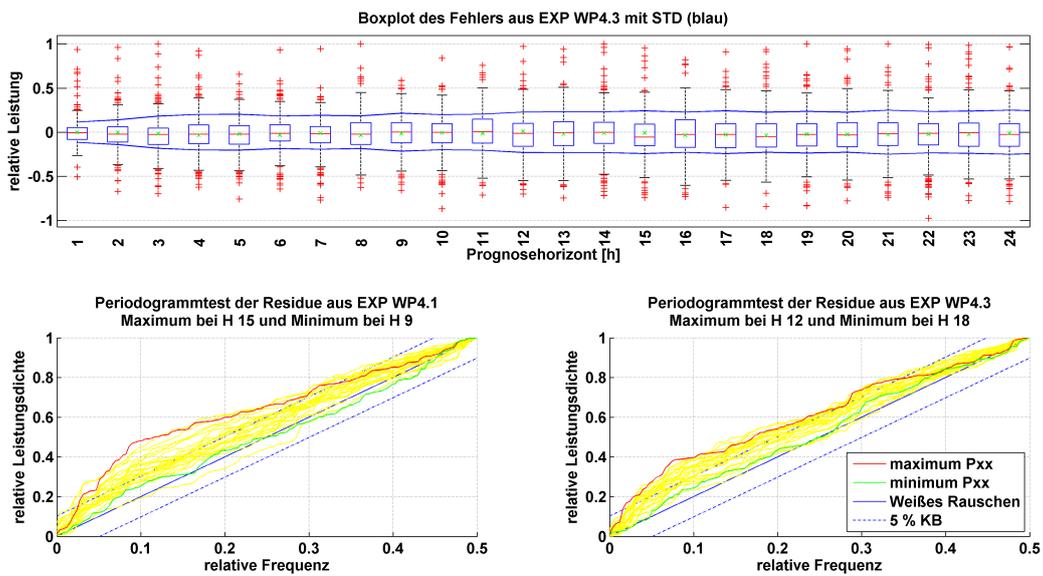


Abbildung D.31: Validierung EXP WP 4.3 im Vergleich zu EXP WP 4.1

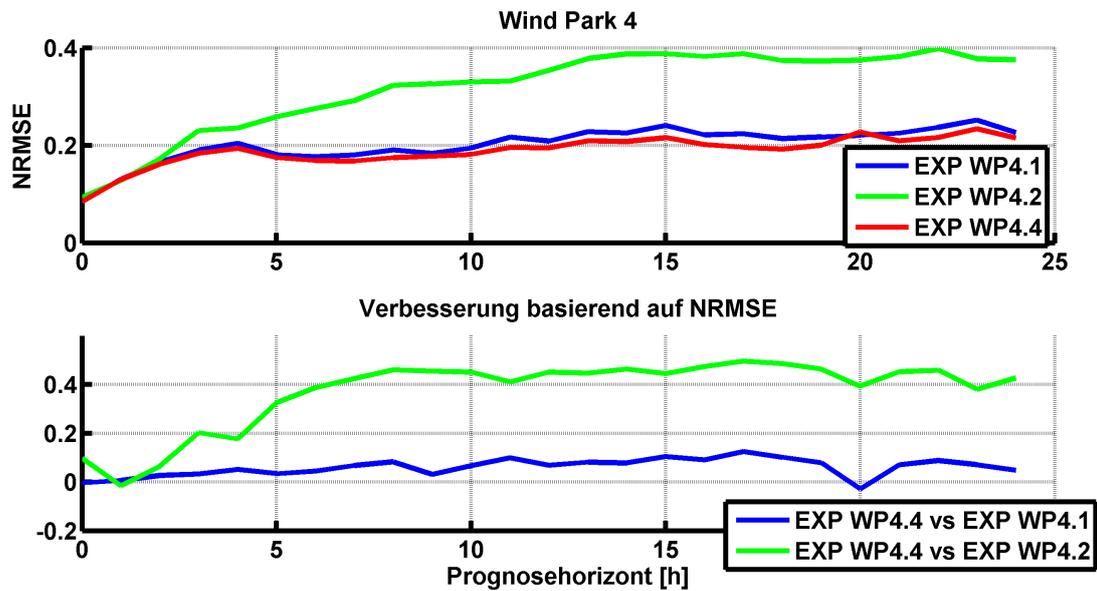


Abbildung D.32: Vergleich Fehlerauswertung EXP WP 4.4 mit EXP WP 4.1 und WP 4.2

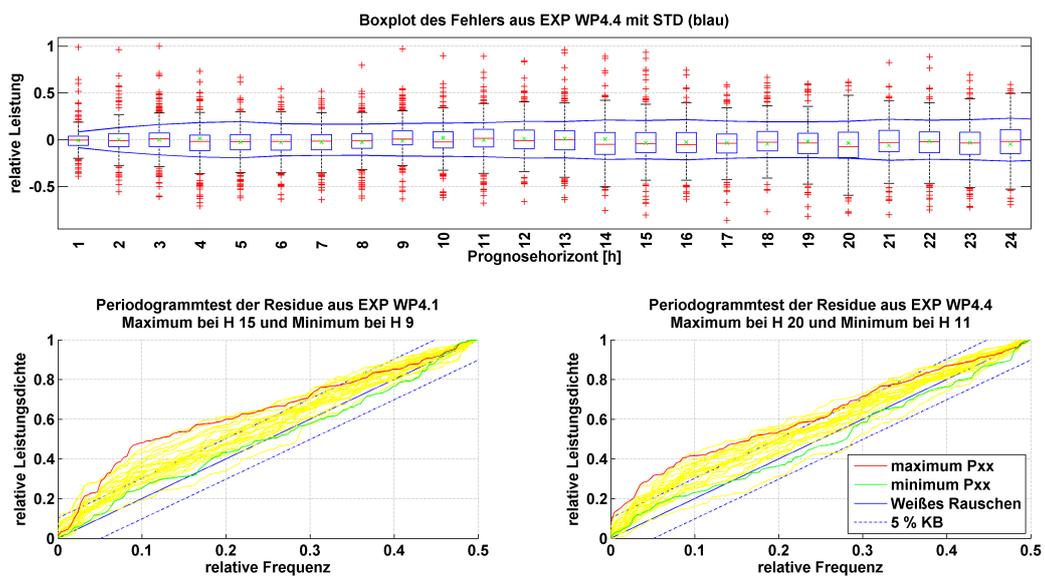


Abbildung D.33: Validierung EXP WP 4.4 mit EXP WP 4.1

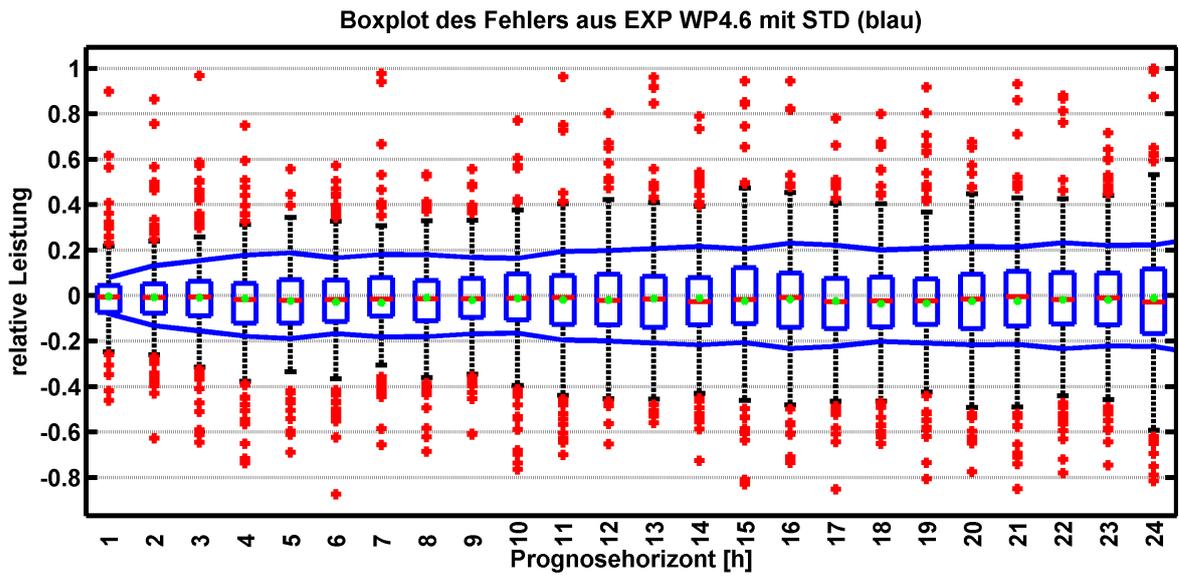


Abbildung D.34: Boxplot zu EXP WP 4.6

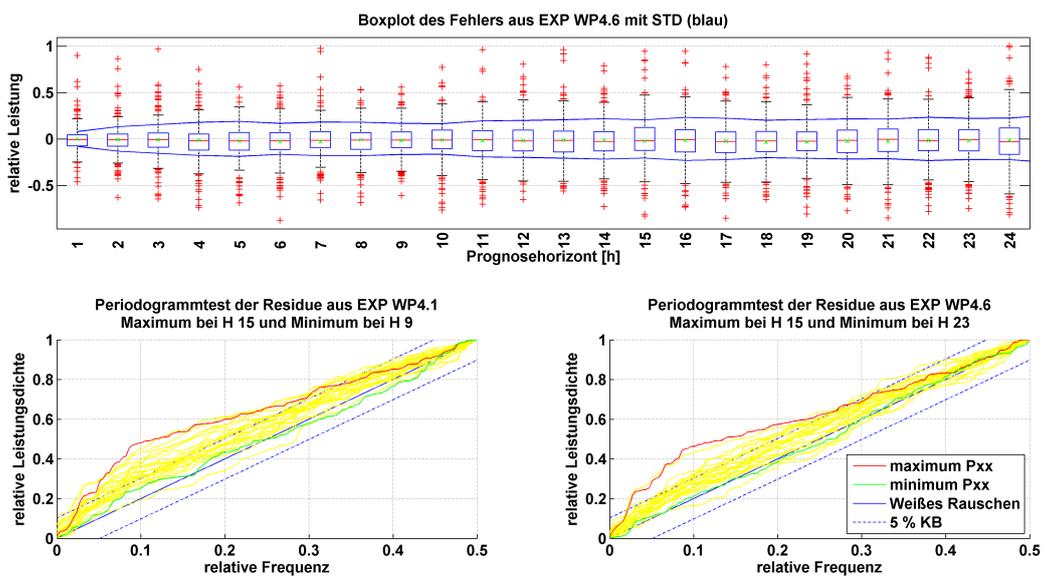


Abbildung D.35: Validierung EXP WP 4.6 im Vergleich zu EXP WP 4.1

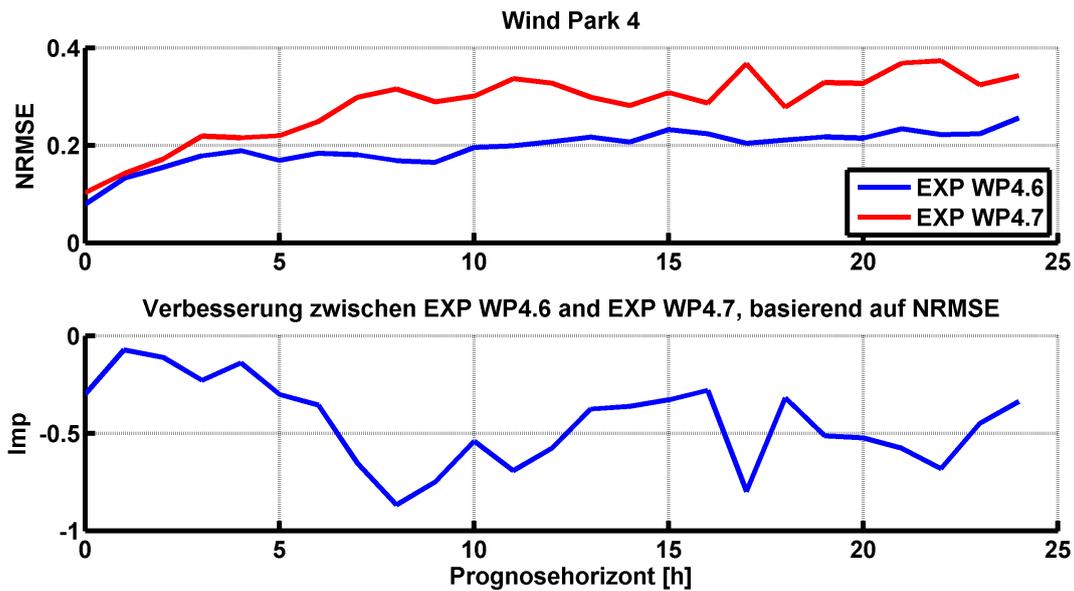


Abbildung D.36: Vergleich Fehlerauswertung EXP WP 4.7 mit EXP WP 4.6

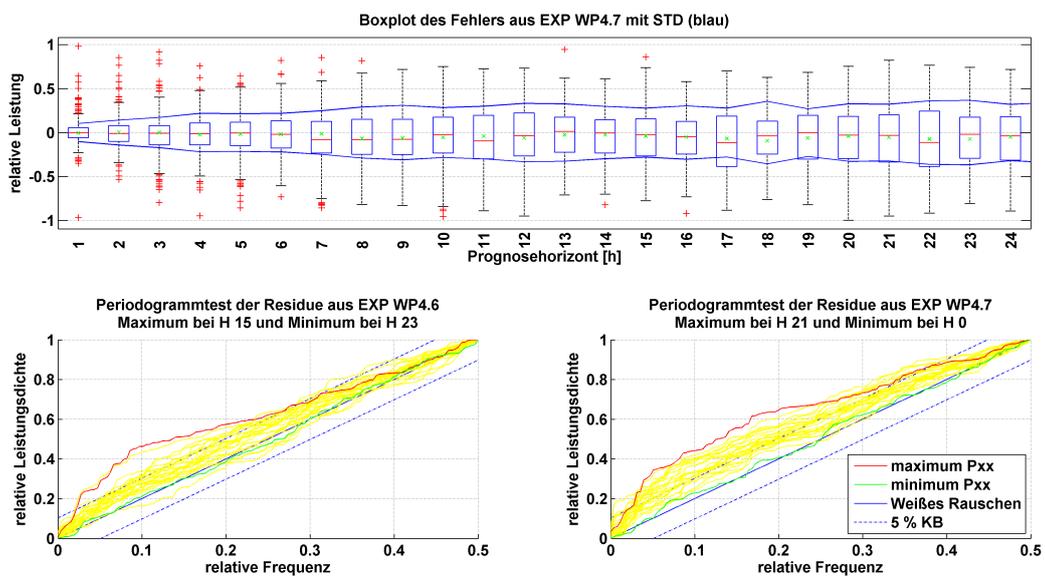


Abbildung D.37: Validierung EXP WP 4.7 im Vergleich zu EXP WP 4.6

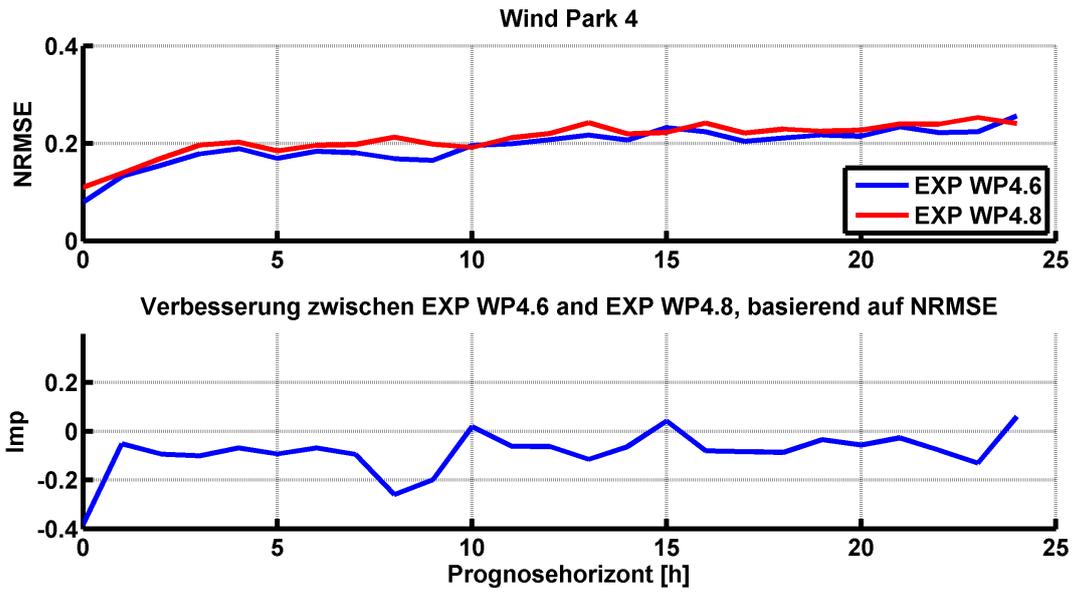


Abbildung D.38: Vergleich Fehlerauswertung EXP WP 4.8 mit EXP WP 4.6

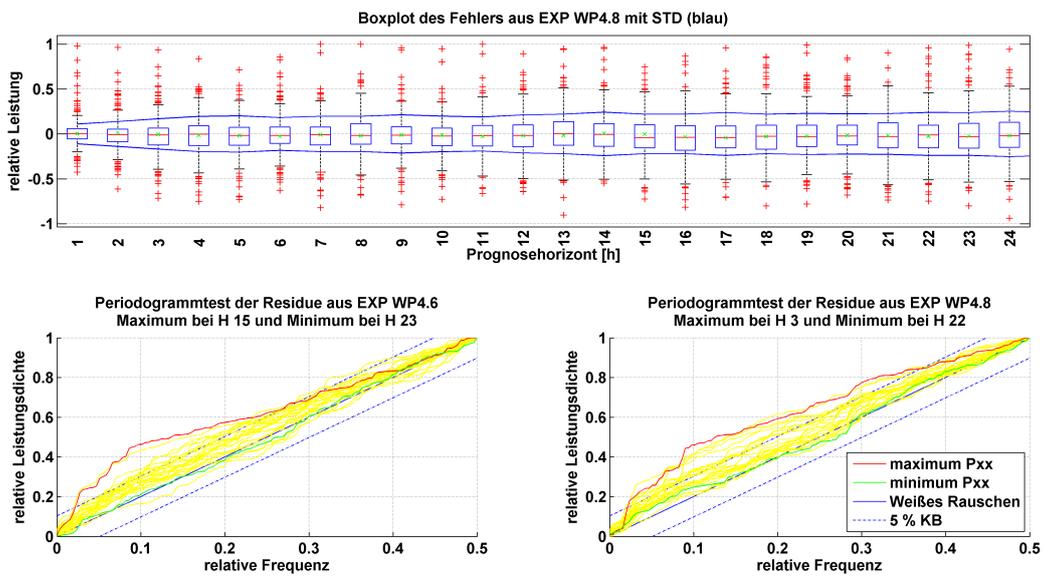


Abbildung D.39: Validierung EXP WP 4.8 im Vergleich zu EXP WP 4.6

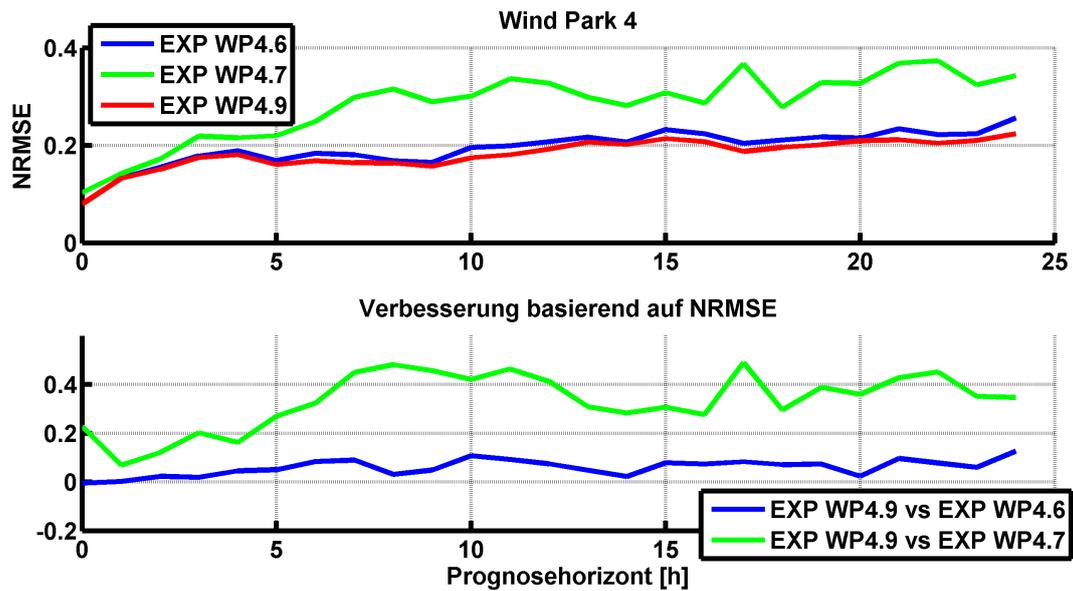


Abbildung D.40: Vergleich Fehlerauswertung EXP WP 4.9 mit EXP WP 4.6 und WP 4.7

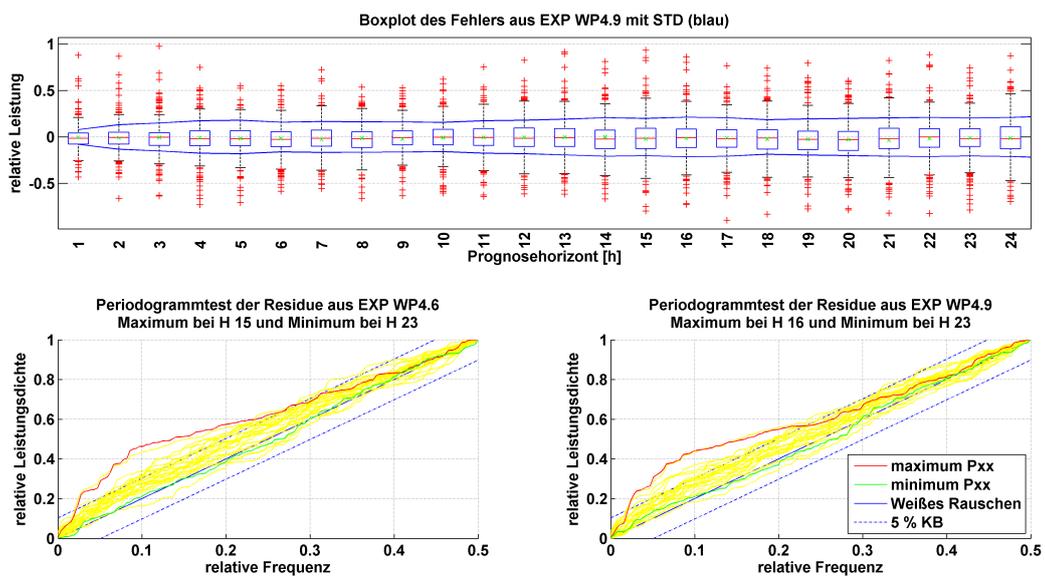


Abbildung D.41: Validierung EXP WP 4.9 mit EXP WP 4.6

D.4 Übertragbarkeit

Nachfolgend sind alle vollständigen Auswertegrافiken für die stationären und nachgeführten PV-Anlagen in den Abbildungen D.42 bis D.65eingefügt.

