

Analyse, Identifikation und Prognose preisbeeinflusster elektrischer Lastzeitreihen

Dissertation

zur Erlangung des akademischen Grades
Doktoringenieur (Dr.-Ing.)

vorgelegt der Fakultät für Elektrotechnik und
Informationstechnik der Technischen Universität Ilmenau

von Dipl.-Ing. Stefan Klaiber

1. Gutachter: Univ.-Prof. Dr.-Ing. Peter Bretschneider
2. Gutachter: Univ.-Prof. Dr.-Ing. Dirk Westermann
3. Gutachter: Prof. Dr.-Ing. Ralf Mikut

Tag der Einreichung: 08.03.2019

Tag der wissenschaftlichen Aussprache: 20.11.2019

Vorwort

Die vorliegende Dissertation entstand in meiner Zeit als wissenschaftlicher Mitarbeiter am Fraunhofer IOSB-AST in Ilmenau. Mein Dank gilt daher zuerst meinem Arbeitgeber für die Möglichkeit der Promotion im Rahmen eines spannenden Forschungsthemas.

Besonders möchte ich mich bei Prof. Dr.-Ing. Peter Bretschneider für die fachliche Betreuung bei der Erstellung der Arbeit sowie für die Diskussionsbereitschaft und für die konstruktive Kritik bedanken. Weiterhin möchte ich Prof. Dr.-Ing. Dirk Westermann und apl. Prof. Dr. Ralf Mikut meinen herzlichen Dank für die hilfreichen Ratschläge und die fachliche Unterstützung aussprechen.

Zudem danke ich meinen Kollegen für die wertvollen Diskussionen, den offenen und vertrauensvollen Austausch und die stets freundschaftliche Atmosphäre.

Ganz besonders möchte ich mich bei meinen Eltern und meiner Familie bedanken, die mir stets ein großer Rückhalt waren. Insbesondere gilt mein Dank meiner Frau Katharina für ihre Unterstützung und Motivation sowie meinen Kindern Neo und Zoe, die mir in der für mich in beruflicher und privater Hinsicht ereignisreichen Zeit während der Promotion wesentliche Dinge des Lebens gelehrt haben.

Ilmenau, den 01.03.2019

Stefan Klaiber

Kurzfassung

Durch die Beeinflussung der Lastzeitreihe mittels Anreiz- bzw. Preiszeitreihen (Demand Side Management) können zusätzliche Flexibilitätpotenziale für den Ausgleich von Erzeugung und Verbrauch im elektrischen Energiesystem erschlossen werden. Allerdings werden dadurch die bisher unbeeinflussten Verbrauchsmuster verändert. Damit einhergehend ist eine steigende Unsicherheit bei der Verbrauchsprognose zu beobachten, was die Untersuchungen der vorliegenden Arbeit auch belegen. Für eine sichere Versorgung und Planbarkeit muss zukünftig auch derart beeinflusstes Verbrauchsverhalten mit höchster Qualität prognostizierbar sein. Die vorliegende Dissertation leistet einen Beitrag zur Analyse und Vorhersage von Lastzeitreihen unter Berücksichtigung preisbasierter Verbrauchsbeeinflussung. Ziel war die Entwicklung eines Gesamtkonzepts für die Analyse, den Entwurf und die Vorhersage von beeinflusstem Verbrauchsverhalten. Die entwickelte neuartige Prognosemethode weist gegenüber etablierten Methoden der Lastprognose neben einer erheblich verbesserten Vorhersagequalität einen weiteren signifikanten Vorteil auf. Mit der Prognosemethode ist es auf Grundlage historischer Daten beeinflusster Verbraucher oder Verbrauchergruppen möglich, neben der Prognose von beeinflusstem Verbrauchsverhalten auch auf das unbeeinflusste Verbrauchsverhalten zu schließen und dieses vorherzusagen. Die Prognose und die damit vollzogene Dekomposition der beeinflussten Verbrauchskurve in den beeinflussten und unbeeinflussten Anteil ist der Ausgangspunkt für die Planung und Preisbildung im Rahmen von Demand Response. Denn nur auf der Grundlage des zu erwartenden Verbrauchs ohne den Preiseinfluss kann abgeschätzt werden, zu welchem Zeitpunkt und mit welchem Ausmaß die Verbraucher mit Hilfe eines zu setzenden Preises zu beeinflussen sind. Die Entwicklung der neuartigen Prognosemethode stützt sich auf einen umfangreich recherchierten und aufbereiteten Stand des Wissens, der systemtechnisch aufgearbeiteten Problemstellung beim Zusammenspiel von Planung, Preisbildung, Verbrauchern und der Prognose sowie der Analyse der Charakteristik von preisbeeinflusstem Verbrauchsverhalten. Die Projekte

- „Prognose und Betriebsführung in Verteilnetzen mit anreizbasierter Verbrauchsbeeinflussung und fluktuierender Einspeisung“ (gefördert durch die Deutsche Forschungsgemeinschaft - BR 4241/2-1),
- „REGES - Optimale Betriebs- und Regelungsstrategien für das zuverlässige elektrische Energieversorgungssystem Deutschlands bei vollständiger Integration der Einspeisung aus erneuerbaren Energien im Zeithorizont 2030“ (gefördert durch das Bundesministerium für Wirtschaft und Energie - 0325779A) sowie
- diverse Industrieprojekte im Zusammenhang mit der Softwarelösung EMS-EDM PRO-PHET

bildeten den Untersuchungsrahmen der hier vorliegenden Arbeit.

Abstract

Influencing of consumption behaviour of consumers by means of incentive or price time series (demand side management) can open up additional flexibility potentials for balancing generation and consumption in an electric energy system. Consumption patterns of previously uninfluenced consumers are, however, changed by this influence and the uncertainty in consumption forecast increases. A reliable supply and predictability in the future requires a sufficiently good forecast quality of consumption behaviour influenced in this way. This present dissertation is intended to contribute to the forecast of price-influenced load time series. The aim was to develop an overall concept for the analysis, design and forecast of influenced consumption behaviour. The newly developed forecasting method has significant advantages over established load forecasting methods. On the one hand, it shows a significantly improved forecasting quality. On the other hand, the forecast method makes it possible, on the basis of historical data from influenced consumers or consumer groups, to conclude and forecast not only the influenced consumption behaviour but also the uninfluenced consumption behaviour. The forecast and the resulting decomposition of the influenced consumption curve into the influenced and uninfluenced component is the sensible starting point for planning and pricing in the context of demand response. To estimate the schedule and the extent of the influence is only possible based on the forecasted uninfluenced consumer behaviour. The development of the new forecasting method is based on an extensively researched and refurbished state of knowledge, the problem definition in the interplay of planning, pricing, consumers and forecasting and the analysis of the characteristics of price-influenced consumption behaviour. The projects

- „Prognose und Betriebsführung in Verteilnetzen mit anreizbasierter Verbrauchsbeeinflussung und fluktuierender Einspeisung“ (funded by the Deutsche Forschungsgemeinschaft - BR 4241/2-1)
- „REGES - Optimale Betriebs- und Regelungsstrategien für das zuverlässige elektrische Energieversorgungssystem Deutschlands bei vollständiger Integration der Einspeisung aus erneuerbaren Energien im Zeithorizont 2030“ (funded by the Federal Ministry for Economic Affairs and Energy - 0325779A) sowie
- Various industrial projects in the context of the software solution EMS-EDM PROPHET

formed the scope of the present dissertation thesis.

Inhaltsverzeichnis

Vorwort	I
Kurzfassung	II
Abstract	III
Inhaltsverzeichnis.....	IV
Abbildungsverzeichnis	VII
Tabellenverzeichnis.....	X
Formelzeichen.....	XI
Definitionen	XIII
1 Einleitung	1
1.1 Motivation	1
1.2 Aufbau der Arbeit	3
1.3 Problembeschreibung	3
1.4 Zielstellung der Arbeit	5
2 Stand des Wissens.....	7
2.1 Beeinflussung der Verbraucherseite - Demand Side Management	7
2.1.1 Herausforderung für den Einsatz von Demand Side Management	7
2.1.2 Kategorisierung	8
2.1.3 Lastbeeinflussungspotenziale von Demand Side Management.....	11
2.1.4 Beschreibungsansätze für die Beeinflussung durch Demand Response	12
2.1.5 Zusammenfassung und wichtigste Erkenntnisse	14
2.2 Analyse	15
2.2.1 Optimale Prognose	15
2.2.2 Methoden der Zeitreihenanalyse	17
2.2.3 Zusammenfassung und wichtigste Erkenntnisse	19
2.3 Vorhersage.....	20
2.3.1 Ansätze zur Zeitreihenmodellierung	20
2.3.2 Zusammenfassung und wichtigste Erkenntnisse	31
3 Preisbeeinflusstes Verbrauchsverhalten	33
3.1 Einsatzgebiete für neue Prognosemethoden	33
3.2 Systemtechnische Betrachtung.....	34
3.3 Charakteristik der unbeeinflussten Lastkomponente	39

3.4	Charakteristik der preissensitiven Lastkomponente	40
3.4.1	Preiselastizität	40
3.4.2	Speicherverhalten bei Lastverschiebung.....	42
3.4.3	Auswirkungen des Planungshorizonts.....	43
3.4.4	Zeitversetzte Verbraucherreaktion	44
3.5	Relevante Methoden zur Analyse der Verbrauchscharakteristik	46
3.6	Zusammenfassung und wichtigste Erkenntnisse	50
4	Konzept und Entwurf der Prognosemethode	53
4.1	Vorgehenskonzept für die Prognose beeinflusster Zeitreihen	53
4.2	Modellierung von preissensitivem Verbrauchsverhalten	55
4.2.1	Modellansatz für die beeinflusste Zeitreihenkomponente (TMR)	56
4.2.2	Modellansatz für die unbeeinflusste Zeitreihenkomponente (TMU)	60
4.3	Vorhersagestrategie und Konzept für die Anwendung der Prognose	62
4.3.1	Das Konzept von globaler und lokaler Prognose.....	62
4.3.2	Ermittlung der Klassenkonfiguration.....	67
4.4	Vorhersagesystem für preisbeeinflusste Zeitreihen	70
4.4.1	Aufbau des Vorhersagesystems	70
4.4.2	Modellbasierte Dekomposition.....	74
4.4.3	Alternative Strategie der Dekomposition.....	80
4.4.4	Ablauf bei der Anwendung des Vorhersagesystems.....	81
4.5	Zusammenfassung und wichtigste Erkenntnisse	84
5	Evaluierung des Lösungskonzeptes	89
5.1	Datengrundlage.....	89
5.1.1	Synthetischer Datensatz und Zeitreihengenerator für Energiezeitreihen	89
5.1.2	Real gemessener Datensatz aus dem „Olympic Peninsula Project“	92
5.2	Validierungsstrategie.....	93
5.2.1	Untersuchungsszenarien	94
5.2.2	Fehlermaße und optimale Prognose	96
5.3	Anwendung des Vorhersagesystems für beeinflusste Zeitreihen	98
5.3.1	Zeitreihenanalyse und Modellkonfiguration	98
5.3.2	Ergebnisse.....	111
5.4	Zusammenfassung und wichtigste Erkenntnisse	126
6	Zusammenfassung und Ausblick	128

6.1	Erkenntnisse der vorliegenden Arbeit	128
6.2	Ausblick auf weiteren Forschungsbedarf	130
7	Literaturverzeichnis	132
Anhang	141
Anhang A:	Methoden der Datenanalyse	141
Anhang B:	Parametervorgaben für synthetische Zeitreihen	152
Anhang C:	Analyse der Klassenkonfiguration.....	157

Abbildungsverzeichnis

Abbildung 1.1:	Problemstellung Demand Side Management.....	5
Abbildung 2.1:	Unterteilung von Demand Side Management (modifiziert nach [4], [9], [29])	9
Abbildung 2.2:	Strategien beim Demand Side Management Programmen (modifiziert nach [3])	9
Abbildung 2.3:	Kategorisierung von Demand Side Management Programmen (modifiziert nach [68], [5], [8], [9], [29], [79], [117])	11
Abbildung 2.4:	Systemtechnische Darstellung eines Verbrauchsprozesses und eines Modells zur Beschreibung des Verbrauchsverhaltens (modifiziert nach [14])	15
Abbildung 2.5:	Systematisierung von Ansätzen zur Zeitreihenmodellierung.....	21
Abbildung 3.1:	Systemtechnisch aufgearbeitetes Gesamtkonzept, bestehend aus beeinflusstem Verbrauchsprozess, Prognosemodell und Betriebsplanungsinstanz (modifiziert nach [59], [68])	35
Abbildung 3.2:	Typische Nachfragekurve (modifiziert nach [74] und [77])	41
Abbildung 3.3:	Zeitversetzte Reaktion der Verbraucher auf Preisevents	44
Abbildung 3.4:	Darstellung des Verarbeitungsworkflows für die Analyse von Lastzeitreihen nach [15]	49
Abbildung 3.5:	Darstellung des Verarbeitungsworkflows für die Auswertung der Residuen.....	50
Abbildung 4.1:	Grobkonzept für Analyse und Entwurf (modifiziert nach [15], [68], [112])	53
Abbildung 4.2:	Beispielhafte Darstellung für Preisvarianz in gleitendem Zeitfenster	60
Abbildung 4.3:	Einschrittmodell laut [15]	62
Abbildung 4.4:	Mehrschrittmodell laut [15].....	62
Abbildung 4.5:	Exemplarische Darstellung der Häufigkeitsverteilung (Histogramm) für klassen- und uhrzeitspezifische Beispielzeitreihe.....	64
Abbildung 4.6:	Klassenbezogenes und uhrzeitabhängiges Mehrschrittmodell	65
Abbildung 4.7:	Uhrzeitabhängiges Mehrschrittmodell	65
Abbildung 4.8:	Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung für die Vorhersage	66
Abbildung 4.9:	Analyse zur Ermittlung der Klassenkonfiguration für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung mit Zerlegung in n Klassen und für eine Abtastzeit von 15 Minuten mit $n \times 96$ Datensätzen in Anlehnung an [15]	68
Abbildung 4.10:	Vorhersagesystem für beeinflusste Zeitreihen (modifiziert nach [15])	71
Abbildung 4.11:	Vorhersagesystem mit Linearisierungskomponente (modifiziert nach [15], [94])	72
Abbildung 4.12:	Modellumschaltung nach [15].....	73
Abbildung 4.13:	Vorhersagesystem mit Nebenbedingungsmodell und Parameterschätzverfahren	74
Abbildung 4.14:	Grafische Darstellung der Modellgleichung	75
Abbildung 4.15:	Exemplarische Darstellung der Wirkweise der Nebenbedingung.....	77
Abbildung 4.16:	Exemplarisches Beispiel für die Berechnung der maximal möglichen Laständerung für die Nebenbedingungsfunktion	79
Abbildung 4.17:	Optimales Prognosemodell	80
Abbildung 4.18:	Prognosemodell ohne Berücksichtigung des Preises (modifiziert nach [61]).....	81
Abbildung 4.19:	Ablauf der modellbasierten Dekomposition und Prognose	83
Abbildung 4.20:	Ablauf der Prognose für Vorhersageintervall $\Delta T_{prog} = k + 1, \dots, k + 96$	84
Abbildung 4.21:	Vereinfachte Darstellung des Ablaufs der Methodenanwendung und Zusammenfassung der Elemente des Methodenentwurfs	88

Abbildung 5.1:	Beispiel-Heatmap-Darstellung der individuellen Besetzung der Matrix Z_c für Typtag von $c = \text{Montag}$	90
Abbildung 5.2:	Rollierende Prognose mit einem Vorhersagehorizont $H = 1, \dots, 96$ Abtastschritten im 15-Minuten-Zyklus	93
Abbildung 5.3:	Beispiel für Periodogrammtest für die Realisierung eines weißen Rauschens als Prüfgröße	98
Abbildung 5.4:	Verlauf der normierten Lastzeitreihen $y[k]$ des synthetischen Datensatzes über 2 Wochen	99
Abbildung 5.5:	Autokorrelationsfunktion der Lastzeitreihen $y[k]$ des synthetischen Datensatzes	99
Abbildung 5.6:	Partielle Autokorrelationsfunktion der Lastzeitreihe $y[k]$ des synthetischen Datensatzes	100
Abbildung 5.7:	Hauptkomponentenanalyse der Lastzeitreihe $y[k]$ des synthetischen Datensatzes ...	100
Abbildung 5.8:	Punktwolke/x-y-Darstellung von Preis $p[k]$ (x-Achse) der Lastzeitreihe $y[k]$ (y-Achse) des synthetischen Datensatzes	101
Abbildung 5.9:	Kreuzkorrelationsfunktion von Preis $p[k]$ und Lastzeitreihe $y[k]$ des synthetischen Datensatzes	101
Abbildung 5.10:	Bestimmung der optimalen Fenstergröße zur Berechnung der Preisvarianz.	102
Abbildung 5.11:	Zusammenfassung des Kreuzvergleichs der Verteilungen aus Anhang C für die Ermittlung der Klassenzuordnung	103
Abbildung 5.12:	Verlauf der normierten Lastzeitreihe $y[k]$ des real gemessenen Datensatzes über 2 Wochen	106
Abbildung 5.13:	Autokorrelationsfunktion der Lastzeitreihe $y[k]$ des real gemessenen Datensatzes...	106
Abbildung 5.14:	Partielle Autokorrelationsfunktion der Lastzeitreihe $y[k]$ des real gemessenen Datensatzes	107
Abbildung 5.15:	Hauptkomponentenanalyse der Lastzeitreihe $y[k]$ des real gemessenen Datensatzes	107
Abbildung 5.16:	Punktwolke/x-y-Darstellung von Preis $p[k]$ (x-Achse) der Lastzeitreihe $y[k]$ (y-Achse) des real gemessenen Datensatzes	108
Abbildung 5.17:	Kreuzkorrelationsfunktion von Preis $p[k]$ und Lastzeitreihe $y[k]$ des real gemessenen Datensatzes	108
Abbildung 5.18:	Bestimmung der optimalen Fenstergröße zur Berechnung der Preisvarianz.	109
Abbildung 5.19:	Ermittlung der Klassenzuordnung für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung in Abhängigkeit von Typtagen und Uhrzeitindex $h = 1 \dots 96$ (15 Minutenwerte)	110
Abbildung 5.20:	Vergleich der mittleren Tageskurven von $y[k]$, $y[k]$ sowie $p[k]$ für Referenzszenarien über Testdaten.	112
Abbildung 5.21:	Standardabweichung von $e[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für Referenzszenarien über Testdaten	112
Abbildung 5.22:	Histogramm von $e[k]$ für verschiedene Vorhersagehorizonte H für Referenzszenarien über Testdaten	113
Abbildung 5.23:	Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest von $e[k]$ für $H = 1$ für Referenzszenarien über Testdaten	113
Abbildung 5.24:	Vergleich der mittleren Tageskurven von $y_u[k]$, $y_u[k]$, und $y[k]$ sowie $p[k]$ für Testszenarien über Testdaten	114
Abbildung 5.25:	Vergleich der mittleren Tageskurven von $y_R[k]$, $y_R[k]$ sowie $p[k]$ für Testszenarien über Testdaten	115
Abbildung 5.26:	Standardabweichung von $e[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für die Testszenarien über Testdaten	116