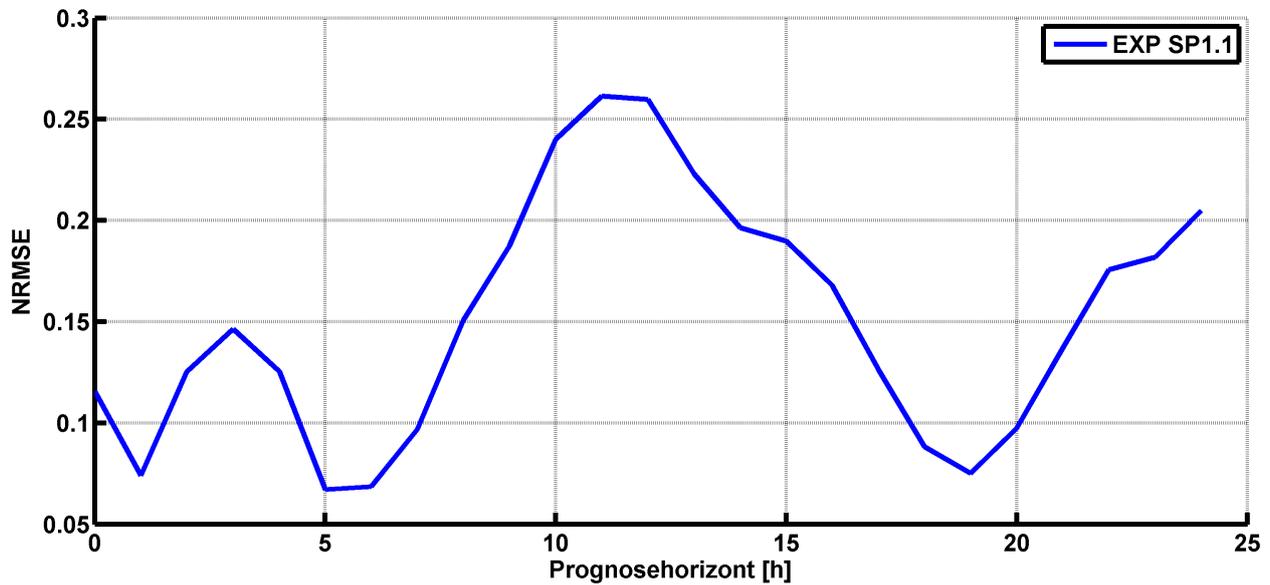


Abbildung D.42: NRMSE des EXP SP 1.1

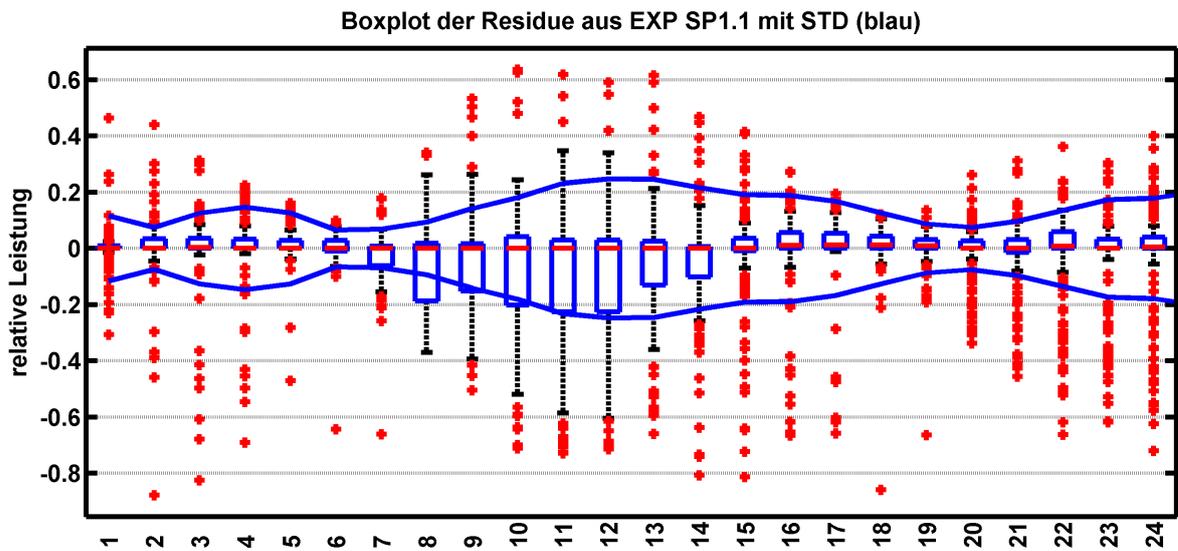


Abbildung D.43: Boxplot der Residuen des EXP SP 1.1

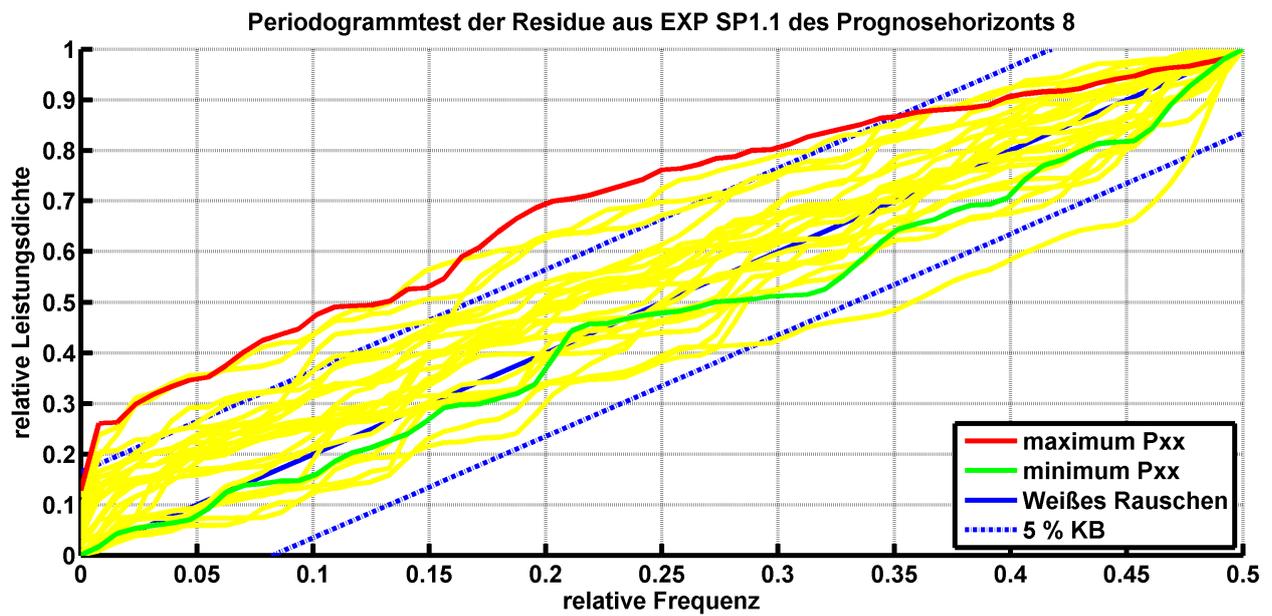


Abbildung D.44: Periodogrammtest des EXP SP 1.1

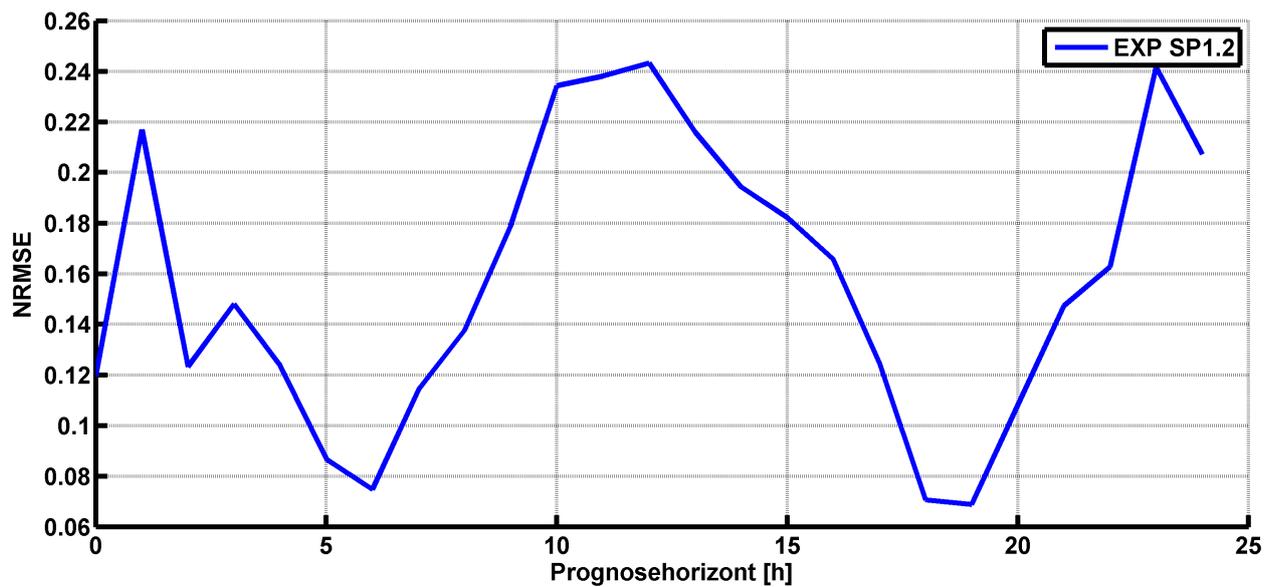


Abbildung D.45: NRMSE des EXP SP 1.2

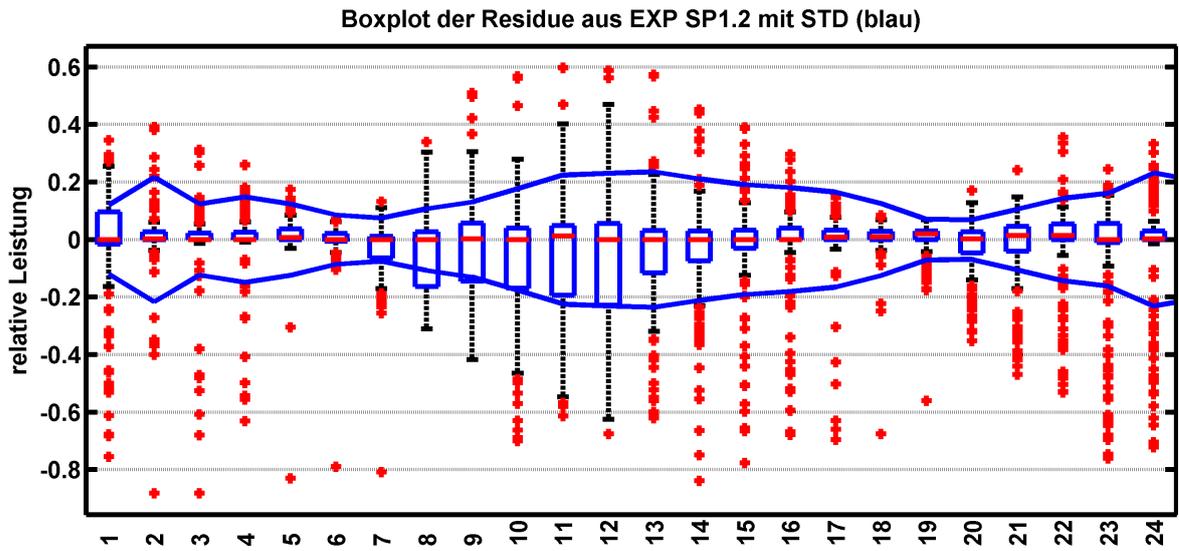


Abbildung D.46: Boxplot der Residuen des EXP SP 1.2

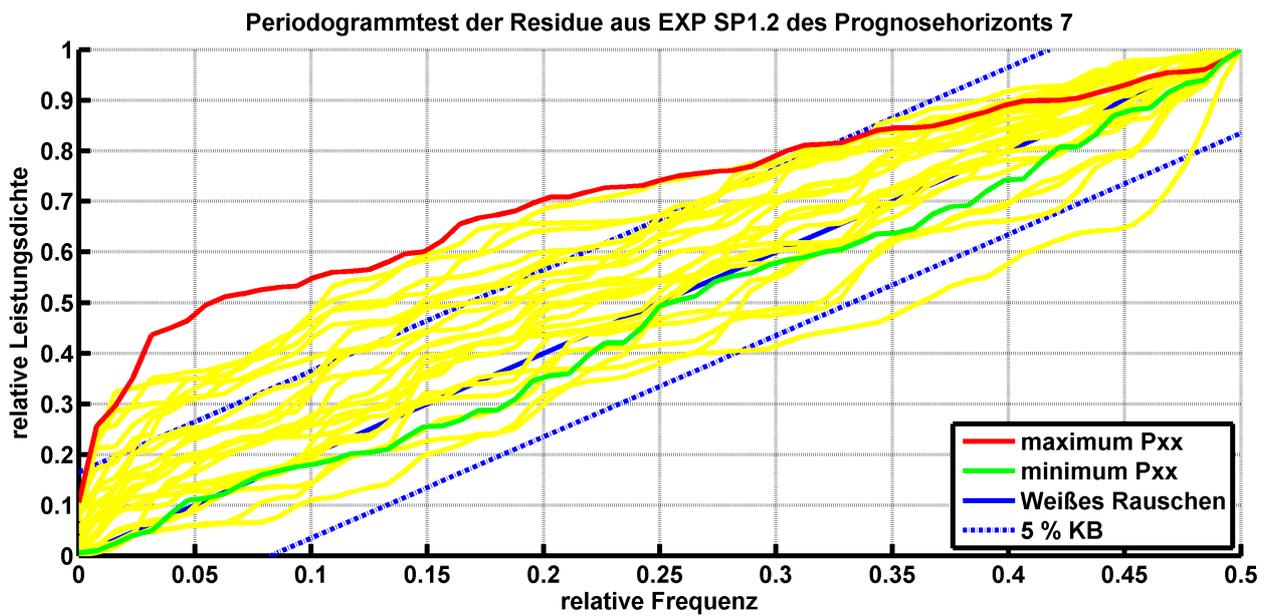


Abbildung D.47: Periodogrammtest des EXP SP 1.2

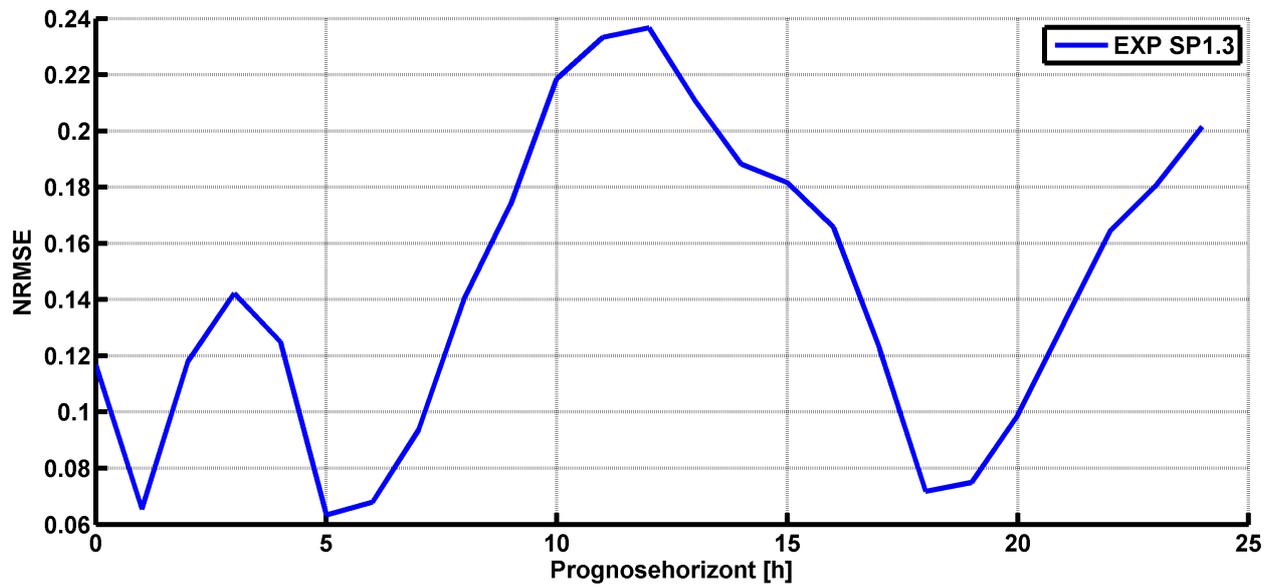


Abbildung D.48: NRMSE des EXP SP 1.3

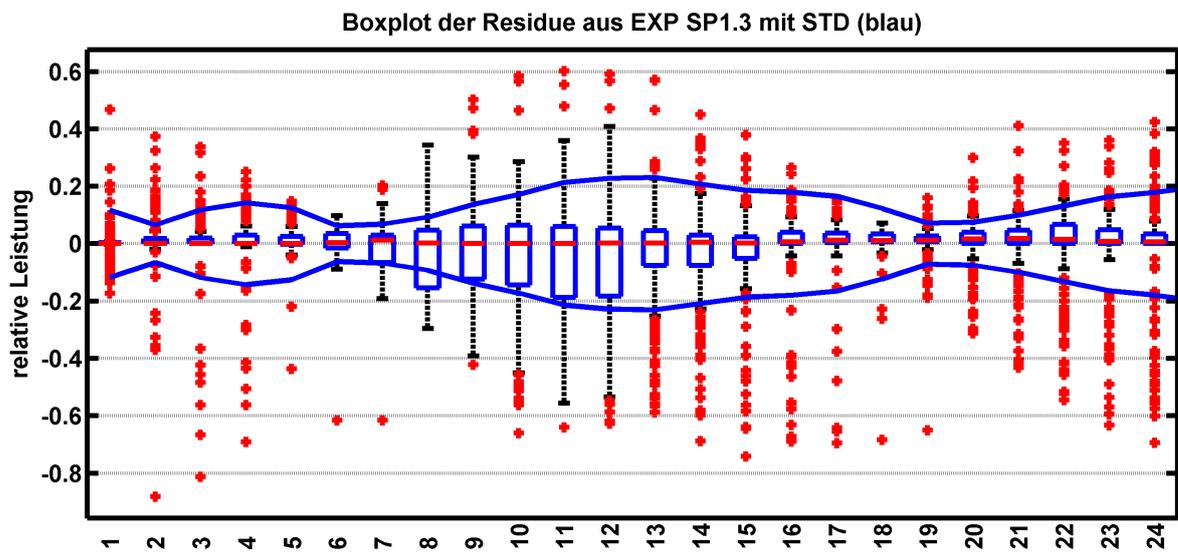


Abbildung D.49: Boxplot der Residuen des EXP SP 1.3

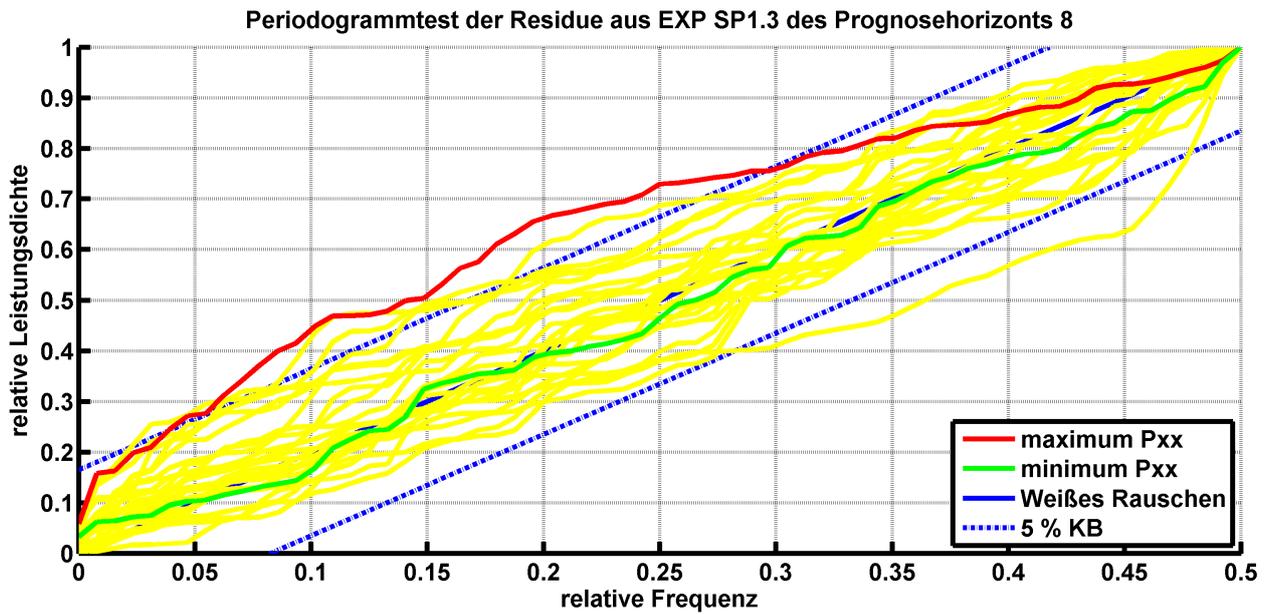


Abbildung D.50: Periodogrammtest des EXP SP 1.3

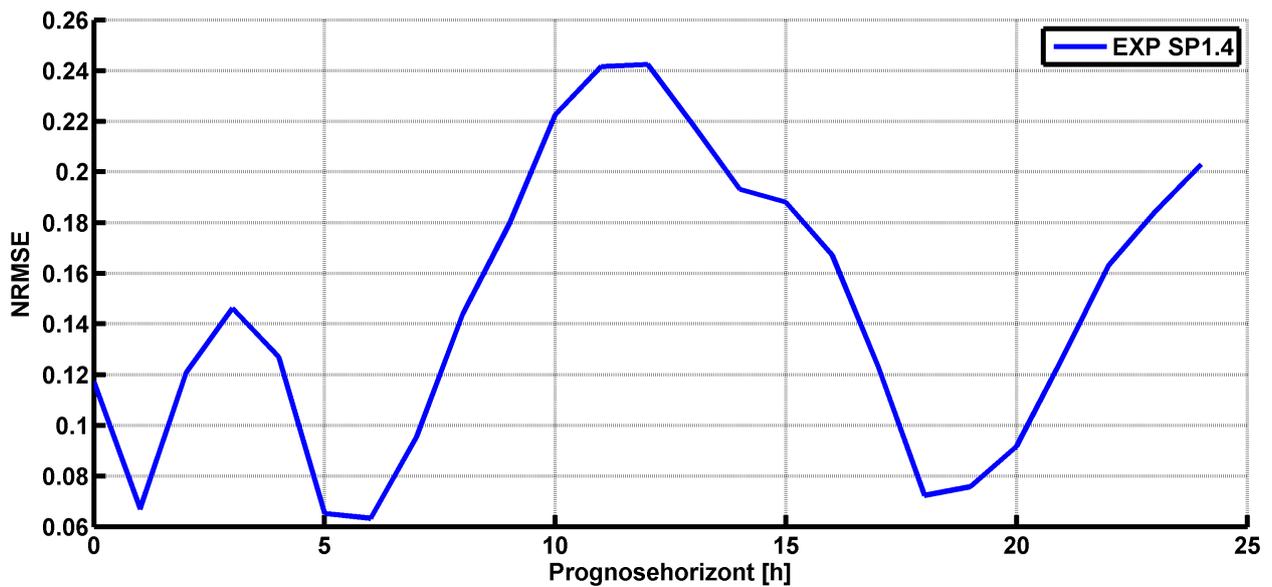


Abbildung D.51: NRMSE des EXP SP 1.4

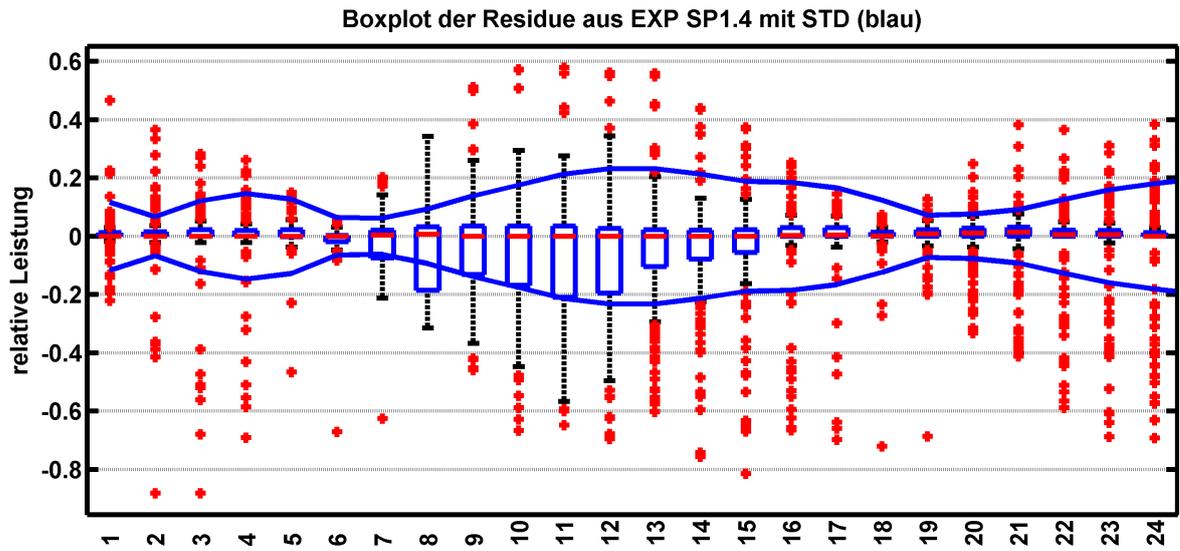


Abbildung D.52: Boxplot der Residuen des EXP SP 1.4

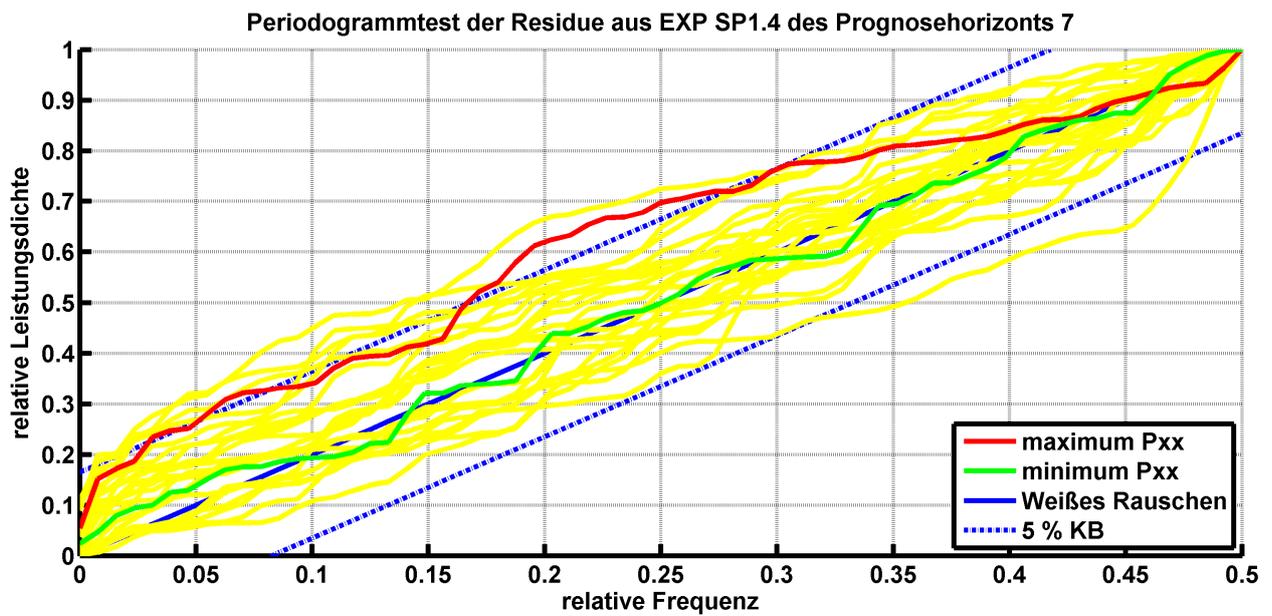


Abbildung D.53: Periodogrammtest des EXP SP 1.4

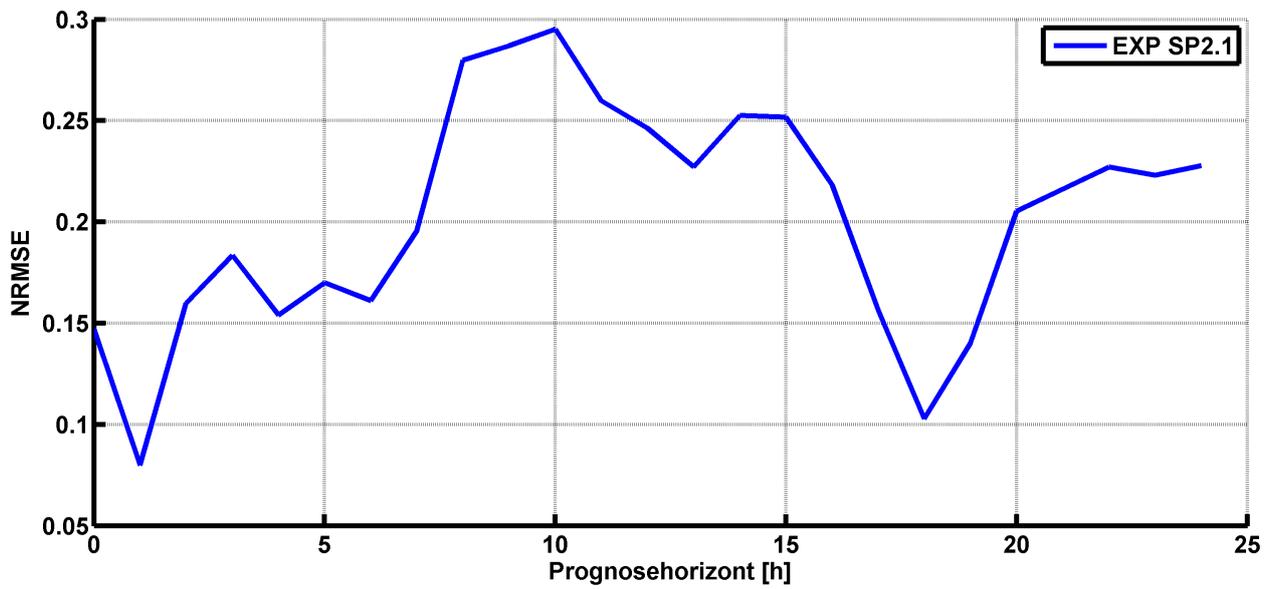


Abbildung D.54: NRMSE des EXP SP 2.1

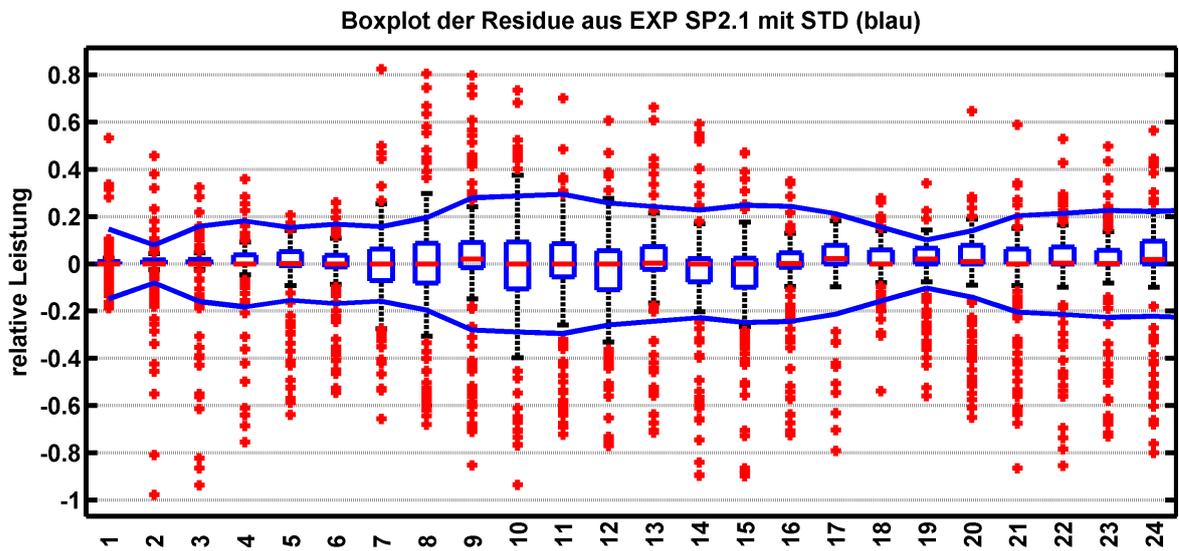


Abbildung D.55: Boxplot der Residuen des EXP SP 2.1

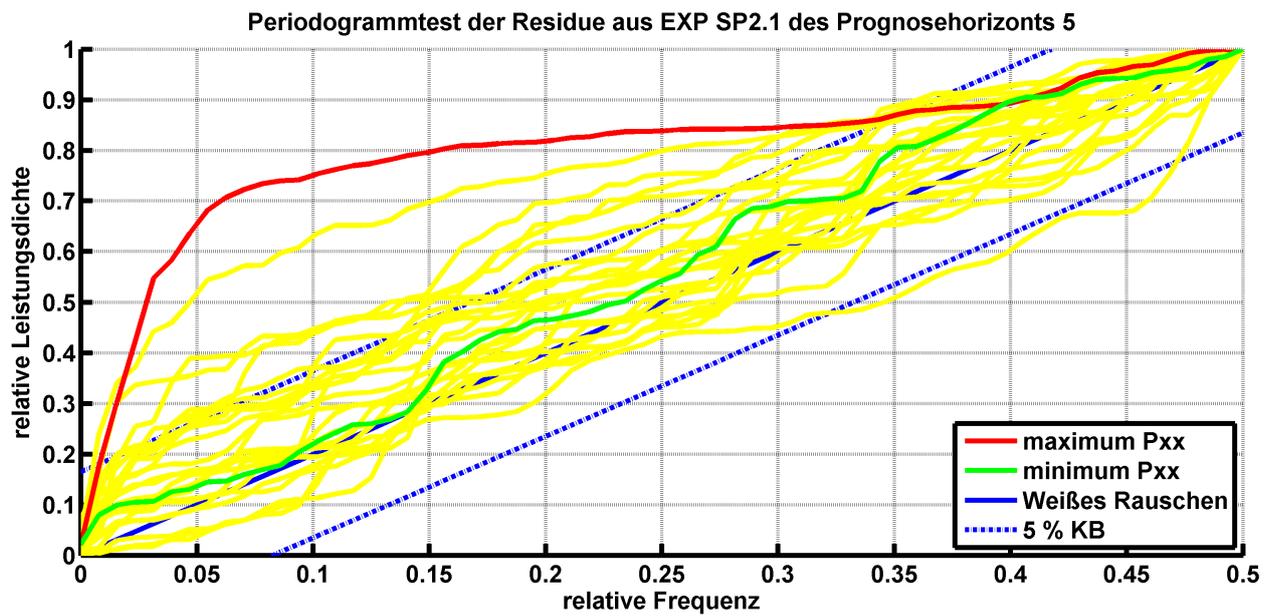


Abbildung D.56: Periodogrammtest des EXP SP 2.1

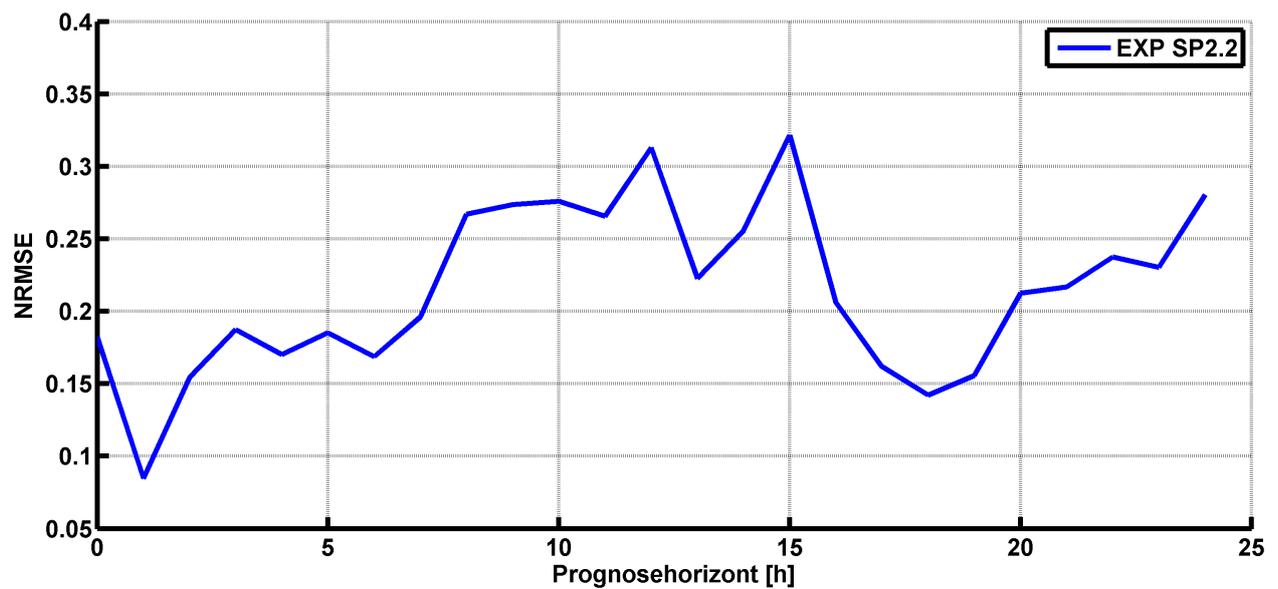


Abbildung D.57: NRMSE des EXP SP 2.2

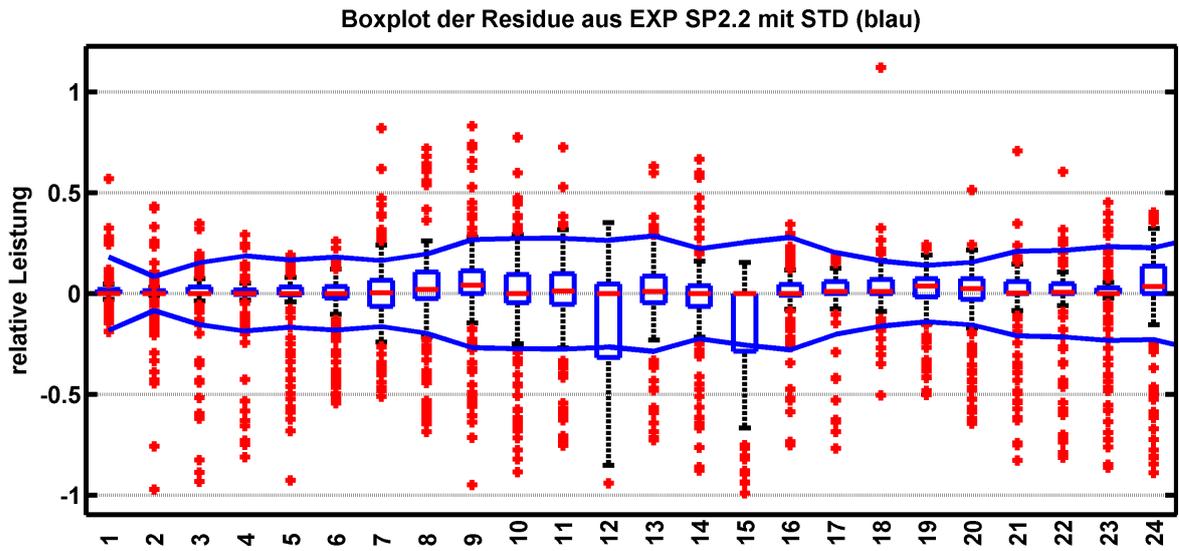


Abbildung D.58: Boxplot der Residuen des EXP SP 2.2

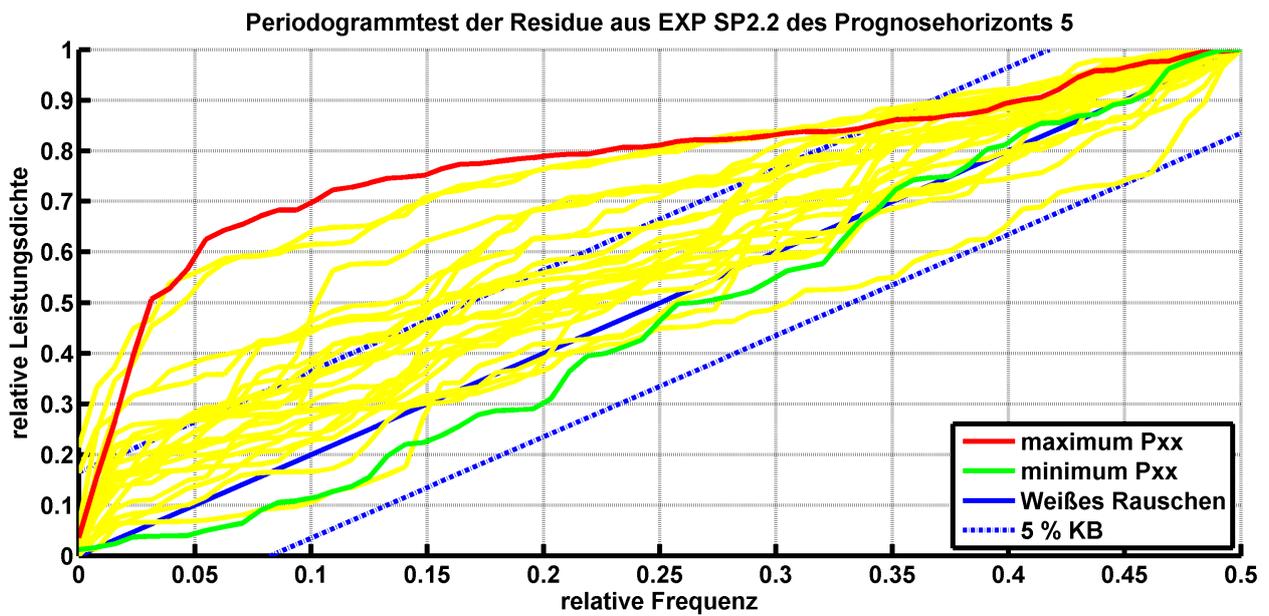


Abbildung D.59: Periodogrammtest des EXP SP 2.2

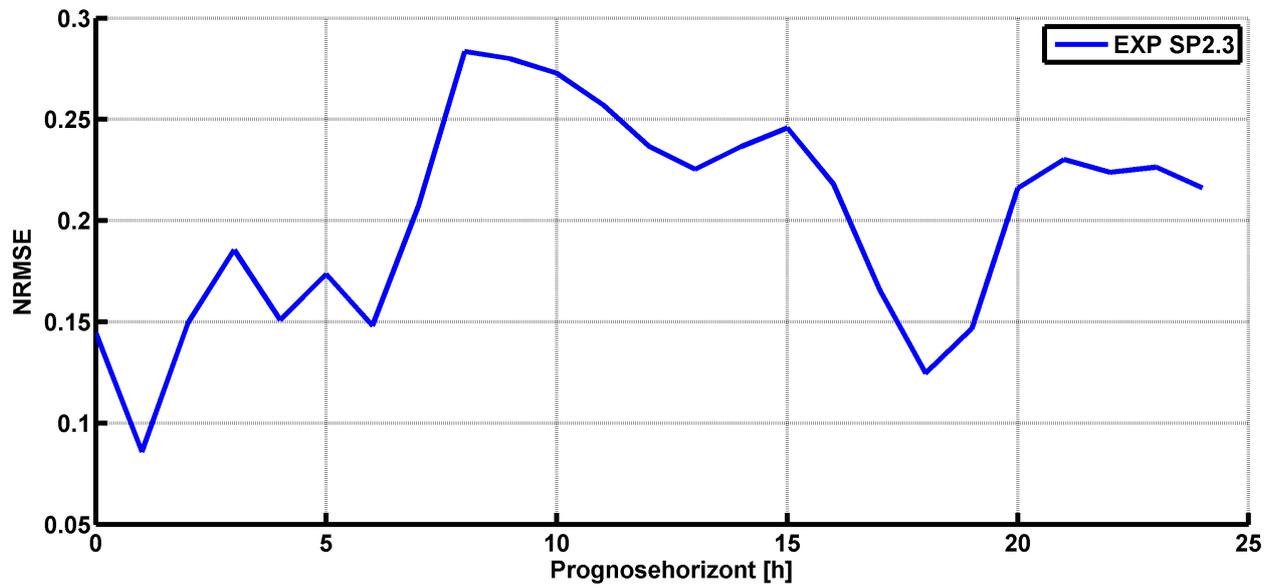


Abbildung D.60: NRMSE des EXP SP 2.3

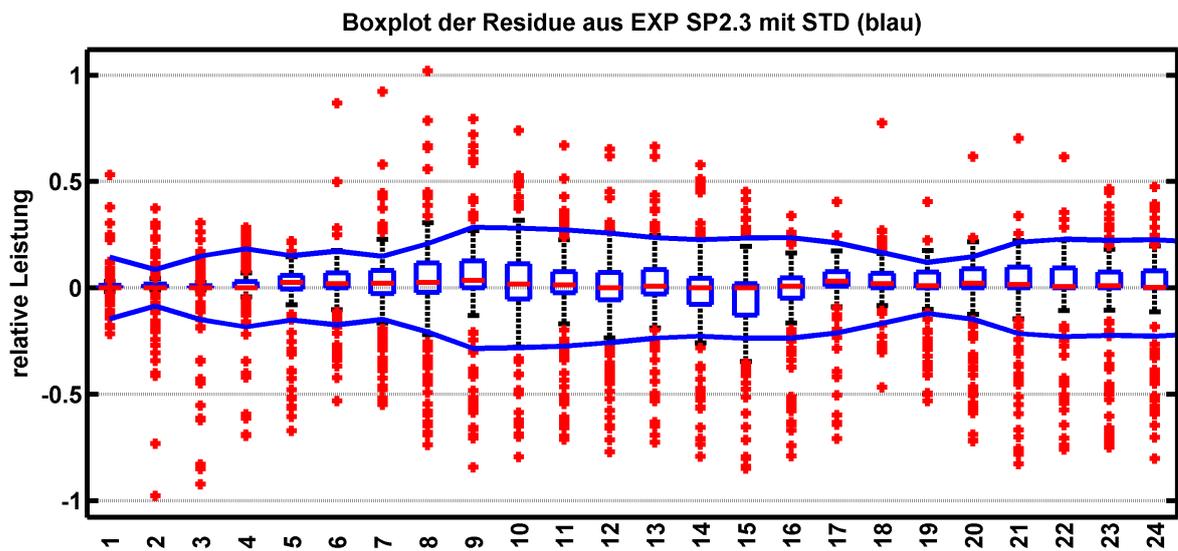


Abbildung D.61: Boxplot der Residuen des EXP SP 2.3

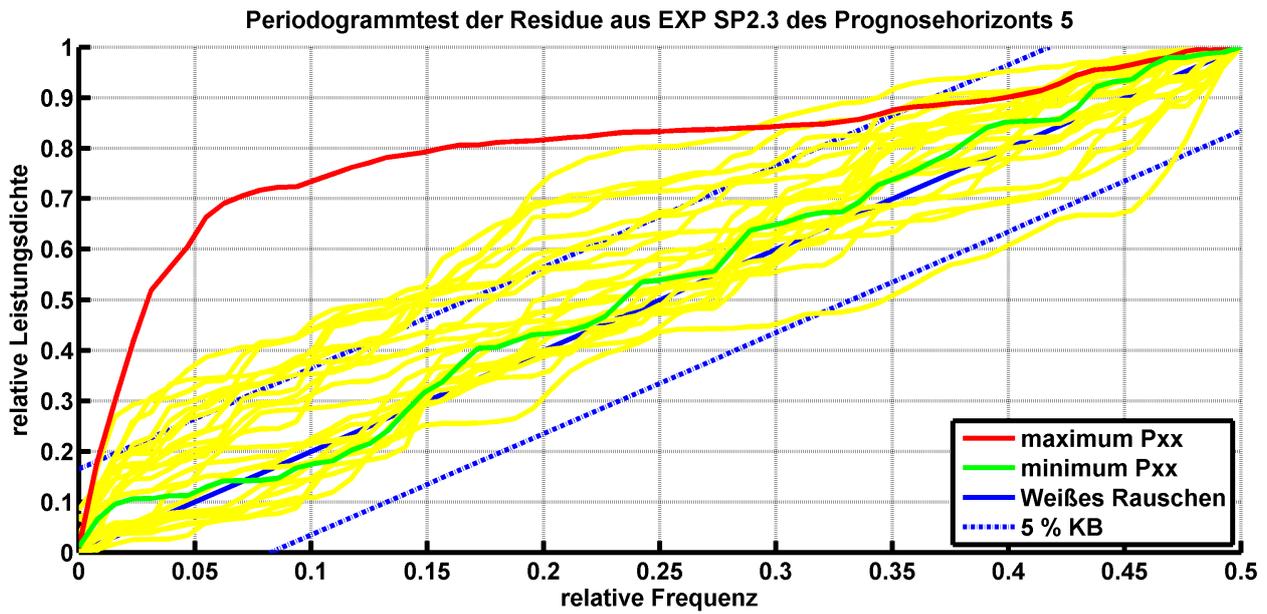


Abbildung D.62: Periodogrammtest des EXP SP 2.3

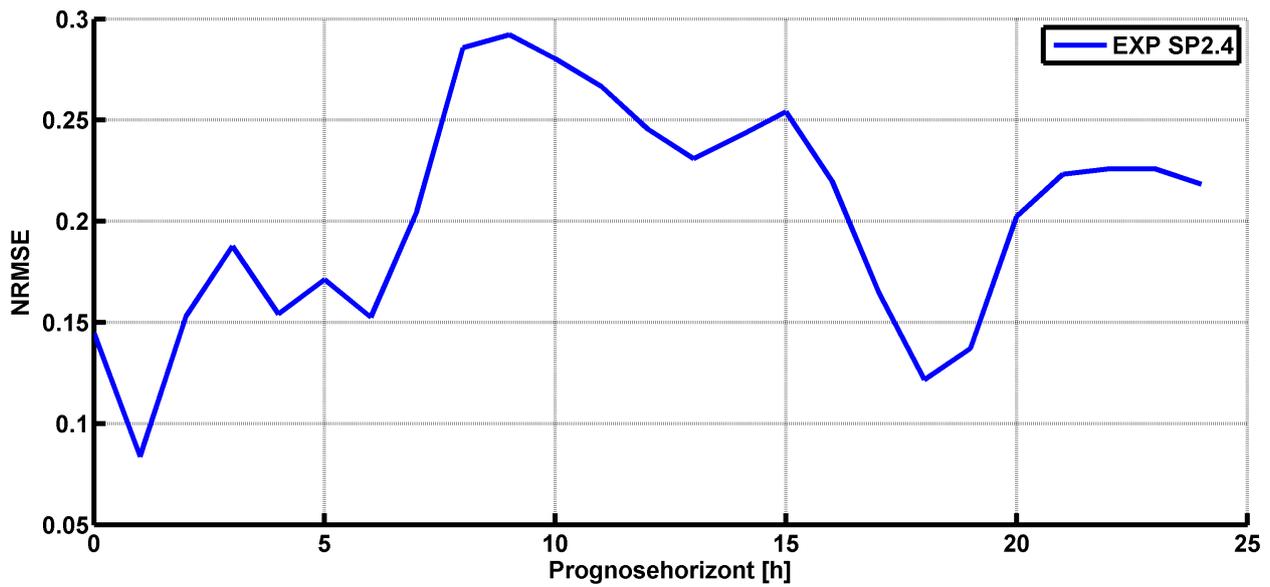


Abbildung D.63: NRMSE des EXP SP 2.4

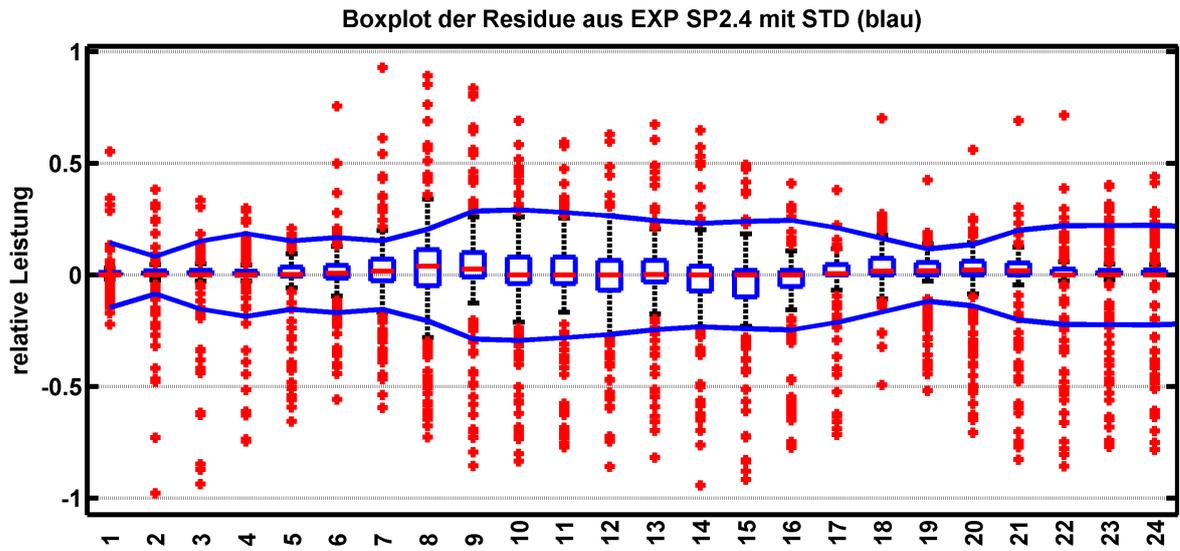


Abbildung D.64: Boxplot der Residuen des EXP SP 2.4

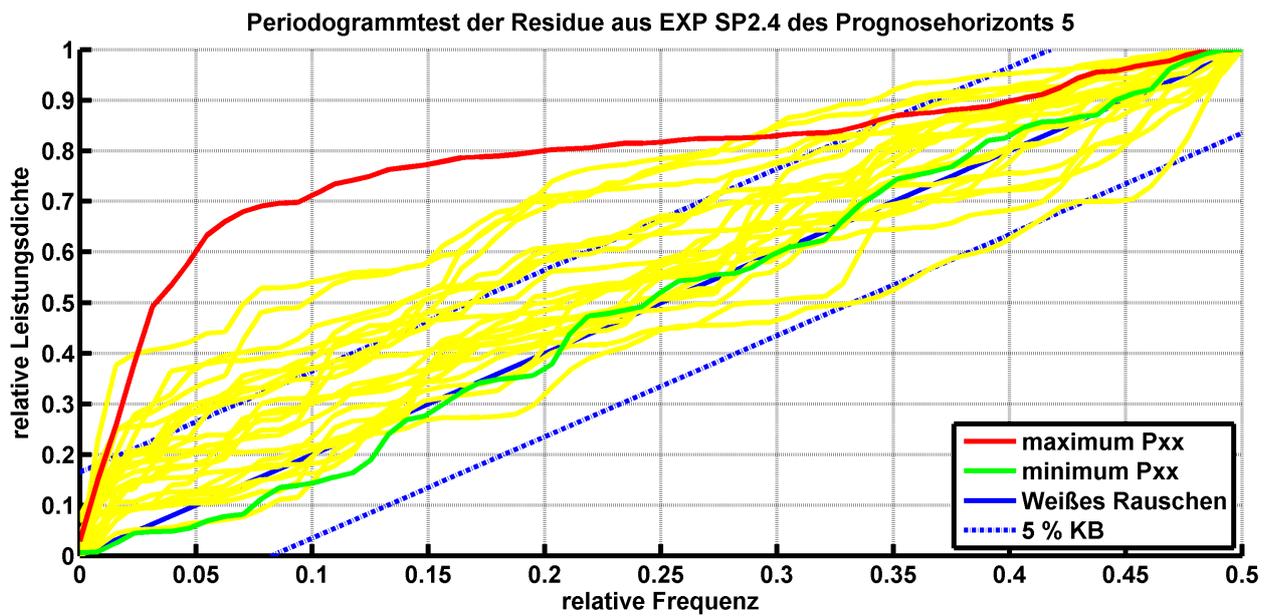


Abbildung D.65: Periodogrammtest des EXP SP 2.4

Literaturverzeichnis

- [1] *Projekt sMobiliTy*. www.smart-mobility-thuringen.de. – Stand: 05.10.2016
- [2] *Windpower 2003: Windpower 2003, Austin, TX (US), 18-21 May 2003*. 2003
- [3] *Windkraftanlagen: Grundlagen, Entwurf, Planung und Betrieb*. Bd. 4., vollst. überarb. und erw. Aufl. Wiesbaden : Teubner, 2005. – ISBN 3-519-36334-8
- [4] *IEEE Power Engineering Society general meeting, 2006: 18 - 22 June 2006, [Montreal, QC, Canada]*. Piscataway and NJ : IEEE Operations Center, 2006 . – ISBN 1-4244-0493-2. – Online: 06.11.2017
- [5] BUNDESMINISTERIUM DER JUSTIZ (Hrsg.): *Gesetz für den Vorrang Erneuerbarer Energien: EEG*. 2008
- [6] ABDEL-AAL, R.E ; ELHADIDY, M.A ; SHAAHID, S.M: Modeling and forecasting the mean hourly wind speed time series using GMDH-based abductive networks. In: *Renewable Energy* 34 (2009), Nr. 7, S. 1686–1699
- [7] AGABUS, H. ; TAMMOJA, H.: ESTIMATION OF WIND POWER PRODUCTION THROUGH SHORT-TERM FORECAST. In: *Oil Shale* 26 (2009), Nr. 3, S. 208
- [8] AL-HAMADI, H.M ; SOLIMAN, S.A: Fuzzy short-term electric load forecasting using Kalman filter. In: *IEE Proceedings - Generation, Transmission and Distribution* 153 (2006), Nr. 2, S. 217
- [9] ALESSANDRINI, S. ; DELLE MONACHE, L. ; SPERATI, S. ; NISSEN, J. N.: A novel application of an analog ensemble for short-term wind power forecasting. In: *Renewable Energy* 76 (2015), S. 768–781