Abbildung 5.27:	Histogramme von $e[k]$ für verschiedene Vorhersagehorizonte H für die Testszenarien über Testdaten	116
Abbildung 5.28:	Standardabweichung von $e_U[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für die Testszenarien über Testdaten	117
Abbildung 5.29:	Standardabweichung von $e_R[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für die Testszenarien über Testdaten	117
Abbildung 5.30:	Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest von $e[k]$ für Vorhersagehorizont $H = 1$ für Testszenarien über Testdaten	118
Abbildung 5.31:	Durchschnittliche Fehlermaße für $e[k]$ des synthetischen Datensatzes für Untersuchungsszenarien über Testdaten	119
Abbildung 5.32:	Durchschnittliche Fehlermaße für $e_U[k]$ und $e_R[k]$ für die Testszenarien (synthetischer Datensatz) über Testdaten	120
Abbildung 5.33:	Standardabweichung für $e[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für Referenz- und Testszenarien (synthetischer Datensatz) über Testdaten	121
Abbildung 5.34:	Vergleich der mittleren Tageskurven von $y[k]$, $\hat{y}[k]$ sowie $p[k]$ für Referenzszenarien und das Testszenario über Testdaten	122
Abbildung 5.35:	Verlauf der mittleren Tageskurve von $y_R[k]$ sowie $p[k]$ für das Testszenario über Testdaten	122
Abbildung 5.36:	Histogramme von $e[k]$ für verschiedene Vorhersagehorizonte H für Referenzszenarien und das Testszenario über Testdaten	123
Abbildung 5.37:	Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest für $e[k]$ für Vorhersagehorizont $H = 1$ für Testszenarien über Testdaten	124
Abbildung 5.38:	Durchschnittliche Fehlermaße für $e[k]$ für Referenzszenarien und Testszenario für den real gemessenen Datensatz über Testdaten	125
Abbildung 5.39:	Standardabweichung für $e[k]$ in Abhängigkeit des Vorhersagehorizontes $H = 1, \dots, 96$ für Referenzszenarien und Testszenario (real gemessener Datensatz) über Testdaten ...	126

Tabellenverzeichnis

Tabelle 2.1:	Lastverschiebepotenzial bei indirektem DSM	12
Tabelle 2.2:	Überblick von Beschreibungsansätze für Demand Response.....	13
Tabelle 2.3:	Überblick über Methoden der Datenanalyse	18
Tabelle 2.4:	Auswahl von Kombination von hybriden Modellansätzen	30
Tabelle 2.5:	Überblick von Ansätze zur Zeitreihenmodellierung.....	31
Tabelle 3.1:	Analysemethoden und Identifikation relevanter Informationen für die Modellbildung...	46
Tabelle 5.1:	Bei der Modellierung verwendete Zeitreihenkomponenten und deren Ausprägungen (erweitert nach [149]).....	91
Tabelle 5.2:	In Untersuchungsszenarien angewendete Methoden und Modellierungsspezifika.....	95
Tabelle 5.3:	Fehlermaße für $e[k]$ des synthetischen Datensatzes für Untersuchungsszenarien über Testdaten	119
Tabelle 5.4:	Fehlermaße für Untersuchungsszenarien für $e_U[k]$ und $e_R[k]$ über Testdaten	120
Tabelle 5.5:	Fehlermaße für Untersuchungsszenarien für $e[k]$ für den real gemessenen Datensatz über Testdaten	125

Formelzeichen

Im Rahmen der Arbeit werden ausschließlich äquidistante Zeitreihen besprochen. Eine zeitdiskrete Zeitreihe wird folgendermaßen dargestellt:

$$x[kT_S]$$

mit: k - Index des Zeitpunktes und
 T_S - Abtastzeit.

Diese wird im Weiteren vereinfacht als $x[k]$ oder x_k dargestellt.

Allgemeine Regeln:

- Es wird zwischen zeitkontinuierlichen $x(k)$ und zeitdiskreten $x[k]$ Zeitreihen unterschieden.
- Das Symbol \hat{x} zeigt an, dass es sich um eine Schätzung für x handelt.
- Ein \bar{x} bedeutet in der Statistik einen (zeitlichen) Mittelwert für x .
- Sofern nicht anderweitig vermerkt, kennzeichnen fett gedruckte Großbuchstaben Matrizen, fett gedruckte Kleinbuchstaben Vektoren und normal gesetzte Zeichen in Symbolen skalare Werte.

α	- Irrtumswahrscheinlichkeit
δ, β, η	- Parameter
c	- Klassenindex mit $c = 1, \dots, C$ Klassen
d	- Index des Tages
$\mathbf{d}_{c,h}[k]$	- Entscheidungsvektor für Klassenindex c und Uhrzeitindex h zum Zeitpunkt kT_S
$\varepsilon[k]$	- weißes Rauschen zum Zeitpunkt kT_S
ζ	- Preiselastizität
$\zeta_{max,c,h}$	- maximalen Ausprägung der Preiselastizität in Abhängigkeit der Klasse c und des Uhrzeitindex h
\mathbf{Z}	- Preiselastizitätsmatrix
$\mathbf{e}[k]$	- Fehlerzeitreihe zum Zeitpunkt kT_S
F	- Verteilungsfunktion
h	- Uhrzeitindex mit $h = 1, \dots, D$
H	- Vorhersagehorizont
k	- Index des Zeitpunktes
k_0	- erster Abtastpunkt im Betrachtungsintervall (aktueller Zeitindex)

K	- Anzahl der Abtastpunkte im Betrachtungsintervall $\Delta T = 1 \dots K$
∇^d	- Differenzenfilter d -ter Ordnung
∇_τ^d	- Differenzenfilter d -ter Ordnung mit dem Backshift-Operator τ
MAE	- mittlerer absoluter Fehler
ME	- mittlerer Fehler
MSE	- mittlerer quadratischer Fehler
$p[k]$	- Anreiz- bzw. Preiszeitreihe zum Zeitpunkt kT_S
$\overline{\Delta p}_{c,h}$	- mittleren Preisänderung für Klassenindex c und Uhrzeitindex h im Vergleich zum Initial- bzw. Referenzpreis p_{init}
p_{init}	- Initial- bzw. Referenzpreis
Q_{95}	- 95%-Quantil
Q_{05}	- 5%-Quantil
$\mathbf{s}[k]$	- Situationsvektor zum Zeitpunkt kT_S
s_r	- kumuliertes Periodogramm
STD	- Standardabweichung des Prognosefehlers
$\sigma_p^2[\Delta k]$	- Varianz der Preiszeitreihe in einem gleitenden relativen Zeitfenster Δk
τ	- Backshift-Operator eines Differenzenfilters
ΔT	- Betrachtungsintervall
T_S	- Abtastzeit
$\mathbf{u}[k]$	- Vektor verschiedener Einflussgrößen
$\mathbf{u}_{EES}[k]$	- Eingangsvektor des elektrischen Energiesystems
y_{init}	- Initial- bzw. Referenzverbrauch
$y_M[k]$	- Musterkomponente einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$y_P[k]$	- periodische Komponente einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$y_{ref}[k]$	- Referenzwert für $y[k]$ zum Zeitpunkt kT_S
$y_{R,max}$	- maximal mögliche Laständerung
$y_R[k]$	- beeinflusste Zeitreihenkomponente (bzw. beeinflusster Lastanteil) einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$y_S[k]$	- stochastische Komponente einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$y_T[k]$	- Polynom- bzw. Trendkomponente einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$y_U[k]$	- unbeeinflusster Zeitreihenkomponente (bzw. unbeeinflusster Lastanteil) einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$y[k]$	- beeinflusste Lastzeitreihe einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
$\Psi_l[k]$	- unabhängigen Variablen, welche die beeinflusste Zeitreihenkomponente modellieren
$z[k]$	- Störgröße einer zeitdiskreten Zeitreihe zum Zeitpunkt kT_S
\mathbf{Z}	- Preiselastizitätsmatrix

Definitionen

„Eine **Zeitreihe** ist die Realisierung eines stochastischen Prozesses. Handelt es sich dabei um einen linearen stochastischen Prozess, wird die Zeitreihe als linear bezeichnet. Andernfalls ist es eine nichtlineare Zeitreihe“ [94]. Die **zeitdiskrete Zeitreihe** $x[k]$ ist eine Folge von Beobachtungen eines stochastischen Prozesses zu zeitdiskreten Zeitabständen im Bereich von $k = 1 \dots n$ und wird in der vorliegenden Arbeit als äquidistante zeitdiskrete Zeitreihe zum Zeitpunkt kT_s betrachtet.

„Eine **Zeitreihe** heißt **musterbasiert**, wenn Teilbereiche von ihr durch typische, wiederkehrende Teilverläufe klassifizierbar und beschreibbar sind. Diese Teilverläufe werden als Muster oder auch Musterobjekte bezeichnet und können linearer und nichtlinearer Gestalt sein. Ihr Auftreten erfolgt entweder periodisch oder nicht periodisch.“ [94]

Elektrische Lastzeitreihen beschreiben den elektrischen Verbrauch angeschlossener Abnahmestellen, erfasst als Zeitreihe in 15-Minuten-Leistungsmittelwerte.

Alle Maßnahmen zur Beeinflussung der Last auf der Verbraucherseite werden als **Demand Side Management (DSM)** oder Lastmanagement bezeichnet [3].

Unter **direktem DSM** versteht man eine Laststeuerung mit gezielter Schaltung von Verbraucherlasten [3].

Als **indirektes DSM (Demand Response)** wird die Einflussnahme auf die Verbraucherlast über ein zeitlich änderndes Anreizsignal (Preiszeitreihe) verstanden – auch als Demand Response bezeichnet. Demand Response (**DR**) umfasst dabei jede vorsätzliche Änderung des Verbrauchsmusters, die dazu bestimmt ist, den Zeitpunkt, das Niveau der momentanen Nachfrage oder den gesamten Verbrauch zu ändern [8], [9].

Eine Beeinflussung der Verbraucherlast, bei der der Energiebedarf unverändert bleibt, wird in dieser Arbeit als **P-DSM** bezeichnet. Wird bei einer Beeinflussung der Verbraucherlast neben den Leistungswerten auch der Energiebedarf verändert, wird diese folgend als **PE-DSM** bezeichnet.

Unter dem Begriff **Betriebsführung** werden alle Maßnahmen zusammengefasst, die zum Betreiben einer Energieanlage oder eines Energiesystems notwendig sind [152].

Der **Vorhersagehorizont** H beschreibt die Länge der Periode, auf die sich ein Vorhersagewert bezieht und setzt sich aus einem oder mehreren Abtastintervallen zusammen. Ein Abtastintervall umfasst dabei jeweils den Abstand zwischen zwei Beobachtungen.

Ein **Prognosemodell** ist eine mathematische Verknüpfung von beobachteten Werten einer zu prognostizierenden Größe mit Werten exogener Größen nach bestimmten Regeln, um als Ergebnis Prognosewerte zu erhalten. Der gewählte Modellansatz bestimmt dabei die Art der mathematischen Verknüpfung. Unter einer Prognosemethode versteht man in der vorliegenden Arbeit ein systematisches Verfahren zur Modellierung und Vorhersage von Zeitreihen. Eine Prognosemethode umfasst die Vorgehensweise bei der Anwendung von Prognosemodellen.

Ausgehend vom aktuellen Zeitpunkt k_0 versteht man unter einem **Prognosewert** die zeitliche Extrapolation von $x[k_0]$ für den Zeitpunkt $k_0 + H$. Ein Prognosewert wird dargestellt als $\hat{x}[k_0 + H]$.

Der **Situationsvektor** $s[k]$ fasst die aktuellen Prozessgrößen, die Preiszeitreihe, Randinformationen und weitere Informationen wie Datum, Uhrzeit oder Typtag als Eingang für das Vorhersagesystem zusammen.

Die Untersuchungen in der vorliegenden Arbeit fokussieren sich auf die Prozessklasse von **Verbraucherprozessen mit indirekter Beeinflussung mittels Preiszeitreihen**. Für die folgenden Abschnitte der vorliegenden Arbeit beziehen sich die Untersuchungen, wenn nicht anders beschrieben, immer auf Zeitreihen der abgegrenzten Prozessklasse von **Verbraucherprozessen mit indirekter Beeinflussung mittels Preiszeitreihen**, welche auch als preissensitiv bezeichnet werden.

1 Einleitung

1.1 Motivation

In der Energieversorgung fällt der Vorhersage elektrischer Lastzeitreihen eine Schlüsselrolle im Rahmen der optimalen Betriebsführung zu. Auf der Grundlage des prognostizierten Energiebedarfs für einen zukünftigen Planungszeitraum werden die Energie und die Leistung, die zum Decken der Nachfragen benötigt werden, eingeplant und bereitgestellt. Gleitende Optimierungsrechnungen für unterschiedliche Planungshorizonte sind die Grundlage einer kosteneffizienten Energiebereitstellung und somit essentiell für tragfähige energiewirtschaftliche Geschäftsmodelle von Energieversorgungsunternehmen (EVU). Die Prognosen sollen das reale Verbrauchsverhalten so genau wie möglich wiedergeben. Die darauf aufbauenden Optimierungsrechnungen liefern Entscheidungsvorschläge mit dem Ziel des optimalen Einsatzes von Ressourcen. Je exakter das Verbrauchsverhalten vorhergesagt werden kann, desto geringer ist die Unsicherheit der auf diesen Lastprognosen basierenden Entscheidungsvorschläge. Die Genauigkeit von Lastprognosen steht damit in direktem Zusammenhang mit der Qualität der anschließenden Optimierung sowie der Entscheidungsvorschläge und spiegelt sich im Ressourceneinsatz und im Betriebsergebnis von EVU wieder.

Vor dem Hintergrund der klima- und marktpolitischen Ziele und dem damit verbundenen wachsenden Anteil der fluktuierenden Einspeisung elektrischer Energie aus dezentralen Erzeugungsanlagen wie Wind- und Photovoltaik stehen die elektrischen Energieversorgungssysteme vor steigenden technischen Herausforderungen. Angesichts dessen wird die Transformation des Energiesystems in [2] in die vier Phasen der Energiewende unterschieden. Diese vier Phasen beschreiben dabei die kontinuierliche Technologieentwicklung und steigende Energieeffizienz im Zeitraum der letzten bis zu den zukünftigen drei Dekaden. Die erste Phase ist durch eine substanzielle Technologieentwicklung erneuerbarer Energien und Effizienztechnologien geprägt und ist weitestgehend abgeschlossen. Die anstehende zweite Phase der Systemintegration ist charakterisiert durch Flexibilisierung, Digitalisierung, direkte Stromnutzung, Speicher und die Entwicklung eines neuen Strommarktes. Es gilt, die Energieerzeugung aus Kraftwerken sowie den Energieverbrauch zunehmend an die volatile Einspeisung aus erneuerbaren Energien anzupassen, um einen systemdienlichen Betrieb anzureizen. Die dritte Phase ist gekennzeichnet durch die Herstellung und Nutzung synthetischer Brenn- und Kraftstoffe, um die hohe negative Residuallast, welche durch fluktuierende erneuerbare Energien entstehen wird und nicht mehr durch Lastmanagement und Speicher ausgeglichen werden kann, nutzbar zu machen. In der vierten Phase findet schließlich eine finale Verdrängung fossiler Energieträger statt. Konkret sollen beispielsweise bis 2025 in Deutschland 40 bis 45 % des Stromverbrauchs durch erneuerbare Energien gedeckt werden, und bis 2050 soll sich dieser Anteil auf mindestens 80% erhöhen [12]. Durch den steigenden Anteil der fluktuierenden Erzeugung vor allem aus Wind und Photovoltaik ändert sich das Verhältnis von regelbarer und fluktuierender Leistung im deutschen elektrischen Energieversorgungssystem und steigert die Komplexität. Standen im Jahre 2017 1 MW installierter Leistung aus fluktuierender Erzeugung noch 0,95 MW Leistung aus konventionellen Kraftwerken gegenüber, ändert sich das Verhältnis laut [1] (Netzentwicklungsplan Szenario B) im Jahre 2030 zu 1 zu 0,52 (bzw. 2035 zu 1 zu 0,47).