- [10] ALESSANDRINI, S. ; SPERATI, S. ; PINSON, P.: A comparison between the ECMWF and COSMO Ensemble Prediction Systems applied to short-term wind power forecasting on real data. In: *Applied Energy* 107 (2013), S. 271–280
- [11] ALEXIADIS, M.C ; DOKOPOULOS, P.S ; SAHSAMANOGLU, H.S: Wind speed and power forecasting based on spatial correlation models. In: *IEEE Transactions on Energy Conversion* 14 (1999), Nr. 3, S. 836–842
- [12] ÄLJJEV, Rafiq ; BONFIG, Karl W. ; ÄLJJEV, Fuad: *Soft computing: Eine grundlegende Einführung ; [die CD: die beiliegende CD enthält Software-Module zur Demonstration verschiedener Fuzzy- und Neuro-Fuzzy-Systeme sowie andere praktisch verwendbare Projekte]*. Berlin : Verl. Technik, 2000. – ISBN 3-341-01238-9
- [13] AMJADY, Nima ; KEYNIA, Farshid ; ZAREIPOUR, Hamidreza: A new hybrid iterative method

-
- for short-term wind speed forecasting. In: *European Transactions on Electrical Power* 21 (2011), Nr. 1, S. 581–595
- [14] AMJADY, Nima ; KEYNIA, Farshid ; ZAREIPOUR, Hamidreza: Short-term wind power forecasting using ridgelet neural network. In: *Electric Power Systems Research* 81 (2011), Nr. 12, S. 2099–2107
- [15] AMJADY, Nima ; KEYNIA, Farshid ; ZAREIPOUR, Hamidreza: Wind Power Prediction by a New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization. In: *IEEE Transactions on Sustainable Energy* 2 (2011), Nr. 3, S. 265–276
- [16] ARNOLDT, A.: Intelligent Data Mining based Local Wind Power Forecasting. In: BETANCOURT, Uta (Hrsg.): *Proceedings / 12th Wind Integration Workshop, International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants, 22 - 24 October 2013, London, UK*. Langen : Energynautics, 2013. – ISBN 9783981387070, S. 701–704
- [17] ARNOLDT, A.: MAProSy Comparing Analysis Strategies and their Error Influence for Local Wind Power and PV Forecasts. In: BETANCOURT, Uta (Hrsg.): *Proceedings / 13th Wind Integration Workshop, International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants, 11 - 13 November 2014, Berlin, DE*. Langen : Energynautics, 2014. – ISBN 9783981387094, S. 783–786
- [18] ARNOLDT, A. ; AGSTEN, M. ; BRETSCHNEIDER, P.: Comparing Two Statistical Local Wind Power Forecasting Methodologies. In: BETANCOURT, Uta (Hrsg.): *Proceedings / 11th International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants*, energynautics GmbH, 2012. – ISBN 978-3-9813870-5-6
- [19] ARNOLDT, A. ; BRETSCHNEIDER, P.: Day Ahead Forecast of Wind Power through optimal Application of Multivariate Analyzing Methods. In: BETANCOURT, Uta (Hrsg.): *Proceedings: 10th International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants*, Energynautics, 2011. – ISBN 9783981387032, S. 654–657
- [20] ARNOLDT, A. ; KÖNIG, S. ; MIKUT, R. ; BRETSCHNEIDER, P.: Application of Data Mining Methods for Power Forecast of Wind Power Plants. In: BETANCOURT, U. (Hrsg.) ; ACKERMANN, Th (Hrsg.): *9th International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants: 18-19 October 2010 Québec City, Québec, Canada* Bd. 1, energynautics GmbH, 2010. – ISBN 978-3-9813870-2-5, S. 655–660
- [21] ARNOLDT, A. ; KÖNIG, S. ; MIKUT, R. ; BRETSCHNEIDER, P.: Einsatz von Data-Mining-Verfahren zur Einspeisungsprognose für Windenergieanlagen. In: *Automation 2010* Bd. 1, VDI-Verl., 2010 (VDI-Berichte). – ISBN 9783180920924, S. 99–102
- [22] ARNOLDT, Alexander ; BRETSCHNEIDER, Peter: Input Model Identifying Techniques for 48h Local Wind Power Forecast. In: *Power and Energy Systems and Applications*, ACTAPRESS, 2011. – ISBN 978-0-88986-905-9
- [23] BALZER, K.: *Menschen und Computer - Daten und Modelle*. Berlin : Springer, 1998. – ISBN 3540641866
-