Um auch zukünftig die Stabilität des elektrischen Energieversorgungssystems mit einer steigenden fluktuierenden Einspeisung und damit Versorgungssicherheit durch den permanenten Ausgleich von Erzeugung und Verbrauch gewährleisten zu können, müssen komplexe technische Herausfor-

derungen bewältigt werden. Dazu zählen die Güteverbesserung der Einspeiseprognosen für erneuerbare Energien, die Kompensation der fluktuierenden Erzeugung beispielsweise bei Wind- und/oder Dunkelflauten oder bei Situationen, in denen die Erzeugung größer als der Verbrauch ist, sowie die Gewährleistung der Frequenzstabilität bei großen Gradienten der gegebenen Einspeisekurve. Es besteht somit die Notwendigkeit der Erschließung neuer Flexibilitätspotenziale [80], [153]. Im heutigen elektrischen Energieversorgungssystem mit einer verbrauchsfolgenden Erzeugung wird zur Erhaltung der Netzstabilität der Ausgleich von Erzeugung und Verbrauch durch die Anpassung der Erzeugung an den Verbrauch realisiert. Alle Maßnahmen, die darauf abzielen, die Last auf der Verbraucherseite zu beeinflussen, werden unter dem Begriff Demand Side Management (DSM) zusammengefasst [3]. Maßnahmen zur Ausnutzung der verbraucherseitigen Lastbeeinflussungspotenziale werden als ein wichtiges Instrument der Flexibilisierung zur Erreichung der energiepolitischen Ziele der Energiepolitik in Deutschland und der Europäischen Union angesehen. In der Richtlinie 2012/27/EU (Energieeffizienz-Richtlinie) [80] des Europäischen Parlaments und des Rates der Europäischen Union findet sich dazu folgende Begründung: „Die Laststeuerung ist ein wichtiges Instrument zur Verbesserung der Energieeffizienz, da sie den Verbrauchern oder von ihnen benannten Dritten erheblich mehr Möglichkeiten einräumt, aufgrund von Verbrauchs- und Abrechnungsinformationen tätig zu werden; sie liefert somit einen Mechanismus, um den Verbrauch zu verringern oder zu verlagern, was zu Energieeinsparungen sowohl beim Endverbrauch als auch - durch bessere Nutzung der Netze und Erzeugungskapazitäten - bei der Energieerzeugung, -übertragung bzw. -fernleitung und -verteilung führt.“ [80]

Das elektrische Energiesystem unterliegt einem Dimensionierungsproblem, bei dem Erzeugung und Transport für Spitzenlasten dimensioniert sind und nicht für den mittleren Verbrauch. Im Allgemeinen schwankt der Verbrauch über einen Tageszyklus und ein Teil der Systemkapazität bleibt ungenutzt [28]. Eine Absenkung der Spitzenlast kann also einen Beitrag zur Systemstabilität leisten. Des Weiteren können DSM-Maßnahmen für den Ausgleich zwischen Erzeugung und Verbrauch unter Ausnutzung verbrauchseitiger Lastverschiebepotenziale sorgen. Mit der Bereitstellung und Ausnutzung dieser Flexibilitätspotenziale ist allerdings auch der Nachteil verbunden, dass typische Verbrauchsmuster von bisher unbeeinflussten Verbrauchern durch markt- und/oder erzeugungssituationsabhängige Anreiz- und Steuersignale verändert werden. Durch die Beeinflussung des typischen Verbrauchsverhaltens erhöht sich wiederum die Unsicherheit bei der Verbrauchsprognose und damit auch aller auf Verbrauchsprognosen aufbauenden Folgeprozesse und Planungsaufgaben, da die momentan eingesetzten Methoden zur Lastprognose den Aspekt der Preisbeeinflussung nicht berücksichtigen. Für die zuverlässige Versorgung muss aber zur Planung eines effizienten Ressourceneinsatzes ein derart beeinflusstes Verbrauchsverhalten in hinreichend guter Qualität prognostizierbar sein. Herkömmliche Lastprognosemethoden können diesen Beitrag durch die geänderten Anforderungen nicht leisten. In [61] und [62] wird der Nachweis erbracht, dass der Prognosefehler sich mit konventionellen Prognosemodellen verschlechtert, wenn eine nicht berücksichtigte Beeinflussung wie z. B. durch dynamische Preise vorliegt. In Abhängigkeit der Preisdynamik und des eingesetzten Prognosemodells konnte eine Erhöhung des Prognosefehlers gegenüber dem unbeeinflussten Verbrauch zwischen 14% bis 40% nachgewiesen [61] werden, wobei eine Verallgemeinerung der quantitativen Aussagen aus [61] und [62] aufgrund der Datengrundlage nicht ohne weiteres vorgenommen werden kann. Dennoch kann in Anbetracht der Vorüberlegungen und der Untersuchungen ausgewählter Fallbeispiele festgehalten werden, dass zur Prognose preisbeeinflusster elektrischer Lastzeitreihen neue mathematische Verfahren und Modellansätze benötigt werden, die das Verbrauchsverhalten unter der Beeinflussung von Anreiz- oder Steuersig-

nalen analysieren und vorhersagen können. Mit einer Unterscheidung in marktgeführte oder netzgeführte DSM-Maßnahmen [4] werden Vorhersagen benötigt, die aus ökonomischen Gesichtspunkten oder aufgrund von Netzrestriktionen zur Entscheidungsfindung für eine Lastbeeinflussung beitragen. Die gesuchten Prognosemethoden müssen dazu auf der Grundlage von historischen Daten beeinflusster Verbraucher oder Verbrauchergruppen neben dem beeinflussten Verbrauchsverhalten auch auf das unbeeinflusste Verbrauchsverhalten schließen können.

1.2 Aufbau der Arbeit

Im Rahmen der vorliegenden Arbeit werden eine erweiterte Analysemethodik und eine neuartige Prognosemethode entworfen und erprobt, die einen Beitrag zur Analyse und Vorhersage von beeinflussten Lastzeitreihen leisten sollen. Dazu werden im Abschnitt 1 nach der Motivation die Problemstellung sowie die Zielsetzung der Arbeit erläutert. Im Abschnitt 2 werden der Stand des Wissens zum Thema Demand Side Management sowie die damit einhergehenden Herausforderungen, Potenziale sowie Beschreibungsansätze vorgestellt. Weiterhin werden bekannte Methoden der Analyse und Lastprognose sowie deren Wechselwirkungen vorgestellt, auf deren Grundlage die neuartige Methode zur Vorhersage von beeinflusstem Verbrauchsverhalten im Rahmen der vorliegenden Arbeit aufgebaut wird. Im Abschnitt 3 werden die zugrundeliegenden charakteristischen Eigenschaften von preisbeeinflusstem Verbrauchsverhalten identifiziert und erläutert, welche Anforderungen sich für eine zu entwerfende Prognosemethode ergeben. Dazu erfolgt eine systemtechnische Aufarbeitung der Problemstellung, bei der Zusammenhänge zwischen der Planung für die Beeinflussung der Verbraucherseite, den Einflüssen möglicher exogener Größen und der resultierenden preisbeeinflussten Lastzeitreihen sowie möglicher Systemrückkopplungen aufgezeigt werden. Im Abschnitt 4 werden das Konzept und der Entwurf der neuen Prognosemethode vorgestellt. Auf der Grundlage der systemtechnischen Aufarbeitung wird ein Gesamtkonzept für die Analyse, den Entwurf und die Vorhersage von beeinflussten Verbrauchsverhalten vorgeschlagen, mit dem die neue Prognosemethode konzipiert wird. Für das Konzept werden die benötigten Analysen, die zugrundeliegende Vorhersagestrategie, der Aufbau des Vorhersagesystems und der Ablauf bei der Anwendung vorgestellt. Der Abschnitt 5 umfasst die Erprobung und Evaluation der neuen Prognosemethode. Dazu werden zwei Datensätze verwendet und umfangreiche Analysen, Testprognosen und Auswertungen durchgeführt. Der Abschnitt 6 fasst die Inhalte der vorliegenden Arbeit zusammen und zeigt Anknüpfungspunkte für zukünftige Forschungsarbeiten.

1.3 Problembeschreibung

Innerhalb der vier Phasen zur Umsetzung der Energiewende in Deutschland liegt nach dem vorrangigen Ausbau der erneuerbaren Energien der gegenwärtige Fokus auf der Phase zwei, der Systemintegration [2]. Vor diesem Hintergrund müssen, um effiziente und nachhaltige Lösungen zu erreichen, neben dem Netzausbau vor allem Flexibilitätspotenziale erschlossen und die dafür erforderlichen Informations- und Kommunikationstechnologien entwickelt und implementiert werden. Flexibilitätspotenziale ergeben sich u.a. durch den Ausbau von Speichertechnologien oder dem Erzeugungsmanagement der fluktuierenden Einspeisung.

Eine weitere Möglichkeit, Flexibilitätspotenziale zu erschließen, bietet das DSM, welches in zahlreichen Studien als technisch und ökonomisch sinnvolle und nutzbringende Flexibilitätsoption angesehen wird [78], [113], [146], [147], [148]. Vorteile ergeben sich durch das technisch hohe Po-

tenzial, den häufig geringen Erschließungsaufwand sowie die regionale Verteilung des DSM-Potenzials, welches somit eine lokale als auch eine systemweite Flexibilitätsoption darstellt [145]. Durch die Beeinflussung des Verbraucherverhaltens beim DSM werden allerdings bisher typische Verbrauchsmuster, die bisher durch etablierte Prognosemethoden gut prognostizierbar sind, verändert. Mit der Beeinflussung der Verbraucherseite, beispielsweise durch Preisanreize, mit dem Ziel, die Nachfrage zu steuern, werden sich die Verbraucher nicht in völlig ökonomisch rationaler Weise verhalten und versuchen über alle anderen Prioritäten die Kosten für den Verbrauch von Elektrizität zu minimieren. Dementsprechend ist zu erwarten, dass sich die Verbrauchsmuster der Nachfragekurve als Reaktion auf eine Änderung des Strompreises auf eine komplexe Art und Weise verändern werden. Infolgedessen ist mit steigenden Prognosefehlern der Verbrauchsprognose zu rechnen, die sich als zusätzliche Unsicherheit für die sich anschließende Energieeinsatzoptimierung und weitere, auf die Verbrauchsprognose aufbauenden Folgeprozesse fortpflanzen werden. Auf den beeinflussbaren Anteil des Verbrauchs können beim DSM verschiedene unterschiedliche Interessen und Verpflichtungen aufgrund von marktgeführter oder netzgeführter Zielstellung einwirken. Auch gegenläufig wirkende Einflussnahme ist dadurch denkbar. Es werden Prognosemethoden benötigt, welche die komplexen Zusammenhänge beim Verbrauchsverhalten mit Berücksichtigung von beeinflussenden Anreizsignalen abbilden können. Die Prognosemethoden und die zugrundeliegenden Datenanalyseverfahren können dabei nur auf historische Daten von beeinflussten Verbrauchern gestützt werden, da der unbeeinflusste Anteil nicht separat messbar ist.

Die Abbildung 1.1 zeigt schematisch das Zusammenspiel von preisbeeinflusstem elektrischen Lastverhalten, dessen Vorhersage sowie der Preisplanung zur Beeinflussung der elektrischen Last im Rahmen des zugrundeliegenden Planungsprozesses der Preisbildung des DSM. Mittels einer Vorschrift zur Preisbildung werden Preiszeitreihen erzeugt, die die Verbraucher zur gezielten Veränderung ihres zukünftigen Lastverhaltens durch Verlagerung ihres elektrischen Verbrauches von Hochpreiszeiten in Niedrigpreiszeiten herbeiführen soll. Die Charakteristik der Preiszeitreihen wie der Preisdynamik mit Vorlaufzeit und Preisstufen wird vom eingesetzten Tarifmodell und der dazu passenden Preisbildungsvorschrift bestimmt. Die Planung der Preiszeitreihe bestimmt sich dabei sowohl durch technische als auch durch akteurspezifische Einflussfaktoren, Randbedingungen und Interessenslagen. Ausgangspunkt der Planung ist der prognostizierte unbeeinflusste elektrische Lastgang, auf dessen Grundlage abgeschätzt werden kann, zu welchem Zeitpunkt und mit welcher Intensität die Verbraucher durch die Vorgabe eines entsprechenden Preises zu beeinflussen sind. Das heißt, die Entscheidungsfindung zur Lastbeeinflussung basiert auf einer Abschätzung des unbeeinflussten Verbrauchs, ohne dass direkt historische Messwerte für diese Größe zur Verfügung stehen. Die Aufgabe der Prognosemethode ist es also, aus den beeinflussten historischen Verbraucherdaten und anderen verfügbaren relevanten Größen auf das unbeeinflusste Verhalten zu schließen (Rückrechnung) und dieses vorherzusagen. Nur mit der Vorhersage der unbeeinflussten Verbraucherkurve kann die Notwendigkeit und die Ausprägung einer Lastbeeinflussung zu einer bestimmten Einspeisesituation bemessen werden.

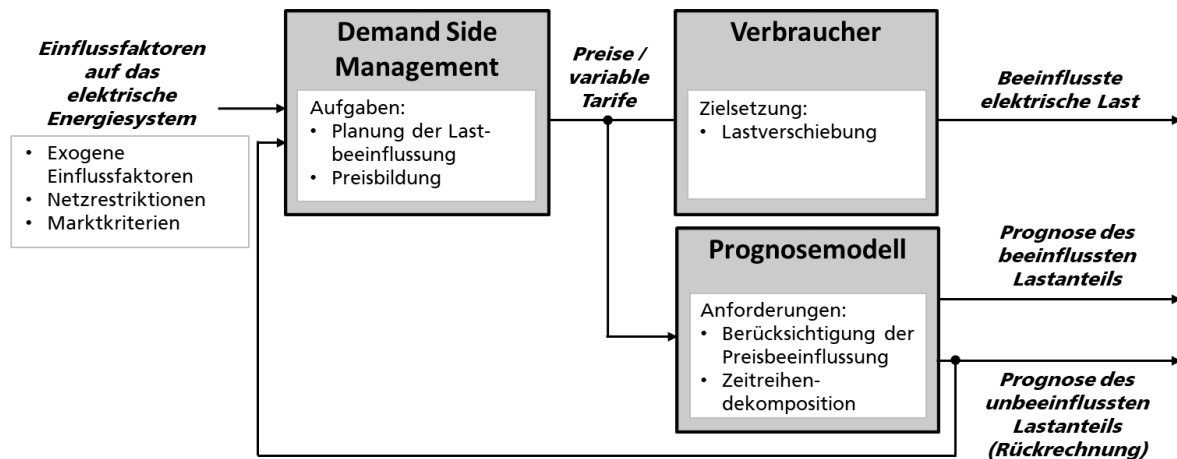


Abbildung 1.1: Problemstellung Demand Side Management

1.4 Zielstellung der Arbeit

Die vorliegende Arbeit soll einen neuartigen Beitrag zur Analyse und Vorhersage preisbeeinflusster elektrischer Lastzeitreihen leisten. Ausgangspunkt ist die systemtechnische Aufarbeitung der Problemstellung, bei der die Zusammenhänge zwischen der Planung für die Beeinflussung der Verbraucherseite, den Einflüssen möglicher exogener Größen und den resultierenden beeinflussten Lastzeitreihen sowie möglicher Systemrückkopplungen aufgezeigt werden. Auf der Grundlage der systemtechnischen Aufarbeitung wird ein Gesamtkonzept für die Analyse, den Entwurf und die Vorhersage von preisbeeinflussten Lastgängen entworfen. Für die Analyse werden Methoden aufbereitet und erarbeitet, mit denen signifikante charakteristische Eigenschaften preisbeeinflusster Lastzeitreihen identifiziert und bewertet werden können. Mit den in der Analyse gewonnenen Erkenntnissen erfolgt der Entwurf und die Konzeption geeigneter mathematischer Modelle, welche in der Lage sind, die komplexen Zusammenhänge und die signifikanten charakteristischen Eigenschaften preisbeeinflusster Lastzeitreihen zu modellieren und für die Vorhersage anzuwenden. Das zu entwerfende Modell soll das Ein- Ausgangs-Verhalten von preisbeeinflussten Verbraucherprozessen mit geeigneten Modellansätzen wiedergeben und neben dem beeinflussten Verbrauchsverhalten auch das unbeeinflusste Verbrauchsverhalten beschreiben. Verbraucherprozesse die durch indirekte Beeinflussung mittels Preissignalen beeinflusst werden, sollen mit dem Ziel der optimalen Beschreibung der Statik und Dynamik dieser Prozesse approximiert werden. Regelmäßige und unregelmäßige Änderungen des Verbrauchsverhaltens sollen durch das Modell erklärt werden ggf. zeitvariantes Verhalten zu abbilden. Die Untersuchungen in der vorliegenden Arbeit fokussieren sich auf die Prozessklasse von *Verbraucherprozessen mit indirekter Beeinflussung mittels Preiszeitreihen*.

Der Anwendungsfall der Prognose preisbeeinflusster Lastzeitreihen stellt den Rahmen der Untersuchungen dar. Das Ergebnis der Arbeit soll ein für die abgegrenzte Prozessklasse möglichst allgemeingültiges Konzept sein, mit dem preisbeeinflusste Lastzeitreihen analysiert, modelliert und vorhergesagt werden können. Bei der Anwendung sollen die zu entwerfenden Verfahren möglichst automatisiert arbeiten und auf Basis von verfügbaren Vergangenheitsdaten adaptiert werden.

Folgende wesentlichen Forschungsfragen ergeben sich für die Arbeit:

- Wie ergeben sich bei der Beeinflussung der Verbraucherseite in Energiesystemen die systemtechnischen Zusammenhänge zwischen der Planung für die Beeinflussung der Verbraucherseite, den Einflüssen möglicher exogener Größen und den resultierenden preisbeeinflussten Lastzeitreihen sowie möglicher Systemrückkopplungen? Welche signifikanten Zusammenhänge bestehen?
- Welche Charakteristik weisen Verbrauchsmuster der Nachfragekurve auf, wenn eine Beeinflussung der Verbraucherseite besteht, und wie sieht die Veränderung in der Verbrauchsscharakteristik als Reaktion auf eine Änderung des Anreizes im Vergleich zu bisher typischen Verbrauchsmustern ohne eine Beeinflussung aus?
- Mit welchen Methoden lassen sich preisbeeinflusste Lastzeitreihen als Grundlage für neue Prognosemethoden in beeinflusste und unbeeinflusste Zeitreihenkomponenten zerlegen (Zeitreihendekomposition)? Welche Modelle werden benötigt?
- Mit welchen Methoden und Modellkonzepten lässt sich durch Anreizsignale beeinflusstes Verbrauchsverhalten in Energiesystemen vorhersagen?
- Wie kann ein möglichst allgemeingültiges Gesamtkonzept für die Analyse, die Modellierung und die Vorhersage von preisbeeinflussten Lastzeitreihen aussehen?
- Welche Methoden zur Identifikation preisbeeinflusster Lastzeitreihen werden benötigt?

2 Stand des Wissens

2.1 Beeinflussung der Verbraucherseite - Demand Side Management

2.1.1 Herausforderung für den Einsatz von Demand Side Management

Das DSM zielt auf die Ausnutzung des Lastbeeinflussungspotenzials der Verbraucherseite ab. Grundsätzlich kann DSM bei der Nutzung bestehender Produktionskapazitäten, bestehender Netzkapazitäten sowie bei der Integration erneuerbarer Energien einen positiven Beitrag leisten [26]. Beispielsweise können DSM-Maßnahmen durch Verschiebung von Lasten in kostengünstigere Zeitfenster einen wirtschaftlichen Vorteil bewirken, zu Spitzenlastzeiten zur Versorgungssicherheit beitragen und durch die Anpassung des Verbrauchs an die fluktuierende Erzeugung die Integration erneuerbarer Energien verbessern. Bei der Einführung von DSM müssen verschiedene Aspekte und notwendige Rahmenbedingungen beachtet werden, die folgend aufgeführt und diskutiert werden.

In [118] werden verschiedenen Herausforderungen für den Einsatz von DSM diskutiert. Die Herausforderungen sind breit gefächert und betreffen Hemmnisse für die Einführung von DSM als Beitrag für Systemdienstleistungen und Herausforderungen, die nach der Einführung bestehen bleiben.

Eines der dringlichsten Hemmnisse ist das Fehlen geeigneter Marktmechanismen in den derzeitigen Marktstrukturen [118]. Für die optimale Ausnutzung der im Abschnitt 2.1.3 beschriebenen Lastbeeinflussungspotenziale ist eine marktbasierte Umsetzung und die Schaffung eines effizienten Marktumfeldes mit neuen Produkten und Dienstleistungen (z.B. die Einführung neuer Tarifmodelle) nötig, um Verbraucher zur Lastanpassung motivieren zu können [81]. Hierzu werden im Abschnitt 2.1.2 verschiedene DSM-Programme mit unterschiedlichen Zielsetzungen und Ausgestaltungen aufgeführt, mit denen Anreize zur Lastbeeinflussung gesetzt werden können.

Eine weitere Herausforderung ist der Aufbau eines geeigneten Geschäftsmodells für DSM. Die Erweiterung des Strommarktes um DSM wird die gesamtwirtschaftliche Effizienz steigern, wenn die DSM-Potenziale ausgenutzt werden können und sich die Lastprognose nicht verschlechtert. Allerdings sind dabei verschiedene Akteure beteiligt, was die Entwicklung eines Geschäftsmodells verkompliziert. Bei einem geeigneten Geschäftsmodell sollten die Akteure profitieren, es sollen Sicherheitsaspekte ausreichend berücksichtigt sein und es sollte rentabel sein, um die erforderlichen Investitionen in die Infrastruktur zu rechtfertigen [118].

Die Einführung von intelligenten Messsystemen und darauf aufbauende Smart Grid- und Smart Market-Lösungen bilden die Basis von DSM. Die Informations- und Kommunikationstechnologie (IKT) erlaubt die Verständigung mit Endkunden und bildet die Grundlage für eine aktive Beeinflussung des Verbrauchs [26]. Damit steigen auch die Chancen, den Effekt von DSM-Maßnahmen zu maximieren. Für einen Beitrag für die Einhaltung der Systembilanz durch die Anpassung der Last in Echtzeit müsste IKT beispielsweise eine genügen hohe Anzahl für Preisupdates ermöglichen [28].

Grundsätzlich kann angenommen werden, dass das Potenzial für DSM der aktuell abgerufenen Leistungen entspricht, wenn die Anreize ausreichend hoch sind [81]. Mit der quantitativen Begrenzung der Anreize ist auch der beeinflussbare Anteil Last begrenzt. Ökonomische Betrachtungen wie Kosten/Nutzen-Verhältnisse und die Untersuchung von gesamtwirtschaftlichen Auswirkungen

sind nötig. Weiterhin müssen die Auswirkungen auf Versorgungsqualität und Versorgungssicherheit beachtet werden.

Für DSM-Maßnahmen, bei dem sich der Preis innerhalb von kurzen Zeitabständen ändern kann (hohe Preisdynamik), ist der Abrechnungsprozess zu beachten. Mit steigender Preisdynamik wird auch die Komplexität des Abrechnungsprozesses steigen. Eine Herausforderung ist ein maximaler DSM-Effekt unter Beachtung des Kommunikationsaufwandes und des Abrechnungsprozesses in Abhängigkeit der Häufigkeit von Preisupdates [28].

Eine weitere Herausforderung besteht in der effizienten Steuerung der Nachfrage durch Preisanreize und der Beschreibung der Auswirkungen. Mit der Einführung von DSM werden sich die Verbraucher nicht in völlig ökonomisch rationaler Weise verhalten [118]. Hier steht die Annahme im Raum, dass die Minimierung der Energiekosten nicht die oberste Priorität der Verbraucher ist. Dementsprechend ist zu erwarten, dass der elektrische Bedarf keine lineare Nachfragekurve aufweisen wird, bei der jede Änderung des Strompreises eine proportionale Änderung in der Nachfrage bewirkt [118]. Es ist daher anzunehmen, dass durch den Einsatz von DSM demnach typische Verbrauchsmuster von bisher unbeeinflussten Verbrauchern verändert werden [61]. Die Untersuchungen der Auswirkungen dieser Veränderungen auf die Prognosequalität und die auf die Prognose aufbauenden Folgeprozesse sind daher nötig und stehen im Mittelpunkt der vorliegenden Arbeit.

2.1.2 Kategorisierung

Die Maßnahmen beim DSM können verschiedene Ausgestaltungsmerkmale und Zielstellungen aufweisen und voneinander unterschiedlich kategorisiert werden. In [27] werden DSM-Maßnahmen je nach zeitlicher Dimension und Auswirkung auf den Verbrauchsprozess eingeordnet. Nach [27] können auch Energieeffizienzmaßnahmen wie der Austausch ineffizienter Geräte in Haushalten oder eine Verbesserung der Isolation an Gebäuden zu DSM-Maßnahmen gezählt werden, da diese zu einer sofortigen und permanenten Beeinflussung des Verbrauchsverhaltens führen.

In Abbildung 2.1 wird eine erste Differenzierung nach Zielstellung, Beeinflussung und Akteuren vorgenommen. Eine allgemeine Unterscheidung ist der Einsatzzweck des DSM. In [4] werden marktgeführter und netzgeführter Einsatz unterschieden. In [29] wird zusätzlich der umweltgeführte Einsatz abgegrenzt. Beim marktgeführten Einsatz ergibt sich nur aus Anreizen des Energiemarktes eine Reaktion des Verbrauchsverhaltens. Dabei kann zu Spitzenlastzeiten eine zusätzliche Netzbelastung vorkommen [4]. Ziel beim marktgeführten Einsatz ist die Reduzierung der allgemeinen Kosten der Energieversorgung, die Erhöhung der Reserveleistung oder die Dämpfung der Preisvolatilität [9]. Beim netzgeführten Einsatz werden DSM-Maßnahmen nur zur Entlastung des Netzes eingesetzt. Das Ziel ist dabei die Erhaltung der Systemstabilität durch eine Reduktion des Verbrauchs zu Spitzenlastzeiten [4], [9]. Eine weitere Zielstellung für DSM ist der umweltorientierte Einsatz. Dabei soll der Energieverbrauch aus nicht umweltfreundlichen Erzeugungseinheiten kontrolliert werden. Eine Steigerung der Energieeffizienz und sinkende Emissionen von Treibhausgasen sind die Folge [9], [29].

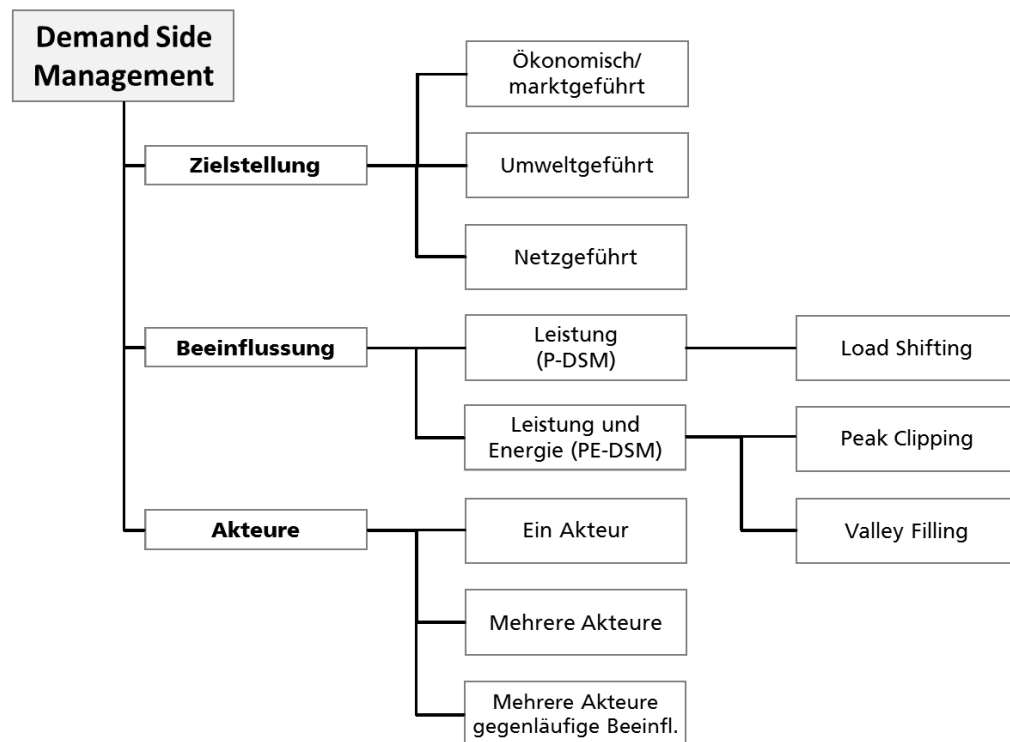


Abbildung 2.1: Unterteilung von Demand Side Management (modifiziert nach [4], [9], [29])

Beim Einsatz von DSM-Maßnahmen kann nach der Strategie der Beeinflussung des Verbraucherverhaltens unterschieden werden. Im Fall der ereignisbasierten Lastbeeinflussung (PE-DSM) werden entweder Spitzen- oder Niedriglasten vermieden (Peak Clipping bzw. Valley Filling). Demgegenüber sollen bei der Lastverschiebung (Load Shifting) Lasten von Spitzen- zu Niedriglastzeiten ohne eine Änderung des Tagesbedarfes verlagert werden (P-DSM) [3]. Die verschiedenen Strategien werden in Abbildung 2.2 dargestellt.




Abbildung 2.2: Strategien beim Demand Side Management Programmen (modifiziert nach [3])

Weiterhin sind beim DSM Incentive-based und Price-based Programme zu differenzieren [5], [6], [8], [26], [29], [79], [117]. Dabei können DSM-Programme für unterschiedliche Planungshorizonte realisiert werden, um bspw. den Zeitpunkt der Leistungsaufnahme (kurzfristige Zeithorizonte) oder den Energiebedarf zu beeinflussen (mittelfristige Zeithorizonte) [9], [79].

Im Fall von Incentive-based Programmen gewähren Kunden den Zugriff auf ihre Verbrauchsanlagen über eine direkte Kommunikation und erhalten für die Durchführung oder Erlaubnis einer

Lastverschiebung Kompensationszahlungen. Die Incentive-based Programme gestalten sich vielfältig. Die bekanntesten Varianten sind die direkte Laststeuerung (Direct Load Control), unterbrechbare Tarife, freiwillige oder festgeschriebene Lastreduktion bei bestimmten Events, Auktionsverfahren für Lastreduktion oder DR-Programme als Substitution für Systemdienstleistungen.

Bei Price-based Programmen findet eine indirekte Beeinflussung des Verbrauchsverhaltens über Anreizsignale statt. Mittels geeigneter Tarife werden Kunden motiviert, den Stromverbrauch zeitlich zu verschieben. In der vorliegenden Arbeit wird angenommen, dass Anreize durch Preiszeitreihen gesetzt werden. Infolgedessen wurden zahlreiche Mechanismen für die Preiszeitreihen- und Tarifbildung in der Literatur untersucht.

Zeitvariable Tarifmodelle, bei denen in Abhängigkeit von Tageszeit, Wochentag und Jahreszeit der Arbeitspreis in wenigen Stufen langfristig festgelegt ist, werden als Time of Use (TOU) bezeichnet [5], [6], [7].

Real Time Pricing (RTP) sind zeitvariable Tarifmodelle, bei denen der Arbeitspreis dynamisch gebildet wird [5]. Der Strompreis wird in diesem Fall flexibel an den Marktgegebenheiten angepasst. Die Information über die Höhe des Strompreises kann dem Stromkunden in einem Bereich von bis zu 24 Stunden im Voraus vorliegen. Tarifmodelle mit einer kleineren Vorlaufzeit bilden das Marktgeschehen besser ab als Preise mit einem größeren Verlauf [6], [7].

Critical Peak Pricing (CPP) sind zeitvariable Tarifmodelle, bei dem der Arbeitspreis wie bei TOU-Tarifen festgelegt wird. Zusätzlich können Preissprünge bei Events auftreten [5], [6]. Die Höhe der einzelnen TOU-Preisstufen ist dem Stromkunden im Voraus bekannt, wohingegen der Zeitpunkt der Preissprünge erst kurzfristig vor deren Eintreten verfügbar ist. Die Auftrittswahrscheinlichkeit der Preissprünge liegt in der Regel bei 1% der Jahresstunden. CPP-Tarifmodelle sollen dem Energieversorger helfen, extreme Netzbelastungen (Events) zu senken [7].

Die Abbildung 2.3 zeigt, wie DSM-Maßnahmen eingeordnet und unterscheiden werden können. Erzeugungsanlagen können in steuerbare und fluktuierende Erzeugung unterschieden werden. Ausgehend von der gegebenen fluktuierenden Erzeugung, passen bei einer bedarfsfolgenden Erzeugung steuerbare Erzeugungsanlagen das Angebot an die Nachfrage an, um den ständigen Ausgleich von Erzeugung und Verbrauch zu realisieren. Vor dem Hintergrund des steigenden Anteils fluktuierender Erzeugung wachsen auch die technischen Herausforderungen für das elektrische Energieversorgungssystem. Mit der Einführung von DSM-Programmen ist es möglich, neue Flexibilitätspotenziale zu erschließen. Dabei wird die Nachfrage so beeinflusst, dass diese an eine gegebene (fluktuierende) Erzeugung angeglichen wird. Der beeinflussbare Anteil macht allerdings nur ein Bruchteil der Verbraucherseite aus. Welche Größenordnung der beeinflussbare Anteil hat, wird in Abschnitt 2.1.3 vorgestellt. Durch die verschiedenen Zielstellungen beim marktgeführten oder netzgeführten Einsatz von DSM kann eine Lastbeeinflussung im elektrischen Energiesystem von verschiedenen Akteuren ausgehen (siehe Abschnitt 3.1). Steuer- und Anreizsignale werden so von verschiedenen Akteursabsichten und Restriktion beeinflusst. Im Planungsprozess für eine indirekte Lastbeeinflussung, bei der die Preiszeitreihe dynamisch gebildet wird, kann die Beeinflussung des Verbrauchs wiederum Einfluss auf den zu bildenden Preis haben und so zu einer Systemrückkopplung führen [10], [11]. Weiterhin können äußere Einflüsse sowie die aktuelle Last- und Einspeisesituation (vor allem EE-Einspeisung) Einfluss auf den Planungsprozess haben und somit die Anreiz- und Steuersignale beeinflussen.

Kategorisierung	Direktes DSM						Indirektes DSM		
	Incentive-based						Price-based		
Programme (Auswahl)	Direkte Laststeuerung	Unterbrechbare Tarife	Emergency Demand Response	Capacity Market Programs	Demand Bidding/ Buyback Programs	Substitut für SDL	Real Time Pricing (RTP)	Critical Peak Pricing (CPP)	Time of Use (TOU)
Signale	Steuersignal bekannt		Steuersignal nicht bekannt				Anreizsignal bekannt	Anreizsignal nicht bekannt	

Abbildung 2.3: Kategorisierung von Demand Side Management Programmen (modifiziert nach [68], [5], [8], [9], [29], [79], [117])

2.1.3 Lastbeeinflussungspotenziale von Demand Side Management

In zahlreichen Studien wurde das Potenzial für die Verschiebung der Elektrizitätsnachfrage für Deutschland untersucht und verschiedene Aspekte dieser Lastverschiebungspotenziale analysiert. In [64] wird ein maximales Lastverschiebungspotenzial von 17 GW unter Behandlung aller Sektoren als Beschränkung identifiziert. Die VDE Studie – Demand Side Integration - [78] beziffert ein Lastverschiebungspotenzial für den Sektor Haushalt (inkl. Elektromobilität) für das Jahr 2010 von ca. 13 GW, für das 2020 18 GW und für das Jahr 2030 bis zu 35 GW. Für den Sektor Gewerbe, Handel und Dienstleistung wird das Lastverschiebungspotenzial mit bis zu 10 GW für das Jahr 2010 mit einer Steigerung auf 13 GW für das Jahr 2030 angegeben.

Für indirektes DSM, bei dem die Lastbeeinflussung über Preisanreize vorgenommen wird, wurde in internationalen Pilotprojekten und Studien das Potenzial zur Spitzenlastreduktion in Abhängigkeiten von Mechanismen für die Preiszeitreihen- und Tarifbildung untersucht. Der beeinflussbare Anteil macht dabei nur einen Bruchteil der Verbraucherseite aus [26], [79]. Das Potenzial zur Spitzenlastreduktion ist dabei neben der Preisspanne sowie dem eingesetzten Tarifmodell und dem damit verbundenen Planungshorizont (Zeitraum, für den die Preise im Vorfeld festgelegt werden und für die Verbraucher im Vorfeld bekannt sind) auch von den technologischen Voraussetzungen (z.B. intelligente Geräte und Kommunikation) abhängig. Die Tabelle 2.1 gibt einen Überblick zu Lastverschiebungspotenzialen bei Programmen für indirektes DSM aus verschiedenen Literaturquellen.