- [24] BALZER, Konrad: *Wetterfrösche und Computer: Möglichkeiten und Grenzen der Wettervorhersage*. Frankfurt (Main) : Deutsch, 1989. – ISBN 3817110987
- [25] BARBOUNIS, T.G ; THEOCHARIS, J.B: Locally recurrent neural networks for wind speed prediction using spatial correlation. In: *Information Sciences* 177 (2007), Nr. 24, S. 5775–5797
- [26] BEI CHEN ; LIANG ZHAO ; JIAN HONG LU: Wind power forecast using RBF network and culture algorithm. In: *The 1st International Conference On Sustainable Power Generation And Supply: SUPERGEN '09., 6-7 April 2009*, Power Network Technology Press, 2009. – ISBN 978–1–4244–4934–7, S. 1–6
- [27] BESSA, Ricardo ; MIRANDA, Vladimiro ; GAMA, Joao: Improvement in wind power forecasting based on information entropy-related concepts. In: *2008 IEEE Power & Energy Society general meeting*, IEEE, 2008. – ISBN 978–1–4244–1905–0, S. 1–6
- [28] BESSA, Ricardo J. ; MIRANDA, V. ; PRINCIPE, Jose C. ; BOTTERUD, A. ; WANG, J.: Information theoretic learning applied to wind power modeling. In: *Neural Networks (IJCNN), The 2010 International Joint Conference on*, 2010. – ISBN 978–1–4244–6916–1, S. 1–8
- [29] BESSA, R.J ; MIRANDA, V. ; GAMA, J.: Entropy and Correntropy Against Minimum Square Error in Offline and Online Three-Day Ahead Wind Power Forecasting. In: *IEEE Transactions on Power Systems* 24 (2009), Nr. 4, S. 1657–1666
- [30] BHASKAR, K. ; SINGH, S.N: AAWN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network. In: *IEEE Transactions on Sustainable Energy* 3 (2012), Nr. 2, 306–315. <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6170987>. – Online: 06.11.2017
- [31] BLONBOU, Ruddy: Very short-term wind power forecasting with neural networks and adaptive Bayesian learning. In: *Renewable Energy* 36 (2011), Nr. 3, S. 1118–1124
- [32] BOTEV, Z. I. ; GROTOWSKI, J. F. ; KROESE, D. P.: Kernel density estimation via diffusion. In: *The Annals of Statistics* 38 (2010), Nr. 5, S. 2916–2957
- [33] BOX, George E. P. ; JENKINS, Gwilym M. ; REINSEL, Gregory C.: *Time series analysis: Forecasting and control*. 3rd ed. Englewood Cliffs, N.J. : Prentice Hall, 1994. – ISBN 0130607746
- [34] BREMEN, L. v. ; SALECK, N. ; GRÄWE, U. ; TAMBKE, J. ; HEINEMANN D.: *Meteorological Models for Prediction and Simulation of Wind Power*. 2006
- [35] BREMEN, Lueder v.: Combination of Deterministic and Probabilistic Meteorological Models to enhance Wind Farm Power Forecasts. In: *Journal of Physics: Conference Series* 75 (2007), Nr. 75, S. 012050
- [36] BREMEN, Lueder v. ; SALECK, Nadja ; HEINEMANN, Detlev: Enhanced regional forecasting considering single wind farm distribution for upscaling. In: *Journal of Physics: Conference Series* 75 (2007), Nr. 75, S. 012040
- [37] BREMNES, John B.: A comparison of a few statistical models for making quantile wind power forecasts. In: *Wind Energy* 9 (2006), Nr. 1-2, S. 3–11

-
- [38] BRETSCHNEIDER, Peter: *Ein Beitrag zur Vorhersage musterbasierter nichtlinearer stochastischer Signale*. Ilmenau : ISLE, 2002 (Automatisierungstechnik). – ISBN 3–932633–72–5
- [39] BROCKWELL, Peter J. ; DAVIS, Richard A.: *Time series: Theory and methods*. 2. New York : Springer-Verlag, 1991. – ISBN 3540974296
- [40] BUHAN, Serkan ; CADIRCI, Isik: Multi-Stage Wind-Electric Power Forecast by Using a Combination of Advanced Statistical Methods. In: *IEEE Transactions on Industrial Informatics* (2015), S. 1
- [41] BUNDESMINISTERIUM FÜR WIRTSCHAFT UND ENERGIE: *Energiedaten: Gesamtausgabe*. Version: 04.2015. <http://bmwi.de/BMWi/Redaktion/PDF/E/energiestatistiken-grafiken,property=pdf,bereich=bmwi2012,sprache=de,rwb=true.pdf>. – Online: 06.11.2017
- [42] BUNDESMINISTERIUM FÜR WIRTSCHAFT UND TECHNOLOGIE (Hrsg.): *Energiekonzept: für eine umweltschonende, zuverlässige und bezahlbare Energieversorgung*. September 2010
- [43] BURTON, Tony: *Wind energy: Handbook*. Reprinted. Chichester : Wiley, 2005. – ISBN 0471489972
- [44] CAIXIA WANG ; ZONGXIANG LU ; YING QIAO: Modeling of wind pattern and its application in wind speed forecasting. In: *The 1st International Conference On Sustainable Power Generation And Supply: SUPERGEN '09., 6-7 April 2009*, Power Network Technology Press, 2009. – ISBN 978–1–4244–4934–7, S. 1–6
- [45] CALLAN, Robert: *Neuronale Netze: Im Klartext*. München and Harlow : Pearson Studium, 2003. – ISBN 3–8273–7071–x
- [46] CAMPBELL, P.R.J: Short-Term Wind Energy Forecasting. In: *IEEE Canada Electrical Power Conference, 2007*, IEEE, 2007. – ISBN 978–1–4244–1444–4, 342–346. – Online: 06.11.2017
- [47] CAROLIN MABEL, M. ; FERNANDEZ, E.: Analysis of wind power generation and prediction using ANN: A case study. In: *Renewable Energy* 33 (2008), Nr. 5, S. 986–992
- [48] CASSOLA, Federico ; BURLANDO, Massimiliano: Wind speed and wind energy forecast through Kalman filtering of Numerical Weather Prediction model output. In: *Applied Energy* 99 (2012), S. 154–166
- [49] CATALÃO, J.P.S ; POUSINHO, H.M.I ; MENDES, V.M.F: Short-term wind power forecasting in Portugal by neural networks and wavelet transform. In: *Renewable Energy* 36 (2011), Nr. 4, S. 1245–1251
- [50] CATALÃO, J.P.S ; POUSINHO, H. M. I. ; MENDES, V. M. F.: Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal. In: *IEEE Transactions on Sustainable Energy* (2010)
- [51] CATALÃO, J.P.S ; POUSINHO, H.M.I ; MENDES, V.M.F: Hybrid intelligent approach for short-term wind power forecasting in Portugal. In: *IET Renewable Power Generation* 5 (2011), Nr. 3, S. 251
-

- [52] CELIK, Ali N. ; KOLHE, Mohan: Generalized feed-forward based method for wind energy prediction. In: *Applied Energy* 101 (2013), S. 582–588
- [53] CHANG, Wen-Yeou: An RBF Neural Network Combined with OLS Algorithm and Genetic Algorithm for Short-Term Wind Power Forecasting. In: *Journal of Applied Mathematics* 2013 (2013), S. 1–9
- [54] CHEN, Niya ; QIAN, Zheng ; NABNEY, Ian T. ; MENG, Xiaofeng: Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction. In: *IEEE Transactions on Power Systems* 29 (2014), Nr. 2, S. 656–665
- [55] CHEN, Peiyuan ; PEDERSEN, Troels ; BAK-JENSEN, Birgitte ; CHEN, Zhe: ARIMA-Based Time Series Model of Stochastic Wind Power Generation. In: *IEEE Transactions on Power Systems* 25 (2010), Nr. 2, S. 667–676
- [56] CHEONG TOOK, C. ; MANDIC, D. P. ; AIHARA, K.: *Quaternion-valued short term forecasting of wind profile*. IEEE, 2010. – ISBN 978–1–4244–6916–1
- [57] COLAK, Ilhami ; SAGIROGLU, Seref ; YESILBUDAK, Mehmet: Data mining and wind power prediction: A literature review. In: *Renewable Energy* 46 (2012), S. 241–247
- [58] COLLINS, Jonathan ; PARKES, Jeremy ; TINDAL, Andrew: Forecasting for utility-scale wind farms the power model challenge. In: *Integration of wide-scale renewable resources into the power delivery system*, 2009. – ISBN 978–1–4244–4860–9, S. 1–10
- [59] COSTA, A. ; CRESPO, A. ; NAVARRO, J. ; LIZCANO, G. ; MADSEN, H. ; FEITOSA, E.: A review on the young history of the wind power short-term prediction. In: *Renewable and Sustainable Energy Reviews* 12 (2008), Nr. 6, S. 1725–1744
- [60] COVER, T. M. ; THOMAS, Joy A.: *Elements of information theory*. 2. Hoboken and N.J : Wiley-Interscience, 2006. – ISBN 978–0–471–24195–9
- [61] CUTLER, Nicholas ; KAY, Merlinde ; JACKA, Kieran ; NIELSEN, Torben S.: Detecting, categorizing and forecasting large ramps in wind farm power output using meteorological observations and WPPT. In: *Wind Energy* 10 (2007), Nr. 5, S. 453–470
- [62] DARBELLAY, Georges A.: Predictability: An Information-Theoretic Perspective. In: BENEDDETTO, John J. (Hrsg.) ; PROCHÁZKA, Ales (Hrsg.) ; UHLÍŘ, Jan (Hrsg.) ; RAYNER, P. W. J. (Hrsg.) ; KINGSBURY, N. G. (Hrsg.): *Signal Analysis and Prediction*. Boston and MA : Birkhäuser Boston, 1998 (Applied and Numerical Harmonic Analysis). – ISBN 978–1–4612–7273–1, S. 249–262
- [63] DARBELLAY, Georges A.: An estimator of the mutual information based on a criterion for conditional independence. In: *Computational Statistics & Data Analysis* 32 (1999), Nr. 1, S. 1–17
- [64] DEMUTH, Howard ; BEALE, Mark ; HAGAN MARTIN: *Neural Network Toolbox™ 6: User's Guide*. The MathWorks, Inc.: 3 Apple Hill Drive, Natick, MA 01760-2098, 2010
- [65] DOERR, H. (Hrsg.) ; LANGE, M. (Hrsg.): *Monitoringbericht 2012*. Version: 27.11.2012. https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2012/MonitoringBericht2012.pdf?__blob=publicationFile. – Online: 06.11.2017

-
- [66] DOESWIJK, T.G ; KEESMAN, K.J: Adaptive Weather Forecasting using Local Meteorological Information. In: *Biosystems Engineering* 91 (2005), Nr. 4, S. 421–431
- [67] DURÁN, M. J. ; CROS, D. ; RIQUELME, J.: *Short-term wind power prediction based on AR models*. Version: 2005. https://www.google.de/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&cad=rja&uact=8&ved=0ahUKEwj-zr75r6rXAhWQKewKHW0oBwwQFggpMAA&url=http%3A%2F%2Fciteseerx.ist.psu.edu%2Fviewdoc%2Fdownload%3Bjsessionid%3DA787BD066D7DE913989A5C4DC63C336A%3Fdoi%3D10.1.1.558.9968%26rep%3Drep1%26type%3Dpdf&usg=A0vVaw02iQstA2yLIrWoy8JQMMU_. – Online: 06.11.2017
- [68] DŽEROSKI, Sašo: *Relational data mining: With 69 tables*. Berlin [u.a.] : Springer, 2001. – ISBN 3540422897
- [69] ELATTAR, E. E.: Short term wind power prediction using evolutionary optimized local support vector regression. In: *2011 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies*, IEEE, 2011. – ISBN 978–1–4577–1421–4, S. 1–7
- [70] ERNST, Bernhard ; REYER, Frank ; VANZETTA, Joachim: Wind power and photovoltaic prediction tools for balancing and grid operation. In: CONSEIL INTERNATIONAL DES GRANDS RÉSEAUX ÉLECTRIQUES (Hrsg.): *Thermal performance of transformers*, CIGRÉ, 2009. – ISBN 978–2–85873–080–3, S. 1–9
- [71] FAN, Shu ; HYNDMAN, Rob J.: Short-Term Load Forecasting Based on a Semi-Parametric Additive Model. In: *IEEE Transactions on Power Systems* 27 (2012), Nr. 1, S. 134–141
- [72] FAULSTRICH, Martin ; FOTH, Heidi ; CALLIESS, Christian ; HOHMEYER, Olav ; HOLM-MÜLLER, Karin ; NIEKISCH, Manfred ; SCHREURS, Miranda ; SUR (Hrsg.): *100% erneuerbare Stromversorgung bis 2050: klimaverträglich, sicher, bezahlbar: Stellungnahme*. Berlin, 2010
- [73] FELIX, Oliver ; ET AL.: *Zweiter Entwurf Netzentwicklungsplan Strom 2014*. Version: 04.11.2014. <http://www.netzausbau-niedersachsen.de/verfahren/netzentwicklungsplan-2012/nep-2014/index.html>. – Online: 06.11.2017
- [74] FOCKEN, Ulrich ; LANGE, Matthias ; MÖNNICH, Kai ; WALDL, Hans-Peter: Räumliche Ausgleichseffekte bei der Vorhersage der Leistungsabgabe von Windkraftanlagen. In: *Deutsche Windenergie-Konferenz - DEWEK 2000*, 2000
- [75] FOCKEN, Ulrich ; LANGE, Matthias ; MÖNNICH, Kai ; WALDL, Hans-Peter: *A statistical analysis of the reduction of the wind power prediction error by spatial smoothing effects*. Version: 2001. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.59.9888&rep=rep1&type=pdf>. – Online: 06.11.2017
- [76] FOCKEN, Ulrich ; LANGE, Matthias ; MÖNNICH, Kai ; WALDL, Hans-Peter ; BEYER, Hans G. ; LUIG, Armin: Short-term prediction of the aggregated power output of wind farms—a statistical analysis of the reduction of the prediction error by spatial smoothing effects. In: *Journal of Wind Engineering and Industrial Aerodynamics* 90 (2002), Nr. 3, S. 231–246
- [77] FOCKEN, Ulrich ; LANGE, Matthias ; WALDL, Hans-Peter: *Previento - A Wind Power Prediction System with an Innovative Upscaling Algorithm*. 2001
- [78] FOLEY, Aoife M. ; LEAHY, Paul G. ; MARVUGLIA, Antonino ; MCKEOGH, Eamon J.: Current methods and advances in forecasting of wind power generation. In: *Renewable Energy* 37 (2012), Nr. 1, S. 1–8
-

- [79] GIEBEL, G. ; ANEMOS (Hrsg.): *The State-Of-The-Art in Short-Term Prediction of Wind Power: A Literature Overview*. Version:2003. https://www.researchgate.net/publication/248021555_The_State-Of-The-Art_in_Short-Term_Prediction_of_Wind_Power_A_Literature_Overview. – Online: 06.11.2017
- [80] GIEBEL, G. ; BADGER, J. ; MARTÍ PEREZ, I. ; LOUKA, P. ; KALLOS, G. ; PALOMARES, A. M. ; LAC, C. ; DESCOMBES, G.: Short-term Forecasting Using Advanced Physical Modelling - The Results of the Anemos Project: Results from mesoscale, microscale and CFD modelling. In: *Conference proceedings DVD*, European Wind Energy Association, 2006, S. 1–29
- [81] GIEBEL, G. ; ET AL. ; ANEMOS.PLUS (Hrsg.): *The State-Of-The-Art in Short-Term Prediction of Wind Power: A Literature Overview, 2nd Edition*. https://www.researchgate.net/publication/283641726_The_State_of_the_Art_in_Short-Term_Prediction_of_Wind_Power_A_Literature_Overview_2nd_Edition. – Online: 06.11.2017
- [82] GILL, Kashif ; MOON, Dennis: Data Mining For Multi-Criteria Energy Predictions. In: AO, Sio-Iong (Hrsg.): *WCECS 2009* Bd. 2, 2009. – ISBN 978–988–18210–2–7
- [83] GLAHN, Harry R. ; LOWRY, Dale A.: The Use of Model Output Statistics (MOS) in Objective Weather Forecasting. In: *Journal of Applied Meteorology* 11 (1972), Nr. 8, S. 1203–1211
- [84] GÓMEZ-MUÑOZ, V.M ; PORTA-GÁNDARA, M.A: Local wind patterns for modeling renewable energy systems by means of cluster analysis techniques. In: *Renewable Energy* 25 (2002), Nr. 2, S. 171–182
- [85] GRASSI, Giuseppe ; VECCHIO, Pietro: Wind energy prediction using a two-hidden layer neural network. In: *Communications in Nonlinear Science and Numerical Simulation* 15 (2010), Nr. 9, S. 2262–2266
- [86] GU, Yundong ; HU, Fangfang: An intelligent forecasting method for short term electric power load based on partitioned support vector regression. In: *Cyber Technology in Automation, Control, and Intelligent Systems (CYBER), 2012 IEEE International Conference on*, 2012, S. 721–725
- [87] GUAN, Che ; LUH, Peter B. ; CAO, Wen: Short-term wind generation forecasting and confidence interval estimation based on neural networks trained by extended Kalman particle filter. In: *Intelligent Control and Automation (WCICA), 2011 9th World Congress on*, 2011. – ISBN 978–1–61284–698–9, S. 1173–1179
- [88] GUAN, Che ; LUH, Peter B. ; MICHEL, Laurent D. ; WANG, Yuting ; FRIEDLAND, Peter B.: Very Short-Term Load Forecasting: Wavelet Neural Networks With Data Pre-Filtering. In: *IEEE Transactions on Power Systems* (2012), S. 1
- [89] HAGAN, M.T ; MENHAJ, M.B: Training feedforward networks with the Marquardt algorithm. In: *IEEE Transactions on Neural Networks* 5 (1994), Nr. 6, S. 989–993
- [90] HAMEL, Lutz: *Knowledge discovery with support vector machines*. Hoboken and N.J : John Wiley & Sons, 2009. – ISBN 9780470371923
- [91] HAN, Shuang ; LI, Jinshan ; LIU, Yongqian: Tabu Search Algorithm Optimized ANN Model for Wind Power Prediction with NWP. In: *Energy Procedia* 12 (2011), S. 733–740