Tabelle 2.1: Lastverschiebepotenzial bei indirektem DSM

Beschreibung	Datengrundlage	Lastverschiebepotenzial	Literaturquelle
Spitzenlastreduktion in Abhängigkeit der eingesetzten Tarife und der technologischen Voraussetzungen	15 Pilotprojekte mit dynamischer Preisbildung	<ul style="list-style-type: none"> • TOU: 3 – 6% • TOU + technologischen Voraussetzungen: 21-30% • CPP: 13 – 20% • CPP + technologischen Voraussetzungen: 27- 44% 	[65]
Spitzenlastreduktion in Abhängigkeit der eingesetzten Tarife und der technologischen Voraussetzungen	100 Pilotprojekte mit dynamischer Preisbildung	<ul style="list-style-type: none"> • TOU: 5% • RTP: 12% • CPP: 16% 	[66]
Spitzenlastreduktion	Zusammenfassung mehrerer Studien	<ul style="list-style-type: none"> • TOU: 1,2 – 23,3% 	[67]
Spitzenlastreduktion in Abhängigkeit der eingesetzten Tarife	Zusammenfassung von 13 Feldversuchen und Demonstrationsprojekten (Angabe wenn Teilnehmerzahl >100)	<ul style="list-style-type: none"> • TOU: 4 – 9% • RTP: 5 – 22% • RTP (day ahead): 10% • CPP: 4,7 – 51% 	[96]
Lastverschiebung in Abhängigkeit von Tarifstruktur (Tarifspreizung, Kombination von Tarifstufen)	Feldtest mit ca. 1000 Testkunden	<ul style="list-style-type: none"> • Spezielles RTP (mit 3 festen Preisstufen; Bekanntgabe des genauen Preises ein Tag im Voraus): Lasterhöhung bis 10,8% Lastreduktion bis 7,7% 	[95]
Spitzenlastreduktion	13 Pilotprojekte mit Demand Response Programmen mit dynamischen Preisen	<ul style="list-style-type: none"> • TOU: 1,84 – 32% • TOU + CPP: 12 – 52,2 % • CPP: 13 – 51% • RTP: 12 – 17% 	[117]

2.1.4 Beschreibungsansätze für die Beeinflussung durch Demand Response

In der Literatur finden sich zahlreiche Ansätze für die Modellierung des Verbrauchsverhaltens im Rahmen von DR. In Tabelle 2.2 werden verschiedene Modellansätze aufgeführt, ohne dabei den Anspruch auf Vollständigkeit zu erheben. Eine eindeutige Abgrenzung zwischen den aufgeführten Modellansätzen ist aufgrund zahlreicher inhaltlicher Überschneidungen allerdings nicht gegeben. In vielzähligen Literatur-Reviews zur Modellierung von DR [115], [120], [127], [128], [139] werden vor allem ökonomische Modelle und Optimierungsmodelle unterschieden. Für die Formulierung von Demand Response als Optimierungsmodell werden in [120] verschiedene Lösungsansätze mittels konvexer Optimierung, Spieltheorie, dynamischer Programmierung, Markov Entschei-

dungsprozess, stochastischer Programmierung oder Particle Swarm Optimization vorgestellt. Ökonomische Modelle beschreiben das Verbrauchsverhalten als Reaktion auf Preisanreize und basieren auf den Zusammenhängen der Preiselastizität, welche in Gleichung (3.7) aufgeführt ist. Die Preiselastizität ist dabei ein Maß für die Sensibilität der Verbraucher, wie stark die Reaktion auf Preisänderungen in Form einer Verbrauchsänderung ausfällt. Modellansätze, die auf dem Konzept der Preiselastizität basieren, kommen in der Literatur sehr häufig vor und es gibt zahlreiche Abwandlungen und Erweiterungen. In [17] wird die Preiselastizität in Abhängigkeit vom Monat, Tag, Stunde und dem Zeitintervall bei konstantem Preis erklärt und mit Hilfe der Regressionsanalyse ermittelt. In [19] werden die mögliche Reaktion der Verbraucher neben dem Energiebedarf ebenfalls in Abhängigkeit von Zeitpunkt, Typtag und saisonalen Einflüssen erklärt. Dabei werden Parameter wie die zeitliche Verfügbarkeit oder die Motivation der Verbraucher in Abhängigkeit von der Uhrzeit einbezogen, was zur Folge hat, dass die Preiselastizität zeitlich variiert. In [72] wird die Preiselastizität als Funktion der Uhrzeit, Kalenderabhängigkeiten, Temperatureffekten und demografischen und ökonomischen Variablen beschrieben. [20] beschreibt die Preiselastizität als Sigmoid-Funktion, die neben dem Preis auch von den Eigenschaften von Haushalten und der Bereitschaft der Kunden, vom gewohnten Verhalten abzuweichen, abhängt. Die resultierende Verbrauchskurve basiert auf der vorab ermittelten Preiselastizitätsfunktion, unterschiedlichen Typtagen und speziellen Eigenschaften von Haushaltsverbrauchern. Die für die Modellierung benötigten Parameter werden dabei beispielsweise aus einem sozioökonomischen Modell oder einem Feldversuch eines Pilotprojektes gewonnen. Die Tabelle 2.2 mit den darin aufgeführten Modellansätzen soll einen Überblick über die in der Literatur diskutierten Methoden geben und die zugrundeliegenden Ideen und Überlegungen zusammenfassen.

Tabelle 2.2: Überblick von Beschreibungsansätze für Demand Response

Beschreibungsansätze	Zugrundeliegende Idee	Referenz
Modelle basierend auf der Preiselastizität	<ul style="list-style-type: none"> Beschreibung des Verbrauchsverhaltens als Reaktion auf Preisanreize basierend auf den Zusammenhängen und dem Konzept der Preiselastizität (aufgeführt in Gleichung (3.7)) Zahlreiche Abwandlungen und Erweiterungen 	[16], [17], [20], [19], [29], [65], [72], [119], [121], [122]
Optimierungsmodell	<ul style="list-style-type: none"> Verschiedene Lösungsansätze mittels konvexer Optimierung, Spieltheorie, dynamischer Programmierung, Markov Entscheidungsprozess, stochastischer Programmierung oder Particle Swarm Optimization 	[20], [120], [124], [125], [126]
Virtueller Speicher	<ul style="list-style-type: none"> Konzept eines virtuellen Speichers mit speziellen Eigenschaften und Freiheitsgraden Beschreibung des Verbrauchsverhaltens als Reaktion auf Preisanreize basierend auf Differenzengleichungssystem 	[18], [115]
Lineare und nicht-lineare stochastische Zeitreihenmodelle	<ul style="list-style-type: none"> Beschreibung der Dynamik von preissensitiven Verbrauchern mit Hilfe von bspw. Finite Impulse Response (FIR) oder Autoregressive Moving Average Models with Exogenous inputs (ARMAX) 	[11], [123]

Beschreibungsansätze	Zugrundeliegende Idee	Referenz
Fuzzy-System	<ul style="list-style-type: none"> Beschreibung der Anpassungsfähigkeit individueller Verbraucher auf Preise im Entscheidungsmodell basierend auf Fuzzy-Technologie in Abhängigkeit der Tageszeit 	[19]
Physikalisches Modell	<ul style="list-style-type: none"> Modellierung von elektrischen Endgeräten nach Bottom-Up-Prinzip Aggregation verschiedener Ebenen, um Lastprofile zu erhalten Meist verbunden mit Monte Carlo Simulationen, um Aggregation der elektrischen Geräte zu simulieren 	[129], [130], [131], [137]
Monte Carlo Simulationen	<ul style="list-style-type: none"> Preissensitive Nachfragekurven (Szenarios), bei der das Kundenverhalten als unsichere Nachfrageelastizität als Reaktion auf Preissignale modelliert wird Unsicherheit beispielsweise aus Mangel an Motivation bzw. Aufmerksamkeit, Latenz bei der Kommunikation oder Änderung des Verbrauchsverhaltens 	[21], [129], [130]
Multiagenten-System	<ul style="list-style-type: none"> Beschreibung von Verbrauchern (entsprechend Aggregationsebene z.B. Endgeräten oder Haushalt) als Agenten Anwendung zur Validierung von DR 	[132], [133], [134], [137]
Clusterverfahren	<ul style="list-style-type: none"> Beschreibung des Verbrauchsverhaltens durch dynamische Segmentierung von Verbrauchsmustern 	[99], [114], [135], [136]

2.1.5 Zusammenfassung und wichtigste Erkenntnisse

Der Abschnitt 2.1 gibt den Stand des Wissens für die Beeinflussung der Verbraucherseite durch DSM wieder.

Zunächst werden die Herausforderungen im Abschnitt 2.1.1 erläutert. Neben technischen Herausforderungen und breit gefächerten Hemmnissen für die Einführung von DSM ergibt sich die Fragestellung einer effizienten Steuerung der Lastkurve durch DSM-Maßnahmen.

Im Abschnitt 2.1.2 werden verschiedene Kategorien von DSM vorgestellt und die Unterscheidungsmerkmale diskutiert. Es findet eine Unterteilung von DSM-Maßnahmen nach deren Zielstellung, Beeinflussung von Leistungs- und/oder Energiewerten, Strategie sowie direkter oder indirekter Beeinflussung statt. Beim indirekten (Price-based) DSM findet eine indirekte Beeinflussung des Verbrauchsverhaltens über Anreizsignale (in der Regel Preisanreize) statt. Durch die Einführung geeigneter variabler Stromtarife sollen Verbraucher dazu animiert werden, den Stromverbrauch zeitlich zu verschieben. Es ist allerdings zu erwarten, dass die Verbraucher sich bei der Reaktion auf Preisanreize nicht völlig ökonomisch rational verhalten werden. Die größte Priorität liegt nicht uneingeschränkt und zu jedem Zeitpunkt auf der Minimierung der Kosten für den Elektrizitätsverbrauch. Der Fokus der vorliegenden Arbeit liegt auf der indirekten Beeinflussung der Verbraucherseite durch Preisanreize.

Die Potenziale für eine Lastbeeinflussung durch DSM, welche im Abschnitt 2.1.3 als Resultat verschiedener Pilotprojekte aufgeführt werden, hängen vom eingesetzten Tarifmodell und der jeweiligen DSM-Maßnahme ab. Die Potenziale zur Lastverschiebung liegen zwischen 1,2 % und 52,2 %. Die Variation der Angaben schwankt allerdings deutlich zwischen den aufgeführten Pilotprojekten bzw. Literaturquellen.

Im Abschnitt 2.1.4 werden Beschreibungsansätze für die indirekte Beeinflussung der Verbraucherseite aufgeführt. Der Fokus der vorliegenden Arbeit liegt neben der Beschreibung beeinflusster Verbrauchsprozesse auch auf der Vorhersage der resultierenden preisbeeinflussten Lastzeitreihen. Verbrauchsmuster ohne eine Beeinflussung durch Preisanreize, welche bisher gut prognostizierbar waren, werden durch den Preiseinfluss verändert und die Unsicherheit bei der Prognose steigt (Anstieg der Unsicherheit zwischen 14% bis 40% laut [61]). Daraus ergibt sich ein Bedarf für neue Prognosemethoden für preisbeeinflusste Lastzeitreihen.

2.2 Analyse

2.2.1 Optimale Prognose

Abbildung 2.4 zeigt die systemtechnische Darstellung eines Verbrauchsprozesses mit den Ein- und Ausgangszeitreihen sowie eines Modells zur Beschreibung des Verbrauchsverhaltens.

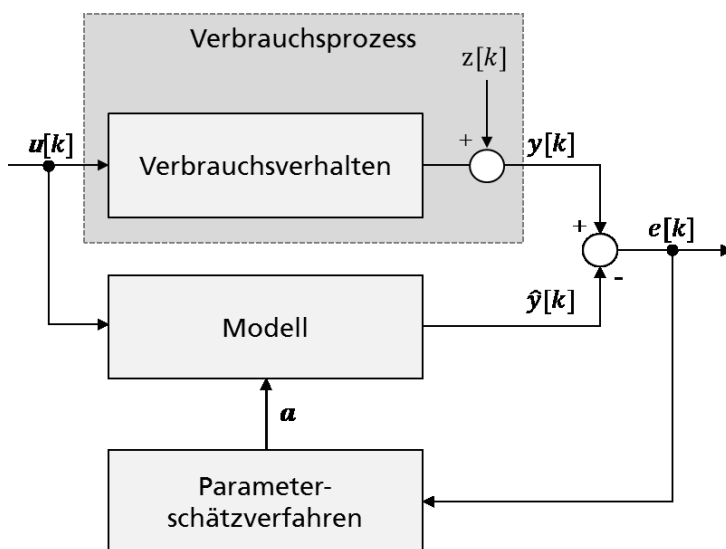


Abbildung 2.4: Systemtechnische Darstellung eines Verbrauchsprozesses und eines Modells zur Beschreibung des Verbrauchsverhaltens (modifiziert nach [14])

Die in der Abbildung 2.4 dargestellten Größen haben folgende Bedeutung:

- $u[k]$ – Vektor verschiedener Einflussgrößen,
- $z[k]$ – Störgröße,
- $y[k]$ – Lastzeitreihe,
- $e[k]$ – Fehlerzeitreihe (auch als Residuen bezeichnet),
- a – Modellparameter.

Mittels eines Parameterschätzverfahrens werden die Modellparameter \mathbf{a} so eingestellt, dass der Fehler $e[x]$ als Differenz zwischen den Istwerten der Lastzeitreihe $y[x]$ und dem Modellausgang $\hat{y}[x]$ minimal wird und dass das Modell somit das Ein-Ausgangsverhalten des Verbrauchsverhaltens optimal abbildet. Dazu wird i. d. R. als Zielfunktion Q der quadratische Fehler, wie folgt, minimiert:

$$Q = \min(e[k]^2). \quad (2.1)$$

Der Fokus der vorliegenden Arbeit liegt auf der Vorhersage. Im Fall der Vorhersage wird das in Abbildung 2.4 gezeigte Modell als Prognosemodell eingesetzt, um das Ein- Ausgangsverhalten für einen zukünftigen Zeitpunkt vorherzusagen, sodass als Ergebnis Prognosewerte vorliegen. Eine grundlegende Forderung an Prognosen ist eine möglichst hohe Genauigkeit. Die Verbesserung der Genauigkeit ist in der Regel mit einem erhöhten Aufwand bei der Modellierung verbunden. Mit einem steigenden Vorhersagehorizont H strebt die Varianz des Fehlers gegen die Prozessvarianz [45]. Damit eine exakte Modellierung gelingen kann, müssen bei der Modellierung für die Residuen bestimmte Modellannahmen getroffen werden, welche auch BLUE-Bedingungen – best linear unbiased estimator – genannt werden. Das Modell liefert nur dann sinnhafte und unverzerrte Ergebnisse, wenn die zuvor genannten Voraussetzungen erfüllt sind. Die Annahmen, die folgend aufgeführt werden, betreffen die Art und Weise des Zusammenhangs zwischen der abhängigen und den unabhängigen Variablen [116] und entsprechen dem Kriterium der optimalen Prognose.

- Linearität: Die Beziehung zwischen der abhängigen Variablen und der (bzw. den) unabhängigen Variablen ist im Hinblick auf die Modellparameter \mathbf{a} linear und die Modellparameter sind identisch für alle Beobachtungen.
- Eigenschaften der Residuen: Die Residuen, also die Abweichungen zwischen den beobachteten und den vorhergesagten Werten, sollten zufällig auftreten und keinem systematischen Muster folgen. Die Residuen folgen den nachstehenden Regeln.
 - Homoskedastische Varianz der Residuen: Die Varianz der Residuen soll konstant sein, sodass diese weder in Abhängigkeit der abhängigen noch einer oder mehrerer unabhängiger Variablen zu- oder abnimmt.
 - Unkorreliertheit der Residuen: Die Fehlerkovarianzen sind null, d.h. es gibt keine Autokorrelation der Residuen. Weiterhin sollen die unabhängigen Variablen und die abhängige Variable unkorreliert sein.

Zur Überprüfung der Modellannahmen kommen verschiedene Tests infrage. Ein optimales Prognosemodell liegt vor, wenn der Nachweis erbracht werden kann, dass die Fehlerzeitreihe weißem Rauschen entspricht [45]. Im diesem Fall ist die Genauigkeit der Prognose optimal und kann auch mit erhöhtem Aufwand nicht mehr verbessert werden. Die Analyse stützt sich also insbesondere bei der Ermittlung der Genauigkeit auch auf die Analyse der Residuen.

Für die Erstellung eines Prognosemodells ergeben sich Wechselwirkungen zwischen der Analyse und der Modellbildung. Im Zuge der Modellbildung findet die Auswahl eines geeigneten Modellansatzes, die Festlegung der Modellstruktur und der Modellkomplexität sowie die Wahl der Eingangsbelegung statt. Zunächst müssen allerdings der zugrundeliegende Prozess und dessen Ein-Ausgangszeitreihen im Rahmen einer Analyse untersucht werden. Die Modellbildung stützt sich auf die Ergebnisse der Analyse und somit auf die Identifikation der charakteristischen Eigenschaften der dem Ein- Ausgangsverhalten zugrundeliegenden Zeitreihen. Im Abschnitt 2.2.2 werden

dazu in Betracht zu ziehende Methoden der Zeitreihenanalyse vorgestellt. Der Abschnitt 2.3.1 führt verschiedene potenzielle Ansätze zur Zeitreihenmodellierung auf.

2.2.2 Methoden der Zeitreihenanalyse

Bei der Datenanalyse sollen mittels statistischer Methoden zusammenfassende Informationen aus numerischen Daten gewonnen und Eigenschaften von Datenmengen charakterisiert werden. Im Zusammenhang mit der Lastprognose wird die Datenanalyse eingesetzt, um Erkenntnisse zu gewinnen, auf die die Modellierung gestützt werden kann. Dabei werden mit Hilfe verschiedener Techniken und Methoden der Statistik und dem Ziel eines zusätzlichen Erkenntnisgewinns Daten in anderer Form strukturiert, geordnet oder dargestellt. Die so gewonnenen Ergebnisse dienen als Grundlage der Modellierung von Prognosemethoden.

Mit dem Fokus der Analyse von Zeitreihen gibt der Abschnitt 2.2.2 einen Überblick über eine Auswahl von Methoden der Datenanalyse, ohne dabei den Anspruch auf Vollständigkeit zu erheben. Vor dem Hintergrund der Datenanalyse kann zwischen deskriptiver, explorativer und induktiver Statistik unterschieden werden.

Bei der deskriptiven Statistik hat die Datenanalyse beschreibenden Charakter und die Aufgabe der Erklärung der Gesamtheit durch die Reduktion der Komplexität. Das Ziel ist, die Informationen eines Datensatzes zu verdichten und das Wesentliche mit Hilfe von geeigneten charakteristischen Kennzahlen, Tabellen oder grafischen Darstellungen deutlich zu machen.

Bei der explorativen (erkundenden) Statistik erfolgt die Datenanalyse ohne Modellannahme (z. B. Annahme der Normalverteilung) und umfasst u. a. grafische Verfahrensweisen und Variablentransformation mit dem Ziel der Darstellung von Daten und des Auffindens von Strukturen.

Die induktive Statistik ermöglicht den Rückschluss von einem Stichprobenbefund auf die zugehörige Grundgesamtheit und auf allgemeine, über den Beobachtungshorizont hinaus gültige Gesetzmäßigkeiten mittels eines statistischen Modells. Dabei werden empirische Befunde und Ergebnisse gegenübergestellt und auf der Grundlage zu prüfender wissenschaftliche Hypothesen mittels Wahrscheinlichkeitsaussagen bewertet.

Die Tabelle 2.3 gibt einen zusammenfassenden Überblick ausgewählter Methoden der Datenanalyse, welche für die vorliegende Arbeit in Betracht gezogen werden. Zielstellung ist dabei die Analyse von Zeitreihen. Eine detailliertere Beschreibung der aufgeführten Methoden, Literaturquellen und Beispiele ist im Anhang A zu finden.

In Bezug zu den in der vorliegenden Arbeit zugrundeliegenden Forschungsfragen (siehe Abschnitt 1.4) ist die Relevanz der aufgeführten Analysemethoden zu prüfen. Im Rahmen der Lastprognose bauen Zeitreihenanalyse und Modellbildung aufeinander auf. Mit Hilfe geeigneter Analysemethoden sind die charakteristischen Eigenschaften der vorherzusagenden Lastzeitreihen zu identifizieren. In Abhängigkeit der identifizierten charakteristischen Eigenschaften sind Modelltyp und Modellstruktur für das zu entwerfende Modell derart zu bestimmen, dass dieses das zugrundeliegende Systemverhalten wiedergeben kann. Bisher wurde die Identifikation charakteristischer Eigenschaften im Rahmen der Analyse von Lastzeitreihen ohne Preisbeeinflussung in der Literatur umfassend behandelt. Für preissensitive Lastzeitreihen besteht bei der Zeitreihenanalyse und der darauf basierenden Modellierung noch Bedarf an geeigneten Methoden. Insbesondere die Identifikation der Charakteristik von preissensitivem Verbrauchsmustern der Nachfragekurve und die Zeitreihendeckomposition in beeinflusste und unbeeinflusste Zeitreihenkomponenten als Grundlage neuer Prog-

nosemethoden können durch bisherige Analysemethoden nicht oder nur unzureichend gelöst werden. Die Methoden der Datenanalyse, welche im Rahmen der Untersuchungen der vorliegenden Arbeit zur Anwendung kommen, und deren Relevanz bei der Zeitreihenanalyse werden im Abschnitt 3.5 diskutiert. Dabei werden die charakteristischen Eigenschaften und die für die Identifikation relevanten Analysemethoden vorgestellt.

Tabelle 2.3: Überblick über Methoden der Datenanalyse

Kategorie		Methode
Visualisierung		Histogramm, Häufigkeitsverteilung
		Torten- und Balkendiagramme
		Punktwolke/ x-y-Kennlinie Scatter-Plot (Streudiagramm)
		Box-Plot/ Box-Whisker-Plot
		Q-Q-Plot (Quantil-Quantil Plot)
Parameter (Informationen über die Häufigkeitsverteilung)		Lage- und Streuungsparameter z.B. Mittelwert, Median, Modus bzw. Modalwert, Varianz, Standardabweichung, Maximum, Minimum, Spannweite, Quantile, usw.
		Konzentrationsmaße z.B. Gini-Koeffizient, Lorenzkurve
		Rangkorrelationskoeffizient
		Kontingenzkoeffizient
Varianzanalyse		Einfaktorielle Varianzanalyse
		Multifaktorielle Varianzanalyse
Regressionsanalyse		Lineare Regression
		Nichtlineare Regression
Korrelationsanalyse	statisch	Empirischer Korrelationskoeffizient
		multipler Korrelationskoeffizient
	dynamisch	Autokorrelationsfunktion (AKF), partielle AKF, inverse AKF
		Kreuzkorrelationsfunktion (KKF)
Transformation durch Filterverfahren		Gleitende Durchschnitte
		Differenzenfilter
		Exponentielle Glättung
		Box-Cox-Transformation
Spektralanalyse		Periodogramm
		Fourier-Transformation
		(Auto- und Kreuz-) Leistungsdichtespektrum
		Wavelet-Analyse
Klassifikation		Hauptkomponentenanalyse
		Diskriminanzanalyse
		Unabhängigkeitsanalyse
		Faktorenanalyse
		Bayes-Klassifikation
		k-nearest-neighbor-Klassifikation
		Support-Vektor-Maschinen (SVM)
		Entscheidungsbäume
Clusterverfahren	hierarchische	Single-Linkage-Verfahren, Complete-Linkage-Verfahren, Average-Linkage-Verfahren, Ward-Verfahren
	partitionierende	k-means-Algorithmus (Minimum-Distanz-Verfahren)
		Fuzzy-C-means-Algorithmus
		Self-Organized Maps (Kohonen-Karte)

Kategorie		Methode
Signifikanztests	Parametertests	Einstichproben-t-Test
		Zweistichproben-t-Test
		F-Test
		Wilcoxon-Vorzeichen-Rangsummen-Test
		Welch-Test
		Wilcoxon-Rangsummen-Test
		F-Test
		Durbin-Watson-Test
		Chi-Quadrat-Streuungstest
		Periodogrammtest
		Z-Test
	Anpassungstests	Chi-Quadrat-Anpassungstest
		Kolmogoroff-Smirnoff-Test (KS-Test)
		Anderson-Darling-Test
		Shapiro-Wilk-Test
	Unabhängigkeitstests	Chi-Quadrat-Unabhängigkeitstest
		Spearman's Rangkorrelationstest
		Fisher-Test
Vorhersagbarkeit		Lineare Vorhersagbarkeit
		Nichtlineare Vorhersagbarkeit
		Bedingte Vorhersagbarkeit
Punktschätzung		Momentenmethode
		Maximum-Likelihood-Methode
		Methode der kleinsten Quadrate
Bereichsschätzung		

2.2.3 Zusammenfassung und wichtigste Erkenntnisse

Es besteht eine Wechselwirkung zwischen der Analyse und der Modellbildung. Die Entscheidungen bei der Modellbildung für die Auswahl eines geeigneten Modellansatzes, die Festlegung der Modellstruktur und die Wahl der Eingangsbelegung stützt sich auf die Ergebnisse der Analyse und somit auf die charakteristischen Eigenschaften der zugrundeliegenden Zeitreihen. Der Abschnitt 2.2.2 gibt einen Überblick über potenzielle Methoden der Zeitreihenanalyse.

Zur Beantwortung der im Abschnitt 1.4 gestellten Forschungsfragen richtet sich die Zielstellung der vorliegenden Arbeit auf den Entwurf eines optimalen Prognosemodells. Für ein optimales Prognosemodell muss als hinreichendes Kriterium der Nachweis erbracht werden, dass die Fehlerzeitreihe weißem Rauschen entspricht.

2.3 Vorhersage

2.3.1 Ansätze zur Zeitreihenmodellierung

In diesem Abschnitt werden Ansätze für die Modellierung von Zeitreihen vorgestellt. Für die Lastprognose sind in der Regel individuelle Modelle erforderlich, die auf den vorgestellten Ansätzen zur Zeitreihenmodellierung basieren.

Für die Beschreibung von Zeitreihen und deren dynamischen Verhaltens stehen in der Literatur umfangreiche Verfahren zur Verfügung. Das klassische Komponentenmodell bietet einen allgemeingültigen Ansatz für die Beschreibung von Zeitreihen und wird in Gleichung (2.2) vorgestellt. Dabei wird angenommen, dass eine Zeitreihe aus folgenden Komponenten zusammengesetzt werden kann [14]:

- $x_T[k]$ durch Polynomansatz beschreibbare Zeitreihenkomponente,
- $x_P[k]$ durch periodischen Ansatz beschreibbare Zeitreihenkomponente und
- $x_S[k]$ durch stochastisches Zeitreihenmodell beschreibbare Zeitreihenkomponente.

Typische Zeitreihen aus der Energiewirtschaft (wie z.B. Lastzeitreihe) weisen in der Regel charakteristische wiederkehrende Zeitreihenverläufe auf. Um solche typischen Muster besser erfassen zu können, wurde das klassische Komponentenmodell in [15] um eine Musterkomponente $x_M[k]$ erweitert zu:

$$x[k] = f(x_T[k], x_P[k], x_S[k], x_M[k]). \quad (2.2)$$

Vor dem Hintergrund des Komponentenmodells werden in den Abschnitten 2.3.1.1 bis 2.3.1.7 Ansätze zur Zeitreihenmodellierung vorgestellt, die für die Modellierung von einer oder mehreren Zeitreihenkomponenten angewendet werden können.

Für die Systematisierung von Ansätzen zur Zeitreihenmodellierung finden sich in der Literatur zahlreiche Vorschläge. Dieser Abschnitt soll einen Überblick über eingesetzte und etablierte Modellierungsansätze liefern. Der Fokus liegt dabei auf Lastprognosen für den Energiemarkt und die Energienetze. Es ergeben sich allerdings zahlreiche Überschneidungen zu Prognosemethoden im Zusammenhang mit anderen Disziplinen wie Bereichen der Betriebswirtschaft, Sozialwissenschaft, Volkswirtschaft oder anderen Teilen von Natur- und Ingenieurwissenschaften.

Die Lastprognose hat sich zu einem wichtigen Werkzeug für Teilnehmer am Energiemarkt entwickelt, um Entscheidungsprozesse zu unterstützen. Für den klassischen Prognoseanwendungsfall der Lastprognosen existieren in der Literatur zahlreiche Modellansätze. Zur Unterscheidung bieten sich unterschiedliche Systematisierungen an. Beispielsweise kann zwischen statischen und dynamischen Modellen unterschieden werden. Eine weitere Möglichkeit der Systematisierung geht von den verarbeiteten Einflussgrößen aus. Dabei werden Modellansätze unterschieden, bei denen etwa die Zeit oder auch andere exogene Einflussgrößen als unabhängige Variablen verwendet werden.

Die Literaturrecherche in [25] gibt einen Überblick über Modellansätze zur Lastprognose. Dabei wird eine methodische Unterscheidung vorgenommen. Darin werden zwei grundsätzliche Modellklassen unterschieden. Die erste Modellklasse stellt die klassischen Zeitreihenmodelle dar. Die zweite Modellklasse beschreibt in [25] die Methoden der künstlichen und computergestützten Intelligenz, also Künstliche Neuronale Netze, die Kombinationen mit Fuzzy-Methoden und die Support Vector Machines und Hybridansätze. Einen sehr umfassenden Überblick von eingesetzten Model-

lansätzen mit einer methodischen Unterscheidung bieten [41] und [151]. In [41] werden die Modellansätze Zeitreihenmodelle, Regression, ökonomische Modelle und ARIMA-Modelle, computergestützte Modelle wie Fuzzy-Logik, genetische Algorithmen und Künstliche Neuronale Netze sowie neue Modellansätze wie Support Vektor Regression und Ant Colony Optimization und Particle Swarm Optimization unterschieden. In [43] wird eine Unterscheidung der Modellklassen in traditionellen Prognosetechniken, modifizierte traditionelle Prognosetechniken und computergestützte Techniken vorgenommen.

In der vorliegenden Arbeit wird ebenfalls, ohne Anspruch auf Vollständigkeit, eine methodische Einordnung der Modellansätze vorgenommen. Dabei wird zunächst in Abhängigkeit der Reproduzierbarkeit der Zeitreihe zwischen deterministischen und stochastischen Modellen unterschieden, die wiederum auf lineare und nichtlineare Verfahren zurückgreifen [14], [15]. Sie umfassen unter anderem die in Abbildung 2.5 aufgeführten Modellansätze, die in den folgenden Abschnitten detailliert mit der Angabe von Literaturverweisen vorgestellt werden.

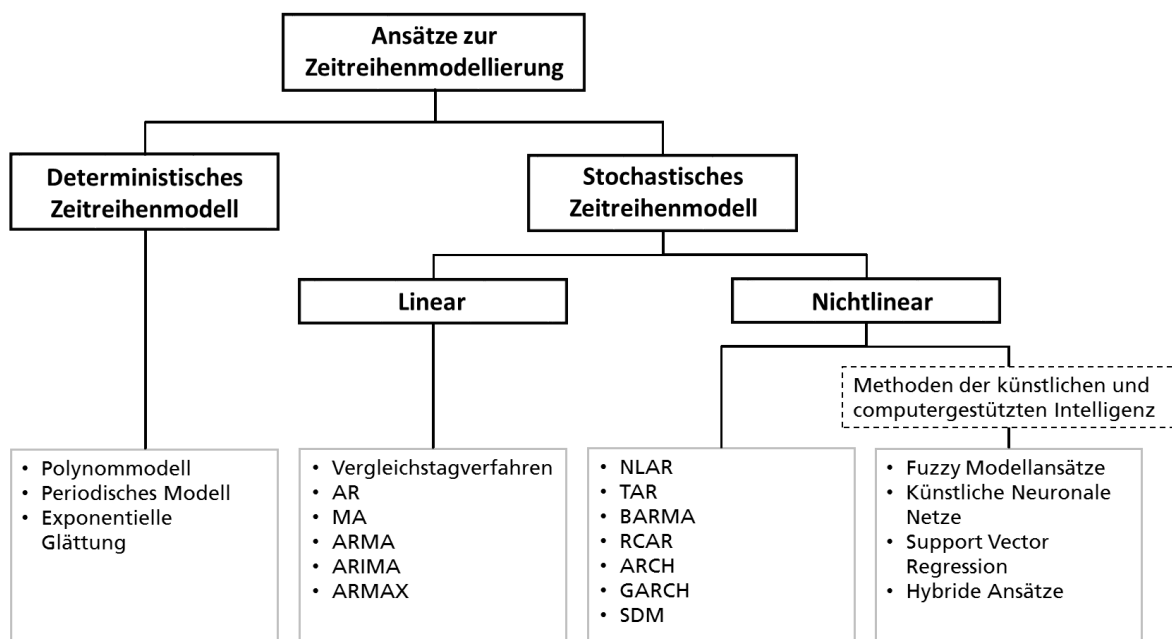


Abbildung 2.5: Systematisierung von Ansätzen zur Zeitreihenmodellierung

2.3.1.1 Deterministische Zeitreihenmodelle

Deterministische Zeitreihenmodelle umfassen Modellansätze, die systematische Komponenten der Zeitreihe als definierte und reproduzierbare Funktionen abbilden.

Polynommodell

Das Polynommodell gilt als universell einsetzbare analytische Beschreibungsform für Zeitreihen. Bei der Modellierung sind die Ordnung m und die Modellparameter a_i zu schätzen [13]. Es gilt folgende Gleichung:

$$x[k] = a_0 + \sum_{i=1}^m a_i \cdot [k]^i \quad (2.3)$$

mit: m - Ordnung des Modells und
 a_0, a_i - Modellparameter.

Periodisches Modell

Für die Approximation von periodisch wiederkehrenden Zeitreihenanteilen eignet sich die Anwendung eines Modells auf Basis des periodischen Modellansatzes, bei dem die Winkelfunktionen für die Darstellung verwendet werden. Bei der Modellierung sind die Parameter a_0, a_i, b_i sowie die dominierenden Frequenzen ω_i zu schätzen [13]. Die Gleichung des periodischen Modells lautet:

$$x[k] = a_0 + \sum_{i=1}^m [a_i \sin \omega_i[k] + b_i \cos \omega_i[k]] \quad (2.4)$$

mit: m - Ordnung des Modells,
 ω_i - Frequenz und
 a_0, a_i, b_i - Modellparameter.

Exponentielle Glättung

Die exponentielle Glättung ist ein Verfahren der Zeitreihenanalyse zur kurzfristigen direkten Prognose auf Basis einer Zeitreihe. Die beobachteten Zeitreihenwerte werden dabei exponentiell gewichtet. Die Vergangenheitswerte gehen hierbei mit abnehmender Aktualität mit abnehmenden Gewichten in die Prognose ein. Die Gleichung (2.5) beschreibt das exponentielle Glätten erster Ordnung für Zeitreihen, welche nicht mit einem Trend behaftet sind und lautet:

$$\hat{x}[k+H] = ax[k] + (1-a)\hat{x}[k+H-1] \quad (2.5)$$

mit: $\hat{x}[k+H-1]$ - alter Prognosewert und
 a - Glättungsfaktor mit: $0 < a < 1$.

Für trendbehaftete Zeitreihen oder Polynome höherer Ordnung stehen besser geeignete Verfahren zur Verfügung, welche ebenfalls auf exponentieller Glättung basieren. In [42] werden verschiedene Verfahren der exponentiellen Glättung vorgestellt.

2.3.1.2 Lineare stochastische Zeitreihenmodelle

Lineare stochastische Zeitreihenmodelle stellen eine der wichtigsten Modellklassen dar und sind Grundlage zahlreicher Prognoseansätze. Mit Hilfe linearer stochastischer Zeitreihenmodelle können die inneren Zusammenhänge von Zeitreihen auf Basis linearer stochastischer Prozesse beschrieben werden. Für den Einsatz dieser ARMA(autoregressive moving average)-Modelle und daran angelehnte Modelle werden stationäre Prozesseigenschaften vorausgesetzt, d.h. die Prozesseigenschaften sind zeitunabhängig. Das ARMA-Modell setzt sich aus einem AR- und einem MA-Modell zusammen.

AR(p)-Modell (autoregressive)

Das AR-Modell ergibt sich aus:

$$x[k] = \sum_{i=1}^p [a_i \cdot x[k-i]] + \varepsilon[k] \quad (2.6)$$

mit: $\varepsilon[k]$ - weißes Rauschen und

a_i, b_i - Modellparameter.

MA(q)-Modell (moving average)

Das MA-Modell berechnet wie folgt:

$$x[k] = \sum_{i=1}^q b_i \cdot \varepsilon[k-i] \quad (2.7)$$

mit: $\varepsilon[k]$ - weißes Rauschen und

b_i - Modellparameter.

Vergleichstagverfahren

Das Vergleichstagverfahren kann ebenfalls den AR-Modellen zugerechnet werden. Ein wesentlicher Aspekt bei der Modellbildung von Prognosemethoden sind die charakteristischen Eigenschaften von Zeitreihen des Energiemarktes und Energienetzen, welche beispielsweise das Verbrauchsverhalten widerspiegeln. Das Verbrauchsverhalten stellt sich in der Regel in typischen Verbrauchsmustern dar, die in periodischen Abständen wiederkehren können. Typische periodisch wiederkehrende Rhythmen in Lastzeitreihen können beispielsweise Tages-, Wochen- oder Jahresrhythmen sein.

Bei der Vergleichstagprognose ergibt sich die Prognose durch das Fortschreiben historischer Werte vergleichbarer Tage aus der Vergangenheit, welche als Referenztage bzw. Referenzwerte oder Referenzmuster bezeichnet werden. Der zeitliche Abstand zum Referenzwert wird durch den Verschiebeoperator τ festgelegt. Es gilt:

$$\hat{x}[k] = x_{ref}[k] = \sum_{i=1}^p [a_i \cdot x[k - \tau_i]] \quad (2.8)$$

mit: $\sum_{i=1}^p a_i = 1$ und $x[k] = \sum_{i=1}^p a_i \cdot x[k - \tau_i] + \varepsilon[k]$,

a_i - Modellparameter,

$\hat{x}[k]$ - Prognosewert von x für Zeitindex k ,

$x_{ref}[k]$ - Referenzwert von $x[k]$ und

τ - Verschiebeoperator.