-
- [92] HAND, David ; MANNILA, Heikki ; SMYTH, Padhraic: *Principles of data mining*. Cambridge : MIT Press, op. 2001. – ISBN 026208290x
- [93] HAO, Chen ; QIULAN, Wan ; FANGXING, Li ; YURONG, Wang: GARCH in mean type models for wind power forecasting. In: *Power and Energy Society General Meeting (PES), 2013 IEEE, 2013*, 1–5. – Online: 06.11.2017
- [94] HAQUE, Ashraf U. ; NEHRIR, M. H. ; MANDAL, Paras: A Hybrid Intelligent Model for Deterministic and Quantile Regression Approach for Probabilistic Wind Power Forecasting. In: *IEEE Transactions on Power Systems* 29 (2014), Nr. 4, S. 1663–1672
- [95] HOMANN, Jochen ; MUNDT, Andreas: *Monitoringbericht 2014: Bericht*. Version: 14.11.2014. http://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2014/Monitoringbericht_2014_BF.pdf?__blob=publicationFile&v=4. – Online: 06.11.2017
- [96] HORN, John L.: A rationale and test for the number of factors in factor analysis. In: *Psychometrika* 30 (1965), Nr. 2, S. 179–185
- [97] HUANG, Chi-Yo ; LIU, Yu-Wei ; TZENG, Wei-Chang ; WANG, Po-Yen: *Short Term Wind Speed Predictions by Using the Grey Prediction Model Based Forecast Method*. IEEE, 2011. – ISBN 978–1–61284–713–9
- [98] HUI ZHOU ; MEI HUANG ; XINFHUA WU: Forecast of Wind speed and power of wind generator based on pattern recognition. In: *International Conference on Industrial Mechatronics and Automation 2009. ICIMA 2009*, IEEE, 2009. – ISBN 978–1–4244–3818–12009900284, S. 504–508
- [99] JOHANNESSON, Rolf: *Informationstheorie: Grundlage der (Tele-)Kommunikation*. [Bonn and München and Reading and Mass. u.a.] and Lund : Addison-Wesley and Studentlitteratur, 1992. – ISBN 3–89319–465–7
- [100] JOHNSON, Peter L. ; NEGNEVITSKY, Michael ; MUTTAQI, Kashem M.: Short term wind power forecasting using adaptive neuro-fuzzy inference systems. In: *Australasian Universities Power Engineering Conference, 2007*, IEEE, 2007. – ISBN 978–0–646–49488–3, S. 1–6
- [101] KANTARDZIC, Mehmed: *Data mining: Concepts, models, methods, and algorithms*. 2. Hoboken and NJ : Wiley-IEEE Press, 2011. – ISBN 9780470890455
- [102] KARINIOTAKIS, G. ; MOUSSAFIR, J. ; MAYER, D. ; CHEVALLAZ-PERRIER, R. ; USAOLA, J. ; SANCHEZ, I. ; MARTI, I. ; MADSEN, H. ; NIELSEN, T. S. ; LAC, C. ; FRAYSSINET, P. ; WALDL, Hans-Peter ; HALLIDAY, J. ; GIEBEL, G. ; LANDBERG, L. ; KALLOS, G. ; OTTAVI, J. ; FOCKEN, Ulrich ; LANGE, Matthias ; HEINEMANN, D. ; KINTXO ANCÍN, J. ; TOEFTING, J. ; O’DONNELL, P. ; MCCOY, D. ; COLLMANN, M. ; GIGANDIDOU, A. ; GONZALES G. ; BARQUERO, C. ; CRUZ, I. ; HATZIARGYRIOU, N.: Next Generation Short-Term Forecasting of Wind Power - Overview of the ANEMOS Project. In: *Conference proceedings DVD*, European Wind Energy Association, 2006, S. 1–10
- [103] KARINIOTAKIS, G. ; MOUSSAFIR, J. ; MAYER, D. ; CHEVALLAZ-PERRIER, R. ; USAOLA, J. ; SANCHEZ, I. ; MARTI, I. ; MADSEN, H. ; NIELSEN, T. S. ; LAC, C. ; FRAYSSINET, P. ; WALDL, Hans-Peter ; HALLIDAY, J. ; GIEBEL, G. ; LANDBERG, L. ; KALLOS, G. ; OTTAVI, J. ; FOCKEN, Ulrich ; LANGE, Matthias ; HEINEMANN, D. ; KINTXO ANCÍN, J. ; TOEFTING, J. ; O’DONNELL, P. ; MCCOY, D. ; COLLMANN, M. ; GIGANDIDOU, A. ; GONZALES G. ; BARQUERO, C. ;
-

- CRUZ, I. ; HATZIARGYRIOU, N.: *ANEMOS: Development of a Next Generation Wind Power Forecasting System for the Large-Scale Integration of Onshore & Offshore Wind Farms*. 2003
- [104] KAVASSERI, Rajesh G. ; SEETHARAMAN, Krithika: Day-ahead wind speed forecasting using f-ARIMA models. In: *Renewable Energy* 34 (2009), Nr. 5, S. 1388–1393
- [105] KHALID, M. ; SAVKIN, A.V: A Method for Short-Term Wind Power Prediction With Multiple Observation Points. In: *IEEE Transactions on Power Systems* 27 (2012), Nr. 2, 579–586. <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6144039>. – Online: 06.11.2017
- [106] KINNEBROCK, Werner: *Neuronale Netze: Grundlagen, Anwendungen, Beispiele*. 2., verb. Aufl. München : Oldenbourg, 1994 <http://www.zentralblatt-math.org/zmath/en/search/?an=0868.68091>. – ISBN 3486229478. – Online: 06.11.2017
- [107] KLOSE, Brigitte: *Meteorologie: Eine interdisziplinäre Einführung in die Physik der Atmosphäre*. Berlin : Springer, 2008. – ISBN 978-3-540-71308-1
- [108] KREISS, Jens-Peter: *Einführung in die Zeitreihenanalyse: Mit 8 Tabellen*. Berlin : Springer, 2006. – ISBN 978-3-540-25628-1
- [109] KUSIAK, A. ; HAIYANG ZHENG ; ZHE SONG: Short-Term Prediction of Wind Farm Power: A Data Mining Approach. In: *IEEE Transactions on Energy Conversion* 24 (2009), Nr. 1, S. 125–136
- [110] KUSIAK, Andrew ; ZHENG, Haiyang ; SONG, Zhe: Wind farm power prediction. In: *Wind Energy* 12 (2009), Nr. 3, S. 275–293
- [111] LANDBERG, L.: Short-term prediction of the power production from wind farms. In: *Journal of Wind Engineering and Industrial Aerodynamics* 80 (1999), Nr. 1-2, S. 207–220
- [112] LANDBERG, Lars ; GIEBEL, Gregor ; NIELSEN, Henrik A. ; NIELSEN, Torben ; MADSEN, Henrik: Short-term Prediction - An Overview. In: *Wind Energy* 6 (2003), Nr. 3, S. 273–280
- [113] LANGE, Matthias: *Analysis of the Uncertainty of Wind Power Predictions*. Oldenburg, Carl von Ossietzky Universität Oldenburg, Diss., 31.10.2003
- [114] LANGE, Matthias ; FOCKEN, Ulrich: *Physical Approach to Short-Term Wind Power Prediction*. Berlin and Heidelberg : Springer, 2006 <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10143412>. – ISBN 3-540-25662-8. – Online: 06.11.2017
- [115] LANGE, Matthias ; FOCKEN, Ulrich: New developments in wind energy forecasting. In: *2008 IEEE Power & Energy Society general meeting, IEEE*, 2008. – ISBN 978-1-4244-1905-0, S. 1–8
- [116] LANGE, Matthias ; FOCKEN, Ulrich ; HEINEMANN, D.: PREVIENTO Regional Wind Power prediction with risk Control. In: *The World Wind Energy Conference and Exhibition, ICC*, Berlin, Germany, 2002
- [117] LANGE, Matthias ; WALDL, Hans-Peter: Assessing the uncertainty of wind power predictions with regard to specific weather situations. In: *Proc. of the 2001 European Wind Energy Association Conference, EWEC 2001*, 2001

-
- [118] LAZIĆ, Lazar ; PEJANOVIĆ, Goran ; ŽIVKOVIĆ, Momčilo: Wind forecasts for wind power generation using the Eta model. In: *Renewable Energy* 35 (2010), Nr. 6, S. 1236–1243
- [119] LEE, Duehee: Short-term prediction of wind farm output using the recurrent quadratic volterra model. In: *2011 IEEE Power and Energy Society General Meeting, IEEE*, 2011. – ISBN 978-1-4577-1000-1, S. 1–8
- [120] LEI, Ma ; SHIYAN, Luan ; CHUANWEN, Jiang ; HONGLING, Liu ; YAN, Zhang: A review on the forecasting of wind speed and generated power. In: *Renewable and Sustainable Energy Reviews* 13 (2009), Nr. 4, S. 915–920
- [121] LI, Gong ; SHI, Jing: On comparing three artificial neural networks for wind speed forecasting. In: *Applied Energy* 87 (2010), Nr. 7, S. 2313–2320
- [122] LI, S. ; WUNSCH, D. C. ; O’HAIR, E. A. ; GIESSELMANN, M. G.: Using Neural Networks to Estimate Wind Turbine Power Generation. In: *IEEE Transactions on Energy Conversion* (2001), Nr. 16 - 3, S. 276–282
- [123] LIU, Xing-Jie ; MI, Zeng-Qiang ; BAI, Lu ; WU, Tao: A Novel Approach for Wind Speed Forecasting Based on EMD and Time-Series Analysis. In: *Asia-Pacific Power and Energy Engineering Conference, 2009, IEEE*, 2009. – ISBN 978-1-4244-2486-3, S. 1–4
- [124] LIU, Yongqian ; SHI, Jie ; YANG, Yongping ; LEE, Wei-Jen: Short-Term Wind-Power Prediction Based on Wavelet Transform & - Support Vector Machine and Statistic-Characteristics Analysis. In: *IEEE Transactions on Industry Applications* 48 (2012), Nr. 4, S. 1136–1141
- [125] LJUNG, Lennart: *System identification: Theory for the user*. 2. ed., 14. printing. Upper Saddle River, NJ : Prentice Hall PTR, 2012 (Prentice Hall information and system sciences series). – ISBN 0-13-656695-2
- [126] LOBO, Miguel G. ; SANCHEZ, Ismael: Regional Wind Power Forecasting Based on Smoothing Techniques, With Application to the Spanish Peninsular System. In: *IEEE Transactions on Power Systems* 27 (2012), Nr. 4, S. 1990–1997
- [127] LOUKA, P. ; GALANIS, G. ; SIEBERT, N. ; KARINIOTAKIS, G. ; KATSAFADOS, P. ; PYTHAROULIS, I. ; KALLOS, G.: Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering. In: *Journal of Wind Engineering and Industrial Aerodynamics* 96 (2008), Nr. 12, S. 2348–2362
- [128] MADSEN, H.: A Protocol for Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models. In: ANEMOS (Hrsg.): *Proceedings of the 2004 Global Windpower Conference and Exhibition*, 2004, S. 1–17
- [129] MAHONEY, W.P ; PARKS, K. ; WIENER, G. ; YUBAO, Liu ; MYERS, W.L ; JUANZHEN, Sun ; DELLE MONACHE, L. ; HOPSON, T. ; JOHNSON, D. ; HAUPT, S.E: A Wind Power Forecasting System to Optimize Grid Integration. In: *IEEE Transactions on Sustainable Energy* 3 (2012), Nr. 4, 670–682. <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6237561>. – Online: 06.11.2017
- [130] MARTI, I. ; KARINIOTAKIS, G. ; ET AL.: Evaluation of Advanced Wind Power Forecasting Models - Results of the Anemos Project. In: *European Wind Energy Conference, EWEC 2006*, 2006
-

- [131] MELLIT, Adel ; KALOGIROU, Soteris A.: ANFIS-based modelling for photovoltaic power supply system: A case study. In: *Renewable Energy* 36 (2011), Nr. 1, S. 250–258
- [132] MESSNER, Jakob W. ; ZEILEIS, Achim ; BROECKER, Jochen ; MAYR, Georg J.: Probabilistic wind power forecasts with an inverse power curve transformation and censored regression. In: *Wind Energy* 17 (2014), Nr. 11, S. 1753–1766
- [133] MIKUT, Ralf: *Modellgestützte on-line-Stabilitätsüberwachung komplexer Systeme auf der Basis unscharfer Ljapunov-Funktionen*. Düsseldorf and Karlsruhe, Univ, Diss., 1999
- [134] MIRANDA, M.S ; DUNN, R.W: One-hour-ahead wind speed prediction using a Bayesian methodology. In: *IEEE Power Engineering Society general meeting, 2006*, IEEE Operations Center, 2006. – ISBN 1-4244-0493-2, S. 6 pp
- [135] MISHRA, A.K ; RAMESH, L.: Application of neural networks in wind power (generation) prediction. In: *The 1st International Conference On Sustainable Power Generation And Supply: SUPERGEN '09., 6-7 April 2009*, Power Network Technology Press, 2009. – ISBN 978-1-4244-4934-7, S. 1–5
- [136] MONTEIRO, C. ; BESSA, R. ; MIRANDA, V. ; BOTTERUD, A. ; WANG, J. ; CONZELMANN, G.: *Wind Power Forecasting: State-of-the-Art 2009*. U.S. Department of Energy, Argonne National Laboratory, 06.11. 2009
- [137] MORI, Hiroyuki ; UMEZAWA, Yasushi: Application of NBTree to selection of meteorological variables in wind speed prediction. In: *2009 Transmission & Distribution Conference & Exposition: Asia and Pacific*, IEEE, 2009. – ISBN 978-1-4244-5230-9, S. 1–4
- [138] MORTENSEN, N. G. ; BOWEN, A. J. ; ANTONIOU, I.: *Improving WAsP Predictions in (TOO) Complex Terrain*. https://www.researchgate.net/publication/228963533_Improving_WAsP_predictions_in_too_complex_terrain. Version: 2006. – Online: 06.11.2017
- [139] MUIRHEAD, Robb J.: *Aspects of multivariate statistical theory*. Hoboken and NJ : Wiley-Interscience, 1982 // 2005 (Wiley series in probability and statistics). – ISBN 9780471769859
- [140] NEGNEVITSKY, M. ; JOHNSON, P. ; SANTOSO, S.: Short term wind power forecasting using hybrid intelligent systems. In: *IEEE Power Engineering Society general meeting, 2007*, IEEE Service Center, 2007. – ISBN 1-4244-1298-6, S. 1–4
- [141] NEGNEVITSKY, Michael ; POTTER, Cameron: Innovative Short-Term Wind Generation Prediction Techniques. In: *IEEE Power Engeneering Society* (2006), S. 60–65
- [142] NIELSEN, Henrik A. ; NIELSEN, Torben S. ; MADSEN, Henrik ; PINDADO, Maria J. San I. ; MARTI, Ignacio: Optimal combination of wind power forecasts. In: *Wind Energy* 10 (2007), Nr. 5, S. 471–482
- [143] NIELSEN, Henrik A. ; MADSEN, Henrik ; NIELSEN, Torben S.: Using quantile regression to extend an existing wind power forecasting system with probabilistic forecasts. In: *Wind Energy* 9 (2006), Nr. 1-2, S. 95–108
- [144] NIELSEN, Torben S. ; JOENSEN, Alfred ; MADSEN, Henrik ; LANDBERG, Lars ; GIEBEL, Gregor: A new reference for wind power forecasting. In: *Wind Energy* 1 (1998), Nr. 1, S. 29–34

-
- [145] NITSCH, Joachim: *Langfristszenarien und Strategien für den Ausbau der erneuerbaren Energien in Deutschland bei Berücksichtigung der Entwicklung in Europa und global: Schlussbericht*. Stuttgart u.a and Hannover : Technische Informationsbibliothek u. Universitätsbibliothek, 2012 <http://edok01.tib.uni-hannover.de/edoks/e01fb14/795431589.pdf>. – Online: 06.11.2017
- [146] NUMERISCHE WETTERVORHERSAGEMODELLE DES DWD: *Numerische Wettervorhersagemodelle des DWD*. 2008
- [147] OZKAN, Mehmet ; KARAGOZ, Pinar: A Novel Wind Power Forecast Model: Statistical Hybrid Wind Power Forecast Technique (SHWIP). In: *IEEE Transactions on Industrial Informatics* (2015), S. 1
- [148] PALOMARES-SALAS, J.C ; LA ROSA, J.J G. d. ; RAMIRO, J.G ; MELGAR, J. ; AGUERA, A. ; MORENO, A.: ARIMA vs. Neural networks for wind speed forecasting. In: CIMSIA (Hrsg.): *Computational Intelligence for Measurement Systems and Applications, 2009.*, IEEE Service Center, 2009. – ISBN 978-1-4244-3819-8, S. 129–133
- [149] PAN CHEN ; HAoyong CHEN ; RONG YE: *Chaotic wind speed series forecasting based on wavelet packet decomposition and support vector regression*. IEEE, 2010. – ISBN 978-1-4244-7399-1
- [150] PENG, Huaiwu ; LIU, Fangrui ; YANG, Xiaofeng: A hybrid strategy of short term wind power prediction. In: *Renewable Energy* 50 (2013), S. 590–595
- [151] PÉREZ-LLERAA, C. ; FERNÁNDEZ-BAIZÁNB, M. C. ; FEITOC, J. L. ; VALLE, V. G.: Local Short-Term Prediction of Wind Speed: A Neural Network Analysis. In: *1st International Congress on Environmental Modelling and Software*, 2002, S. 124–129
- [152] PICTON, Philip: *Neural networks*. Basingstoke, Hampshire and New York : Palgrave, 2000 ([Grassroots series]). – ISBN 9780333802878
- [153] PINSON, P. ; JUBAN, J. ; KARINIOTAKIS, G. N.: On the Quality and Value of Probabilistic Forecasts of Wind Generation. In: *International Conference on Probabilistic Methods Applied to Power Systems, PMAPS 2006*, IEEE, 2006
- [154] PINSON, P. ; KARINIOTAKIS, G.: On-line assessment of prediction risk for wind power production forecasts. In: *Wind Energy* 7 (2004), Nr. 2, S. 119–132
- [155] PINSON, P. ; NIELSEN, H.Aa ; MADSEN, H. ; KARINIOTAKIS, G.: Skill forecasting from ensemble predictions of wind power. In: *Applied Energy* 86 (2009), Nr. 7-8, S. 1326–1334
- [156] PINSON, Pierre ; MADSEN, Henrik ; NIELSEN, Henrik A. ; PAPAETHYMIU, George ; KLÖCKL, Bernd: From probabilistic forecasts to statistical scenarios of short-term wind power production. In: *Wind Energy* 12 (2009), Nr. 1, S. 51–62
- [157] RAMIREZ-ROSADO, Ignacio J. ; FERNANDEZ-JIMENEZ, L. A. ; MONTEIRO, Cláudio ; SOUSA, João ; BESSA, Ricardo: Comparison of two new short-term wind-power forecasting systems. In: *Renewable Energy* 34 (2009), Nr. 7, S. 1848–1854
- [158] RAN, Li (Hrsg.) ; YONG-QIN, Ke (Hrsg.) ; XIAO-QIAN, Zhang (Hrsg.): *Forecasting of wind speed with least squares support vector machine based on genetic algorithm*. IEEE, 2011 . – ISBN 978-1-61284-458-9
-