In der Literatur finden sich zahlreiche andere Modellansätze, bei denen Referenzwerte als zusätzliche Eingangsgröße dienen [15], [22], [23], [33], [34]. Referenzmuster dienen dabei als Repräsentanten des typischen Verbrauchsmusters für die aktuelle Situation. Referenzwerte können dabei beispielsweise abhängig von kalendarischen Einflüssen sein, wenn typische Verbrauchsmuster in Abhängigkeit des Wochentages oder Typtages vorliegen. Vor diesem Hintergrund wird als einfachster Ansatz zur Prognose von Energiezeitreihen von der Vergleichstagprognose ausgegangen.

Im Folgenden werden die drei Modellansätze ARMA, ARIMA (autregressive integrated moving average) und ARMAX (autregressive moving average exogenous models) kurz vorgestellt, welche in zahlreicher Literatur beschrieben werden ([14], [15], [35], [42], [45], [112]). Es finden sich auch diverse Erweiterungen, die auf der ARMA-Modellklasse basieren (z.B. Seasonal Autoregressive Integrated Moving Average Models – SARIMA). Diese Erweiterungen werden allerdings im Rahmen der vorliegenden Arbeit nicht weiter betrachtet.

ARMA(p,q)-Modell (autregressive moving average)

Das ARMA-Modell berechnet wie folgt:

$$x[k] = \sum_{i=1}^p [a_i \cdot x[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \cdot \varepsilon[k-i] \quad (2.9)$$

mit: $\varepsilon[k]$ - weißes Rauschen und

a_i, b_i - Modellparameter.

ARIMA(p,d,q)-Modell (autregressive integrated moving average)

Mit der Anwendung eines Differenzenfilters [14] wird aus einem ARMA-Modell ein ARIMA-Modell. Für die Beschreibung instationärer stochastischer Prozesse bietet das ARIMA-Modell einen Ansatz, bei dem der instationäre Teil (Trend) durch Differenzenbildung der gemessenen benachbarten Zeitreihenwerte miterfasst wird. Differenzenfilter werden so für die Überführung in Zeitreihen mit stationären Eigenschaften (Linearisierung) eingesetzt. Es gilt:

$$\nabla^d x[k] = \sum_{i=1}^p [a_i \cdot \nabla^d x[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \cdot \varepsilon[k-i] \quad (2.10)$$

mit: ∇^d -Differenzenfilter d -ter Ordnung,

$\varepsilon[k]$ - weißes Rauschen und

a_i, b_i - Modellparameter.

ARMAX(p,q,m)-Modell (autregressive moving average exogenous models)

Mit der Berücksichtigung einer zusätzlichen exogenen Einflussgröße wird aus einem ARMA-Modell ein ARMAX-Modell, welches wie folgt berechnet wird:

$$x[k] = \sum_{i=1}^p [a_i \cdot x[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \cdot \varepsilon[k-i] + \sum_{i=0}^m c_i \cdot u[k-i] \quad (2.11)$$

mit: $\varepsilon[k]$ - weißes Rauschen und

a_i, b_i, c_i - Modellparameter.

Beispiele für Prognosemethoden auf der Grundlage linearer stochastischer Signalmodelle sind [50], [53] und [58].

2.3.1.3 Nichtlineare stochastische Signalmodelle

Nichtlineare stochastische Signalmodelle sind im Gegensatz zu Modellansätzen der Theorie der linearen Prozesse wie den ARMA-Modellen nicht auf lineare Zusammenhänge begrenzt. Die Abweichung zur Linearität ist auf sehr vielfältige Weise möglich und durch lokale lineare Approximation oft nur sehr unzureichend zu erfassen. In der Literatur finden sich zahlreiche Ansätze für die Beschreibung nichtlinearer Signale. In [45] wird eine Auswahl der wichtigsten nichtlinearen Modellansätze für die Beschreibung von nichtlinearen Signalen vorgestellt.

NLAR(p)-Modell (nonlinear autoregressive)

Bei den NLAR-Modellen wird die Struktur der AR-Prozesse übernommen und die Annahme der linearen Abhängigkeit von den Werten der eigenen Vergangenheit verworfen. Dabei gilt:

$$x[k] = f[x[k-1], \dots, x[k-p]] + \varepsilon[k] \quad (2.12)$$

mit: $\varepsilon[k]$ - weißes Rauschen und

f - nichtlineare Funktion.

TAR(p)-Modell (threshold autoregressive)

Bei den TAR-Modellen handelt es sich um die einfachste Form der vollständig parametrisierten nichtlinearen autoregressiven Modelle. Der TAR-Modellansatz unterstellt eine Änderung des Verhaltens von dynamischen Zeitreihen bei Über- oder Unterschreitung eines bestimmten Schwellwertes [45] mit:

$$x[k] = \begin{cases} \mu_1 + \sum_{i=1}^p a_i x[k-i] + \varepsilon[k] & \text{für } x[k-d] \leq c \\ \mu_2 + \sum_{i=1}^p b_i x[k-i] + \varepsilon[k] & \text{für } x[k-d] > c \end{cases} \quad (2.13)$$

mit: $\varepsilon[k]$ - weißes Rauschen,

c - Schwellwert und

d - Verzögerungsparameter.

BARMA(p,q,P,Q)-Modell (bilinear autoregressive moving average)

Zeitreihen, in denen sich Perioden mit stärkeren und schwächeren Aktivitäten abwechseln, können mit dem BARMA-Modellansatz wie folgt abgebildet werden:

$$x[k] = \mu + \sum_{i=1}^p [a_i \cdot x[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \cdot \varepsilon[k-i] + \sum_{i=0}^Q \sum_{j=1}^P c_{ij} \varepsilon[k-i] x[k-j] \quad (2.14)$$

mit: $\varepsilon[k]$ - weißes Rauschen,
 a_i, b_i - Modellparameter und
 c_{ij} , - Bewertung der Bilinearität.

RCAR(p)-Modell (random coefficient autoregressive)

RCAR-Modelle sind lineare Signalmodelle mit zeitveränderlichen Parametern und können so nichtlineare Prozesse abbilden. Die Koeffizienten sind dabei stochastisch und unabhängig von der Vergangenheit. Es gilt:

$$x[k] - \sum_{i=1}^p [a_i + A_i[k]] \cdot x[k-i] = \mu + \varepsilon[k] \quad (2.15)$$

mit: $\varepsilon[k]$ - weißes Rauschen,
 a_i - Konstanten und
 $A_1[k], \dots, A_p[k]$ - Folge unabhängiger Zufallsvektoren mit
 $E\{A_i[k]\} = 0; \text{cov}(A_i[k], A_j[k]) = \sigma_{ij}$
 $a_p \neq 0$ oder $\sigma_{pp} > 0$.

ARCH(p)-Modell (autoregressive conditional heteroscedastic)

Im Gegensatz zu AR-Modellen, bei denen stationäre Prozesseigenschaften vorausgesetzt werden, können durch ARCH-Modelle Zeitreihen mit nicht konstanter Varianz (Heteroskedastizität) mit Hilfe folgender Gleichung beschrieben werden [42], [45]:

$$\begin{aligned} \sigma^2[k|s < k] &= \text{Var}[z[k]|z[k-1], z[k-2], \dots] \\ &= a_0 + a_1 z^2[k-1] + \dots + a_p z^2[k-p] \end{aligned} \quad (2.16)$$

mit: $a_0 > 0, a_1, \dots, a_p \geq 0$,
 $\mu[k|s < k] = E[z[k]|z[k-1], z[k-2], \dots] = 0$ und
 $z[k] = \sigma[k] \cdot \varepsilon[k]$.

GARCH(p,q)-Modell (generalized autoregressive conditional heteroscedastic)

GARCH-Modelle stellen die verallgemeinerte Form der ARCH-Modelle dar. GARCH-Modelle sind um autoregressive Terme erweiterte ARCH-Modelle, bei denen die Varianz selbst autoregressiv modelliert wird [45], [42]. Es gilt:

$$\begin{aligned} \sigma^2[k] &= \text{Var}[z[k]|z[k-1], z[k-2], \dots] \\ &= a_0 + a_1 z^2[k-1] + \dots + a_p z^2[k-p] + c_1 \sigma^2[k-1] + \dots + c_q \sigma^2[k-q] \end{aligned} \quad (2.17)$$

$$\begin{aligned} \text{mit: } & a_0 > 0, a_1, \dots, a_q, c_1, \dots, c_q \geq 0, \\ & \mu[k|s < k] = E[z[k]|z[k-1], z[k-2], \dots] = 0 \text{ und} \\ & z[k] = \sigma[k] \cdot \varepsilon[k]. \end{aligned}$$

SDM(p,q)-Modell (state dependent model)

Ausgehend vom ARMA-Modellansatz sind die Parameter beim SDM-Modellansatz zeitveränderlich und abhängig von den vergangenen stochastischen Größen. Es wird wie folgt berechnet:

$$x[k] - \sum_{i=1}^p [a_i x[k-1]] \cdot x[k-i] = \mu[x[k-1]] + \varepsilon[k] + \sum_{i=1}^q b_i [x[k-1]] \cdot \varepsilon[k-i] \quad (2.18)$$

$$\begin{aligned} \text{mit: } & \varepsilon[k] && - \text{weißes Rauschen,} \\ & a_i, b_i && - \text{Modellparameter und} \end{aligned}$$

$$\text{Zustandsvektor } x[k-1] = [\varepsilon[k-1], \dots, \varepsilon[k-q], x[k-1], \dots, x[k-p]]^T.$$

Beispiele für Prognosemethoden auf der Grundlage linearer stochastischer Signalmodelle sind in [56] aufgeführt.

2.3.1.4 Support Vector Regression

Support Vector Machine (SVM) ist eine Methode des maschinellen Lernens zur Mustererkennung und wurde von [44] vorgestellt. Trainingsdaten werden in einen Vektorraum übertragen, wobei jedes Datenobjekt durch einen Vektor repräsentiert wird. Die Aufgabe der SVM ist es, die Trennfläche (Hyperebene) einzupassen, um Datenobjekte in Klassen zu unterteilen. Für die mathematische Beschreibung der Hyperebene werden nur die am nächsten liegenden Vektoren benötigt (support vectors). Sind Datenobjekte nicht linear durch die Hyperebene trennbar, dann wird für nichtlineare Klassengrenzen ein Kernel verwendet. Dabei werden der Vektorraum und die darin enthaltenen Datenobjekte in einen höherdimensionalen Raum überführt. Die Dimension wird dabei so lange erhöht, bis eine lineare Trennung möglich ist. Die Hyperebene wird bei der Rücktransformation nichtlinear. Für die Beschreibung der Hyperebene werden geeignete Kernelfunktionen verwendet, mit denen eine Beschreibung für Hin- und Rücktransformation möglich ist. Die vier wesentlichen Kernelfunktionen sind der lineare Kernel, der polynomiale Kernel, der radiale Kernel und der Sigmoid-Kernel. Mit der Anwendung für die Lösung nichtlinearer Regressionsprobleme (Support Vector Regression – SVR) wird die SVR-Funktion eingeführt, um die nichtlinearen Zusammenhänge zwischen Ein- und Ausgangsdaten zu beschreiben. Dabei wird eine nichtlineare Transformation $f(\cdot): R^n \rightarrow R^{n_h}$ definiert, um die Trainingsdaten $\{(x_i, y_i)\}_{i=1}^N$ in einen höherdimensionalen Raum R^{n_h} zu transformieren. Die SVR-Funktion beschreibt die Zusammenhänge der Ein- und Ausgangsdaten im höherdimensionalen Raum wie folgt:

$$g[x] = w^T \cdot f[x] + b \text{ mit } w = \sum_{i=1}^N [\beta_i^* - \beta_i] f[x_i] \quad (2.19)$$

mit:	$g[\mathbf{x}]$	- SVR-Funktion,
	β_i^*, β_i	- Lagrangemultiplikatoren und
	\mathbf{w}, b	- Koeffizienten mit $\mathbf{w} \in R^{n_h}$ und $b \in R$.

Die SVR-Funktion für einen dualen Raum wird in Gleichung (2.20) aufgeführt. $K[\mathbf{x}_i, \mathbf{x}_j]$ wird dabei Kernelfunktion genannt. Der Wert des Kernels ist gleich dem inneren Produkt der beiden Vektoren \mathbf{x}_i und \mathbf{x}_j im Merkmalsraum $f[\mathbf{x}_i]$ und $f[\mathbf{x}_j]$. Es gilt:

$$g[\mathbf{x}] = \sum_{i=1}^N [\beta_i^* - \beta_i] K[\mathbf{x}_i, \mathbf{x}_j] + b \quad (2.20)$$

mit:	$g[\mathbf{x}]$	- SVR-Funktion und
	$K[\mathbf{x}_i, \mathbf{x}_j]$	- Kernelfunktion

Beispiele für Prognosemethoden auf der Grundlage von SVM bzw. SVR sind [39], [40], [54] und [55] dargelegt.

2.3.1.5 Künstliche Neuronale Netze

Laut [45] werden Künstliche Neuronale Netze (KNN) auch zu den nichtlinearen stochastischen Zeitreihenmodellen gezählt. Durch den verbreiteten Einsatz von KNN im Kontext von Energieprognosen und den dementsprechend zahlreichen Veröffentlichungen in der Literatur werden in dieser Arbeit die KNN in einem separaten Abschnitt beschrieben.

Künstliche Neuronale Netze bilden das Prinzip von Nervenzellen des Gehirns nach und bestehen aus mehreren Neuronen (auch Knoten genannt). Die Neuronen sind im Vergleich zum Gesamtsystem einfach aufgebaut und können in mehreren Schichten angeordnet sein. Durch gerichtete Verbindungen der Knoten untereinander können sich diese untereinander nach definierten Regeln aktivieren. Durch die Struktur und die Verknüpfungen der Knoten entsteht ein informationsverarbeitendes System, welches komplexe Zusammenhänge abbilden kann. Den Verbindungen der Knoten werden Gewichte zugeordnet, welche die Stärke der Verbindungen kennzeichnen. Durch dieses Verarbeitungsprinzip werden KNN u.a. in Anwendungsfeldern der Klassifikation, Funktionsapproximation und Vorhersage eingesetzt und sind bei der Anwendung von Lastprognosen weit verbreitet. Aus mathematischem Blickwinkel können Künstliche Neuronale Netze auch als spezielle Darstellungsmethode für funktionale Zusammenhänge betrachtet werden [24]. Die Netzarchitektur wird durch die für das jeweilige Netz charakteristische Verschaltungsweise der Knoten festgelegt. Es werden drei verschiedene Netzarchitekturen unterschieden [24]:

- **Feedforward-Netze:** Bei Feedforward-Netzen sind die Knoten üblicherweise in Schichten angeordnet. Die Informationsverarbeitung findet nur in eine Richtung von der Eingangsschicht hin zur Ausgangsschicht statt. Rückkoppelnde Verbindungen sind in der Netzstruktur nicht vorhanden.
- **Rekurrente Neuronale Netze (RNN):** Rekurrente Netze (auch rückgekoppelte oder rekursive Netze genannt) sind im Gegensatz zu Feedforward-Netzen durch Verbindungen von Knoten einer Schicht zu Knoten derselben oder vorgelagerten Schichten charakterisiert. Durch rekurrente Verschaltung können zeitlich codierte Informationen verarbeitet oder dynamische Systeme modelliert werden.

- **Zellförmige Netzwerke:** Bei zellförmigen Netzwerken sind die Verschaltungen nicht in bestimmten Richtungen vorhanden, sondern Knoten sind wechselseitig mit benachbarten Knoten verbunden.

Für die Abbildung von Zusammenhängen wird dem Netz ein Datensatz (Trainingsdatensatz) vorgegeben. Mit Hilfe eines für die Netzarchitekturen geeigneten Lernverfahrens (mathematischer Algorithmus) werden in einem Lernprozess (Training) die Gewichte des Netzes an den Trainingsdatensatz angepasst. Welches Lernverfahren eingesetzt wird, hängt vom Einsatzzweck des KNN ab. Prinzipiell lassen sich zwei Klassen von Lernverfahren unterscheiden [24]:

- **Überwachte Lernverfahren:** Beim überwachten Lernen werden dem Netz Eingangsdaten und dazugehörige Ausgangsdaten vorgegeben. Das KNN lernt Ein-Ausgangszusammenhänge. Anhand des verwendeten numerischen Verfahrens zur Lösung des Optimierungsproblems werden Abstiegsverfahren und stochastische Verfahren unterschieden. Bei den Abstiegsverfahren ist der weit verbreitete Backpropagation-Algorithmus zu nennen, der das Standard-Lernverfahren für Feedforward-Netze darstellt.
- **Nicht überwachte Lernverfahren:** Beim nicht überwachten Lernen werden dem Netz nur Eingangsdaten präsentiert. Das Netz soll selbständig Ausgangsdaten zuordnen. In der Regel entspricht das einer Clusteraufgabe.

Beispiele für Prognosemethoden auf der Grundlage von KNN sind in [31], [32], [36], [37], [56], [57], [141] und [142] enthalten.

2.3.1.6 Fuzzy-Modelle

Fuzzy-Modelle basieren auf der Theorie der Fuzzylogik zur Beschreibung unscharfer Mengen. Die Fuzzylogik stellt eine Erweiterung der Booleschen Logik dar. Die Zugehörigkeit von Objekten zu einer Menge wird mittels Zugehörigkeitsfunktionen definiert. Jedem Element wird dazu ein numerischer Wert als Grad der Zugehörigkeit (Unsicherheit) zugeordnet. Zur Beschreibung der Unsicherheit werden linguistische Formulierungen, z. B. in Form von Regeln, verwendet. Diese Regeln werden in ein mathematisches Modell integriert. Die Regeln liegen vorwiegend in Form von WENN *Prämisse* DANN *Konklusion* vor, wodurch linguistische Formulierungen umgesetzt werden können. Fuzzy-Systeme kommen in Anwendungsfeldern der Regelungstechnik, Klassifikation und Funktionsapproximation zur Anwendung. Der prinzipielle Aufbau eines Fuzzy-Systems unterteilt sich in die Bereiche Fuzzifizierung, Regelwerk und Inferenz sowie Defuzzifizierung. Bei der Fuzzifizierung werden scharfe (quantitative) Eingangswerte über Zugehörigkeitsfunktionen in eine oder mehrere unscharfe Größen umgewandelt. Die Inferenz ist die Methode der Regelverarbeitung des zugrundeliegenden Regelwerks von WENN-DANN-Regeln. Dieses Regelwerk umfasst das Wissen über den zu modellierenden Prozess. Das Regelwerk muss dabei vollständig, richtig und widerspruchsfrei sein. Mit Hilfe des Regelwerkes und der Zugehörigkeitsfunktionen wird eine unscharfe Ausgangsgröße ermittelt. Während der Defuzzifizierung werden aus der unscharfen Ausgangsmenge der Inferenz wieder konkrete quantitative Stellwerte/Prognose erzeugt [105], [106], [143], [144].