- [159] RAUSCHENBACH, Thomas: Habilitationsschrift: Modellierung und Vorhersage nichtlinearer Zeitreihen. In: *at - Automatisierungstechnik* 54 (2006), Nr. 6_2006, S. 306–307
- [160] REN, Ye ; SUGANTHAN, P. N. ; SRIKANTH, N.: Ensemble methods for wind and solar power forecasting—A state-of-the-art review. In: *Renewable and Sustainable Energy Reviews* 50 (2015), S. 82–91. <http://dx.doi.org/10.1016/j.rser.2015.04.081>. – DOI 10.1016/j.rser.2015.04.081
- [161] RIEDMILLER, M. ; BRAUN, H.: A direct adaptive method for faster backpropagation learning: the RPROP algorithm. In: *IEEE International Conference on Neural Networks*, 28 March-1 April 1993, S. 586–591
- [162] RINNE, Horst: *Statistische Analyse multivariater Daten: Einführung*. München [u.a.] : Oldenbourg, 2000 (Lehr- und Handbücher der Statistik). – ISBN 3486254030
- [163] ROHRING, Kurt: *Rechenmodelle und Informationssysteme zur Integration großer Windleistungen in die elektrische Energieversorgung*. Kassel, Universität Kassel, Diss., 14.09.2003
- [164] ROULSTON, M.S ; KAPLAN, D.T ; HARDENBERG, J. ; SMITH, L.A: Using medium-range weather forecasts to improve the value of wind energy production. In: *Renewable Energy* 28 (2003), Nr. 4, S. 585–602
- [165] SACHS, Lothar: *Angewandte Statistik: Methodensammlung mit R*. Bd. 13., aktualisierte und erw. Aufl. Dordrecht : Springer, 2009. – ISBN 978-3-540-88901-4
- [166] SALCEDO-SANZ, Sancho ; PÉREZ-BELLIDO, Ángel M. ; ORTIZ-GARCÍA, Emilio G. ; PORTILLA-FIGUERAS, Antonio ; PRIETO, Luis ; CORREOSO, Francisco: Accurate short-term wind speed prediction by exploiting diversity in input data using banks of artificial neural networks. In: *Neurocomputing* 72 (2009), Nr. 4-6, S. 1336–1341
- [167] SALECK, Nadja ; BREMEN, Lueder v.: Wind power forecast error smoothing within a wind farm. In: *Journal of Physics: Conference Series* 75 (2007), Nr. 75, S. 012051
- [168] SÁNCHEZ, Ismael: Short-term prediction of wind energy production. In: *International Journal of Forecasting* 22 (2006), Nr. 1, S. 43–56
- [169] SÁNCHEZ, Ismael: Adaptive combination of forecasts with application to wind energy. In: *International Journal of Forecasting* 24 (2008), Nr. 4, S. 679–693
- [170] SANZ, S. S. ; PÉREZ-BELLIDO, Á. ; ORTIZ-GARCÍA, E. ; PORTILLA-FIGUERAS, A. ; PRIETO, L. ; PAREDES, D. ; CORREOSO, F.: Short-Term Wind Speed Prediction by Hybridizing Global and Mesoscale Forecasting Models with Artificial Neural Networks. In: XHAFA, Fatos (Hrsg.): *Eighth International Conference on Hybrid Intelligent Systems, 2008*, IEEE, 2008. – ISBN 978-0-7695-3326-1, S. 608–612
- [171] SCHLITTGEN, Rainer ; STREITBERG, Bernd H. J.: *Zeitreihenanalyse*. 9. München [u.a.] : Oldenbourg, 2001 (Lehr- und Handbücher der Statistik). – ISBN 3-486-25725-0
- [172] SCHWARZ, H.: North-East Germany, one of the most challenging regions of the world for the grid integration of renewable energies. In: BETANCOURT, U. (Hrsg.) ; ACKERMANN, Th (Hrsg.): *9th International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants: 18-19 October 2010*

-
- Québec City, Québec, Canada* Bd. 1, energynautics GmbH, 2010. – ISBN 978-3-9813870-2-5, S. 479-484
- [173] SFETSOS, A. ; SIRIOPOULOS, C.: Time Series Forecasting of Averaged Data With Efficient Use of Information. In: *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* 35 (2005), Nr. 5, S. 738-745
- [174] SHAN GAO ; YU HE ; HAO CHEN: Wind speed forecast for wind farms based on ARMA-ARCH model. In: *The 1st International Conference On Sustainable Power Generation And Supply: SUPERGEN '09., 6-7 April 2009*, Power Network Technology Press, 2009. – ISBN 978-1-4244-4934-7, S. 1-4
- [175] SHAO, Yichuan ; YAO, Xingjia: Cerebellar Model Controller Applied in Wind Power Prediction. In: *Physics Procedia* 25 (2012), S. 2304-2308
- [176] SHI, Jie ; DING, Zhaohao ; LEE, Wei-Jen ; YANG, Yongping ; LIU, Yongqian ; ZHANG, Mingming: Hybrid Forecasting Model for Very-Short Term Wind Power Forecasting Based on Grey Relational Analysis and Wind Speed Distribution Features. In: *IEEE Transactions on Smart Grid* 5 (2014), Nr. 1, S. 521-526
- [177] SHUHUI LI ; WUNSCH, D.C ; O'HAIR, E.A ; GIESSELMANN, M.G: Using neural networks to estimate wind turbine power generation. In: *IEEE Transactions on Energy Conversion* 16 (2001), Nr. 3, S. 276-282
- [178] SIDERATOS, G. ; HATZIARGYRIOU, N. D.: Probabilistic Wind Power Forecasting Using Radial Basis Function Neural Networks. In: *IEEE Transactions on Power Systems* 27 (2012), Nr. 4, 1788-1796. <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6172635>. – Online: 06.11.2017
- [179] SIDERATOS, G. ; HATZIARGYRIOU, N. D.: Wind Power Forecasting Focused on Extreme Power System Events. In: *IEEE Transactions on Sustainable Energy* 3 (2012), Nr. 3, S. 445-454
- [180] SIDERATOS, G. ; HATZIARGYRIOU, N.D: An Advanced Statistical Method for Wind Power Forecasting. In: *IEEE Transactions on Power Systems* 22 (2007), Nr. 1, S. 258-265
- [181] SREELAKSHMI, K. ; KUMAR, P. R.: Performance Evaluation of Short Term Wind Speed Prediction Techniques. In: *IJCSNS International Journal of Computer Science and Network Security* (2008), Nr. 8-8, S. 162-169
- [182] SREELAKSHMI, K. ; RAMAKANTHKUMAR, P.: Neural Networks for Short Term Wind Speed Prediction. In: *World Academy of Science, Engineering and Technology* (2008), Nr. 42, S. 721-725
- [183] TASCIKARAOGLU, A. ; UZUNOGLU, M. ; VURAL, B.: The assessment of the contribution of short-term wind power predictions to the efficiency of stand-alone hybrid systems. In: *Applied Energy* 94 (2012), S. 156-165
- [184] TATSUOKA, Maurice M. ; LOHNES, Paul R.: *Multivariate analysis: Techniques for educational and psychological research*. 2. New York : Macmillan, 1988. – ISBN 0024191205
- [185] TAYLOR, James W. ; MCSHARRY, Patrick E. ; BUIZZA, Roberto: Wind Power Density Forecasting Using Ensemble Predictions and Time Series Models. In: *IEEE Transactions on Energy Conversion* 24 (2009), Nr. 3, S. 775-782
-

- [186] THINIUS, Dr Ing B.: *Adaptives Windleistungsprognosesystem für Windenergieanlagen*. <http://www.toss.de/content/download/windprog.pdf>. Version: 2003. – Online: 06.11.2017
- [187] TOGELOU, A. ; SIDERATOS, G. ; HATZIARGYRIOU, N. D.: Wind Power Forecasting in the Absence of Historical Data. In: *IEEE Transactions on Sustainable Energy* 3 (2012), Nr. 3, S. 416–421
- [188] TORRES, J.L ; GARCÍA, A. ; BLAS, M. d. ; FRANCISCO, A. d.: Forecast of hourly average wind speed with ARMA models in Navarre (Spain). In: *Solar Energy* 79 (2005), Nr. 1, S. 65–77
- [189] TRÖSTER, E. ; KUWAHATA, R. ; ACKERMANN, Th ; GREENPEACE (Hrsg.): *Battle of the Grids: How Europe can go 100 % renewable and phase out dirty energy: Report 2011*. 2011
- [190] TSENG, Yu-Heng ; DURBIN, Paul ; TZENG, Gwo-Hshiong: Using a Fuzzy Piecewise Regression Analysis to Predict the Nonlinear Time-Series of Turbulent Flows with Automatic Change-Point Detection. In: *Flow, Turbulence and Combustion* 67 (2001), Nr. 2, S. 81–106
- [191] TURBELIN, Grégory ; NGAË, Pierre ; GRIGNON, Michel: Wavelet cross-correlation analysis of wind speed series generated by ANN based models. In: *Renewable Energy* 34 (2009), Nr. 4, S. 1024–1032
- [192] WANG, Ruigang (Hrsg.) ; LI, Wenyi (Hrsg.) ; BAGEN, B. (Hrsg.): *Development of Wind Speed Forecasting Model Based on the Weibull Probability Distribution*. IEEE, 2011 . – ISBN 978-1-61284-278-3
- [193] WANG, Xiaochen ; GUO, Peng ; HUANG, Xiaobin: A Review of Wind Power Forecasting Models. In: *Energy Procedia* 12 (2011), S. 770–778
- [194] WATTERS, Christophe S. (Hrsg.) ; LEAHY, Paul (Hrsg.): *Comparison of linear, Kalman filter and neural network downscaling of wind speeds from numerical weather prediction*. IEEE, 2011. – ISBN 978-1-4244-8779-0
- [195] WERNSTEDT, Jürgen: *Experimentelle Prozessanalyse*. 1. Berlin : Verl. Technik, 1989. – ISBN 3341006761
- [196] WI, Young-Min ; JOO, Sung-Kwan ; SONG, Kyung-Bin: Holiday Load Forecasting Using Fuzzy Polynomial Regression With Weather Feature Selection and Adjustment. In: *IEEE Transactions on Power Systems* 27 (2012), Nr. 2, S. 596–603
- [197] WIND ENERGY: Wind energy literature survey no. 8. In: *Wind Energy* 11 (2008), Nr. 3, S. 297–304
- [198] WU, J. L. ; JI, T. Y. ; LI, M. S. ; WU, P. Z. ; WU, Q. H.: Multistep Wind Power Forecast Using Mean Trend Detector and Mathematical Morphology-Based Local Predictor. In: *IEEE Transactions on Sustainable Energy* (2015), S. 1–8
- [199] XU, Qian Yao ; HE, Dawei ; ZHANG, Ning ; KANG, Chongqing ; XIA, Qing ; BAI, Jianhua ; HUANG, Junhui: A Short-Term Wind Power Forecasting Approach With Adjustment of Numerical Weather Prediction Input by Data Mining. In: *IEEE Transactions on Sustainable Energy* (2015), S. 1–9
- [200] YAN, Jie ; LIU, Yongqian ; HAN, Shuang ; WANG, Yimei ; FENG, Shuanglei: Reviews

- on uncertainty analysis of wind power forecasting. In: *Renewable and Sustainable Energy Reviews* 52 (2015), S. 1322–1330. <http://dx.doi.org/10.1016/j.rser.2015.07.197>. – DOI 10.1016/j.rser.2015.07.197
- [201] YANG, Lei ; HE, Miao ; ZHANG, Junshan ; VITTAL, Vijay: Support-Vector-Machine-Enhanced Markov Model for Short-Term Wind Power Forecast. In: *IEEE Transactions on Sustainable Energy* 6 (2015), Nr. 3, S. 791–799
- [202] YANG, Ming ; FAN, Shu ; LEE, Wei-Jen: Probabilistic Short-Term Wind Power Forecast Using Componential Sparse Bayesian Learning. In: *IEEE Transactions on Industry Applications* 49 (2013), Nr. 6, S. 2783–2792
- [203] ZAREIPOUR, Hamidreza ; HUANG, Dongliang ; ROSEHART, William: Wind power ramp events classification and forecasting: A data mining approach. In: *2011 IEEE Power and Energy Society General Meeting*, IEEE, 2011. – ISBN 978-1-4577-1000-1, S. 1–3
- [204] ZENG, Jianwu ; QIAO, Wei: *Support vector machine-based short-term wind power forecasting*. IEEE, 2011. – ISBN 978-1-61284-789-4
- [205] ZENG, Jianwu ; QIAO, Wei: Short-Term Wind Power Prediction Using a Wavelet Support Vector Machine. In: *IEEE Transactions on Sustainable Energy* 3 (2012), Nr. 2, S. 255–264
- [206] ZHANG, Qian ; LAI, Kin K. ; NIU, Dongxiao ; WANG, Qiang: Wind Park Power Forecasting Models and Comparison. In: *2012 Fifth International Joint Conference on Computational Sciences and Optimization*, IEEE, 2012. – ISBN 978-1-4673-1365-0, S. 27–31
- [207] ZHAO, Pan ; WANG, Jiangfeng ; XIA, Junrong ; DAI, Yiping ; SHENG, Yingxin ; YUE, Jie: Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China. In: *Renewable Energy* 43 (2012), S. 234–241
- [208] ZHAO MINGHAO ; JIANG DONGXIANG ; LIU CHAO: Research on wind power forecasting method using phase space reconstruction and artificial neural network. In: *The 1st International Conference On Sustainable Power Generation And Supply: SUPERGEN '09., 6-7 April 2009*, Power Network Technology Press, 2009. – ISBN 978-1-4244-4934-7, S. 1–5
- [209] ZHENG, Z.W ; CHEN, Y.Y ; HUO, M.M ; ZHAO, B.: An Overview: the Development of Prediction Technology of Wind and Photovoltaic Power Generation. In: *Energy Procedia* 12 (2011), S. 601–608
- [210] ZHOU, H. ; JIANG, J. X. ; HUANG, M.: Short-term wind power prediction based on statistical clustering. In: ZHOU, H. (Hrsg.) ; JIANG, J. X. (Hrsg.) ; HUANG, M. (Hrsg.): *Short-term wind power prediction based on statistical clustering*, IEEE, 2011. – ISBN 978-1-4577-1000-1, S. 1–7
- [211] ZHOU, H. (Hrsg.) ; JIANG, J. X. (Hrsg.) ; HUANG, M. (Hrsg.): *Short-term wind power prediction based on statistical clustering*. IEEE, 2011. – ISBN 978-1-4577-1000-1
- [212] ZHU, He ; XU, Jianyuan ; WANG, Xiaoyu: The output forecast research of the wind farm based on GM-weibull wind speed distribution combined model. In: *4th IEEE Conference on Industrial Electronics and Applications, 2009*, IEEE, 2009. – ISBN 9781424427994, S. 2137–2140

Erklärung

Ich versichere, dass ich die vorliegende Arbeit ohne unzulässige Hilfe Dritter und ohne Benutzung anderer als der angegebenen Hilfsmittel angefertigt habe. Die aus anderen Quellen direkt oder indirekt übernommenen Daten und Konzepte sind unter Angabe der Quelle gekennzeichnet.

Bei der Auswahl folgenden Materials haben mir die nachstehenden aufgeführten Personen in der jeweils beschriebenen Weise unentgeltlich geholfen:

1. Stefan König: Masterarbeit mit Titel: Vorhersage der Windenergie; Im Rahmen der Arbeit wurden Grundlagen zur Systemmodellbildung und stochastischen Modellbildung aufgearbeitet, die bei der Erstellung dieser Arbeit berücksichtigt wurden.

Weitere Personen waren an der inhaltlichen-materiellen Erstellung der vorliegenden Arbeit nicht beteiligt. Insbesondere habe ich hierfür nicht die entgeltliche Hilfe von Vermittlungs- bzw. Beratungsdiensten (Promotionsberater oder anderer Personen) in Anspruch genommen. Niemand hat von mir unmittelbar oder mittelbar geldwerte Leistungen für Arbeiten erhalten, die im Zusammenhang mit dem Inhalt der vorgelegten Dissertation stehen.

Die Arbeit wurde bisher weder im In- noch im Ausland in gleicher oder ähnlicher Form einer Prüfungsbehörde vorgelegt.

Ich bin darauf hingewiesen worden, dass die Unrichtigkeit der vorstehenden Erklärung als Täuschungsversuch bewertet und gemäß § 7 Abs. 10 der Promotionsordnung den Abbruch des Promotionsverfahrens zur Folge hat.

Arnstadt, 07.11.2017

Alexander Arnoldt