2.3.1.7 Hybride Ansätze

Hybridansätze sind ebenfalls weit verbreitet bei der Anwendung von Lastprognosen und kombinieren zwei oder mehrere unterschiedliche Modellansätze, um Schwächen einzelner Modellansätze zu

kompensieren. In der Literatur finden sich zahlreiche Kombinationen von Modellansätzen. Im folgenden Abschnitt werden einige in der Literatur beschriebene Kombinationen aufgezählt. Eine Auswahl an etablierten Kombinationen für KNN und Fuzzy-Logik wird kurz erläutert. Eine Zusammenfassung von hybriden Ansätzen ist in der Tabelle 2.4 aufgelistet, ohne den Anspruch auf Vollständigkeit zu erheben.

Kombinationen mit KNN

Einen Überblick über hybride Ansätze der Lastprognose mit Künstlichen Neuronalen Netzen gibt [45]. Dabei werden fünf hybride Ansätze unterschieden, bei denen Künstlichen Neuronalen Netzen jeweils mit Fuzzy-Logik, Support Vector Machine, Künstlichem Immunsystem, Genetischen Algorithmen und Particle Swarm Optimization kombiniert werden.

Kombinationen von KNN und Fuzzy-Logik

Die Kombination von KNN und Fuzzy-Modellen zu Neuro-Fuzzy-Modellen ergeben in einem hybriden Ansatz verschiedene Vorteile. Die Vorteile liegen in der Kombination der Lernfähigkeit neuronaler Netze und der gleichzeitigen Integration von vorhandenem Wissen bei Fuzzy-Systemen. Modellansätze solcher Neuro-Fuzzy-Modelle sind ANFIS-Modelle (adaptive neuro-based fuzzy inference system [46], [52] und [111]), ARIC-Modelle (Approximate Reasoning based Intelligent Control [106] und [107]), EfuNN-Modelle (Evolving Fuzzy Neural Network [108]) und DENFIS-Modelle (Dynamic Evolving Neural-Fuzzy Inference System [109] und [110]).

Tabelle 2.4: Auswahl von Kombination von hybriden Modellansätzen

Kombinationen von Modellansätzen		Beispiele und Literaturquellen
KNN	Fuzzylogik	<ul style="list-style-type: none"> • [32], [47], [106], [107] • ANFIS-Modell [46], [52] • ARIC-Modell [106], [107] • EfuNN-Modell [108] • DENFIS-Modell [109], [110]
	Support Vector Machine	[47]
	Alternative Lernverfahren	<ul style="list-style-type: none"> • Genetische Algorithmen [47] • Particle Swarm Optimization [47] • Künstliches Immunsystem [37], [47]
	Wavelet-Transformation	[31], [60]
Fuzzylogik	Particle Swarm Optimization	[48]
Fuzzylogik	Support Vector Regression	[49], [40]
Fuzzylogik	Genetische Algorithmen	[38], [51]
Fuzzylogik	Lineare stochastische Signalmodelle	[15]
Support Vector Machine	ARIMA	[53], [59]

2.3.2 Zusammenfassung und wichtigste Erkenntnisse

Im Abschnitt 2.3.1 werden verschiedene Ansätze der Zeitreihenmodellierung vorgestellt. Diese bilden die Grundlage der Lastprognose. Es wird diskutiert, für welche Anwendungsfälle welcher Modellansatz geeignet ist und aus welchem Grund. Die Tabelle 2.5 gibt einen zusammenfassenden Überblick der Ansätze zur Zeitreihenmodellierung und deren Einsatzrelevanz.

Tabelle 2.5: Überblick von Ansätze zur Zeitreihenmodellierung

Deterministische Zeitreihenmodelle	
<ul style="list-style-type: none"> • Universell einsetzbar • Einfacher Modellansatz • Abbildung einfacher funktionaler Zusammenhänge 	
Lineare stochastische Zeitreihenmodelle	
<ul style="list-style-type: none"> • Einfacher Modellansatz mit guter Interpretierbarkeit • Abbildung linearer Zusammenhänge und stochastischer Zeitreihenkomponenten • Abbildung innerer Zusammenhänge und Zusammenhänge zu exogenen Größen • Gut auf Problemspezifika zu erweiternder Modellansatz 	
Nichtlineare stochastische Zeitreihenmodelle	
Sonstige Methoden	Methoden der künstlichen und computergestützten Intelligenz
<ul style="list-style-type: none"> • Einfache Implementierung • Abbildung nichtlinearer Zusammenhänge oder Heteroskedastizität (nicht konstante Varianz) • Information über Nichtlinearität muss i. d. R. bekannt sein 	<p>KNN:</p> <ul style="list-style-type: none"> • Abbildung komplexer nichtlinearer Zusammenhänge • Black-Box-Modell (keine Interpretierbarkeit, Nachvollziehbarkeit nicht gegeben) • Minimum an a-priori-Wissen notwendig <p>Fuzzy-Modelle</p> <ul style="list-style-type: none"> • Abbildung nichtlinearer Zusammenhänge (Hohe Komplexität bei großen Systemen) • A-priori-Wissen nutzbar (Regelwissen muss verfügbar sein) <p>Support Vector Regression</p> <ul style="list-style-type: none"> • Abbildung nichtlinearer Zusammenhänge <p>Hybride Ansätze</p> <ul style="list-style-type: none"> • Kombination von zwei oder mehreren unterschiedlichen Modellansätzen

Eine quantitative Bewertung der Relevanz der aufgeführten Modellansätze hinsichtlich Prognose preisbeeinflusster Lastzeitreihen und damit der Abbildung der Prozessdynamik sowie der speziellen Zeitreihencharakteristik findet im Rahmen der Arbeit nicht statt.

Modellauswahl

Der Untersuchungsschwerpunkt der vorliegenden Arbeit liegt auf den **stochastischen Zeitreihenmodellen**, welche auf den ARIMAX- und TAR-Modellen aufbauen. Diese bieten einen vielseitig erprobten, gut interpretierbaren und bezüglich der prozessklassenspezifischen Modellkomponenten gut zu erweiternden Modellansatz. Im Hinblick auf das Prozessverständnis, die mathematische Modellierung und die modellbasierte Analyse der funktionalen Zusammenhänge für die zu untersuchenden Prozessklasse sind die stochastischen Zeitreihenmodelle substanziell für die Beantwortung der im Abschnitt 1.4 gestellten Forschungsfragen geeignet. Die Eignung komplexerer Modellansätze, wie Künstliche Neuronale Netze, Support Vector Regression oder hybride Ansätze ist im Hinblick auf eine geeignete Modellierung preisbeeinflusster Verbraucher und die resultierende Prognosequalität in weiterführender Forschungsarbeit zu prüfen.

3 Preisbeeinflusstes Verbrauchsverhalten

3.1 Einsatzgebiete für neue Prognosemethoden

Im Abschnitt 3.1 werden Einsatzgebiete und potenzielle Anwendungsfälle für Prognosen von preisbeeinflusstem Verbrauchsverhalten im Energiesystem diskutiert. Dabei wird der Frage nachgegangen, wie ein Szenariorahmen in Kontext der Fragestellung der vorliegenden Arbeit abgesteckt werden kann. Es ist zu beleuchten, welche Akteure für eine Initiierung von DSM in Frage kommen, wie der mögliche Nutzen von DSM für potenzielle Akteure aussieht und ob sich daraus unterschiedliche Anwendungsfälle für die Prognose ergeben.

Vor dem Hintergrund des steigenden Anteils fluktuierender Erzeugung und der damit verbundenen Zielstellung einer vollständigen bzw. größtmöglichen Integration erneuerbarer Energien stellt DSM eine Maßnahme zur Flexibilisierung des Energieversorgungssystems dar. In diesem Zusammenhang können folgende Gründe angeführt werden, die für eine Flexibilisierung von Lasten und damit für eine Verbrauchsbeeinflussung sprechen [78]:

- Technische Gründe wegen Überlastung von Netzbetriebsmitteln,
- Kommerzielle Gründe zur Vermeidung kostspieliger Einspeise-Last-Situationen (z.B. Lastspitzen oder Lastüberschuss) oder aufgrund vertraglicher Restriktionen sowie
- Ökonomische Gründe zur optimalen Ausnutzung erneuerbarer Energien und Stabilisierung des Strompreises und des Marktwertes erneuerbarer Energien.

Weiterhin stellt sich die Frage nach den Einsatzgebieten für flexible Lasten und damit für die Beeinflussung des Verbrauchsverhaltens. In [113] werden verschiedene Einsatzgebiete diskutiert. Folgende mögliche Einsatzgebiete können angeführt werden:

- Strommarkt: Grundsätzlich bietet die Ausgestaltung von Day-Ahead- und Intraday-Märkten die Voraussetzungen für die Nutzung von flexiblen Lasten.
- Bilanzkreismanagement: Im Rahmen eines Bilanzkreismanagements können flexible Lasten im Portfolio des Bilanzkreisverantwortlichen einen Beitrag zum Ausgleich der Abweichungen des geplanten Verbrauchs und der geplanten Erzeugung leisten und somit die Risiken einer Fahrplanabweichung minimieren.
- Regelleistungsmarkt und Systemdienstleistungen: Flexible Lasten können grundsätzlich für die Erbringung von Regelenergie eingesetzt werden. Voraussetzung dafür ist die Einhaltung der Vorgaben der entsprechenden Produktdefinition. Weiterhin ist der Einsatz für andere Systemdienstleistungen wie Engpassbehebung möglich.

Die aufgeführten Gründe für eine Flexibilisierung der Verbraucherseite und die potenziellen Einsatzgebiete lassen eine prinzipielle Unterscheidung in marktgeführten oder netzgeführten Einsatz von DSM-Maßnahmen zu. In beiden Fällen werden jedoch Prognosen benötigt, die den beeinflussten Verbrauch vorhersagen können. Mit dem Fokus der vorliegenden Arbeit auf der Prozessklasse von *Verbraucherprozessen mit indirekter Beeinflussung mittels Preiszeitreihen* lassen sich aus Sicht der Prognoseaufgabe keine unterschiedlichen Modellansätze aufgrund der Einsatzgebiete von marktgeführten oder netzgeführten Einsatz von DSM-Maßnahmen ableiten. Die Motivation für die Beeinflussung von Verbrauchern mittels Preiszeitreihen hat letztlich keinen Einfluss auf die resultierende Charakteristik der beeinflussten Lastzeitreihen. Einfluss auf das zu entwerfende Modell

haben charakteristische Prozesseigenschaften und die zeitliche Verfügbarkeit der Daten. Der vorgestellte Ansatz zur Prognose von beeinflusstem Verbrauchsverhalten kann also für beide Einsatzgebiete eingesetzt werden.

3.2 Systemtechnische Betrachtung

Für die Beschreibung von beeinflussten Zeitreihen wird das Komponentenmodell aus Gleichung (2.2) um ein weiteres Zeitreihenelement erweitert, um den Preiseinfluss separat mittels einer Zeitreihenkomponente modellieren zu können. Die beeinflusste Zeitreihenkomponente $y_R[k]$ beschreibt den Anteil der Zeitreihe, der direkt oder indirekt durch Anreiz- oder Steuersignale verändert werden kann und die Abweichung vom normalen Verbrauchsverhalten erklärt. Die unbeeinflusste Zeitreihenkomponente $y_U[k]$ und die beeinflusste Zeitreihe $y[k]$ können nun folgendermaßen dargestellt werden:

$$y_U[k] = f(y_T[k], y_P[k], y_S[k], y_M[k]) \quad (3.1)$$

und

$$y[k] = f(y_T[k], y_P[k], y_S[k], y_M[k], y_R[k]) \quad (3.2)$$

- mit:
- $y_T[k]$ - durch Polynomansatz beschreibbare Zeitreihenkomponente,
 - $y_P[k]$ - durch periodischen Ansatz beschreibbare Zeitreihenkomponente,
 - $y_S[k]$ - durch stochastisches Signalmodell beschreibbare Zeitreihenkomponente,
 - $y_M[k]$ - musterbasierte Zeitreihenkomponente und
 - $y_R[k]$ - beeinflusste Zeitreihenkomponente.

Als Grundlage für die Entwicklung von Prognosemethoden wird der zugrundeliegende beeinflusste Prozess genauer untersucht. Das Zusammenspiel von preisbeeinflusstem Verbraucherverhalten, dessen Vorhersage sowie die darauf basierende Betriebsplanung inklusive der Preisbildung wird in einem Gesamtkonzept systemtechnisch aufgearbeitet. Dabei werden die Wechselwirkungen und Rückkopplungen von Preisbildung, preisbeeinflussten Verbrauchern sowie der Vorhersage von preisbeeinflusstem Verbrauchsverhalten unter Berücksichtigung der jeweiligen Einflussgrößen detailliert beschrieben. In Abbildung 3.1 ist das systemtechnisch aufgearbeitete Gesamtkonzept, bestehend aus beeinflusstem Verbrauchsprozesses, Prognosemodell und Betriebsplanungsinstanz, skizziert [68].

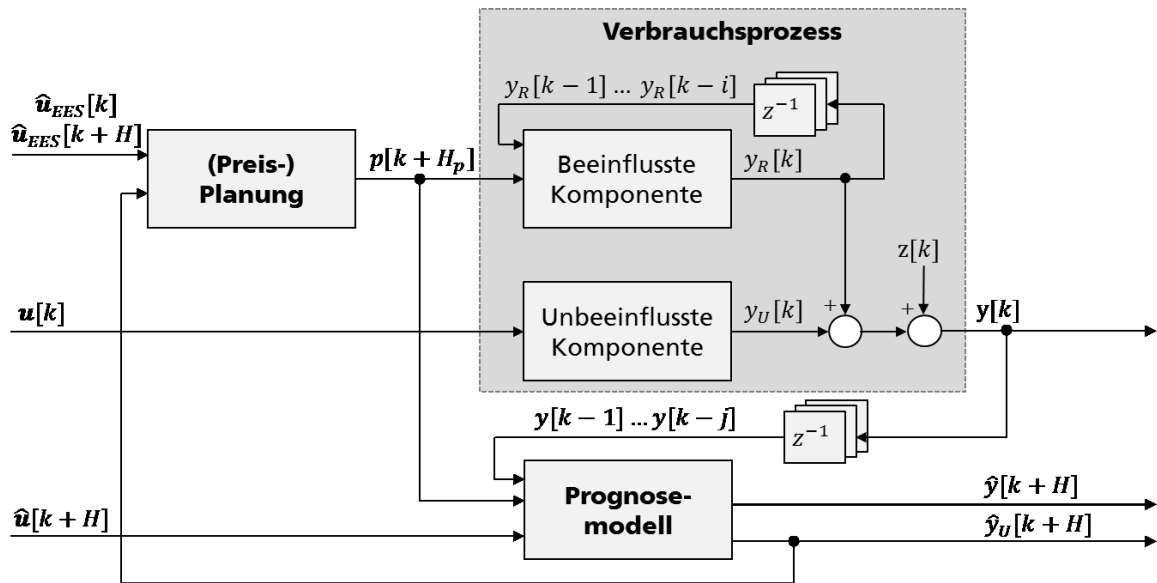


Abbildung 3.1: Systemtechnisch aufgearbeitetes Gesamtkonzept, bestehend aus beeinflusstem Verbrauchsprozess, Prognosemodell und Betriebsplanungsinstanz (modifiziert nach [59], [68])

Das Gesamtkonzept umfasst die Blöcke Planung, Verbrauchsprozess und Prognosemodell mit deren Abhängigkeiten und Wechselwirkungen.

Die in Abbildung 3.1 gezeigten Größen haben folgende Bedeutung:

- $u[k]$ – Vektor verschiedener Einflussgrößen,
- $\hat{u}[k]$ – Prognosevektor verschiedener Einflussgrößen,
- $\hat{u}_{EES}[k]$ – Eingangsvektor des elektrischen Energiesystems als Prognosen,
- $z[k]$ – Störgröße,
- $y_R[k]$ – beeinflusste Zeitreihenkomponente,
- $y_U[k]$ – unbeeinflusste Zeitreihenkomponente,
- $y[k]$ – beeinflusste Lastzeitreihe,
- $p[k]$ – Anreiz- bzw. Preiszeitreihe,
- H – Vorhersagehorizont,
- H_p – Horizont, für den die Preiszeitreihe im Vorfeld bekannt ist,
- $y_R[k-1], \dots, y_R[k-i]$ – Vergangenheitswerte von $y_R[k]$,
- $y[k-1], \dots, y[k-n]$ – Vergangenheitswerte von $y[k]$,
- z^{-1} – Verschiebeoperator $y_R[k-1] = z^{-1}y_R[k]$,
- $\hat{y}_U[k+H]$ – Prognose des unbeeinflussten Zeitreihenanteils und
- $\hat{y}[k+H]$ – Prognose der beeinflussten Lastzeitreihe.

Verbrauchsprozess

Das Verbrauchsverhalten ist abhängig von verschiedenen Einflussgrößen, die durch den Vektor $u[k]$ repräsentiert werden. Diese Einflussgrößen können meteorologischen Größen wie Temperatur und Globalstrahlung, tageszeitabhängigen und saisonalen Faktoren in Form des Tagestyps und der Uhrzeit, aber auch singuläre Faktoren wie Sonderereignisse (z.B. Sportereignisse oder Naturkatastrophen) umfassen. Zur Beschreibung der Einflüsse exogener Größen sowie der spezifischen cha-

rakteristischen Eigenschaften einer Lastzeitreihe bietet das Komponentenmodell (3.1) einen allgemeingültigen Ansatz. Ausgehend davon, dass Anreize durch Preiszeitreihen gesetzt werden, ist die einflussnehmende Preiszeitreihe $p[k]$ das Ergebnis der Betriebsplanung. Die beobachtbare Größe $y[k]$ als Ausgangsgröße des beeinflussten Verbrauchsprozesses, die sich in Abhängigkeit exogener Größen $u[k]$ und der Preiszeitreihe $p[k]$ einstellt, kann als Funktion der unbeeinflussten und des beeinflussten Zeitreihenanteile $y_U[k]$ und $y_R[k]$ wie folgt abgebildet werden:

$$y[k] = f(y_R[k], y_U[k]). \quad (3.3)$$

Die Zeitreihenkomponenten $y_U[k]$ und $y_R[k]$ sind dabei nicht separat messbar. Die beeinflusste Lastzeitreihe $y[k]$ ist Ausgangsgröße eines Verbrauchsprozesses, welcher neben deterministischen Anteilen auch einen stochastischen Anteil besitzt. Der stochastische Anteil wird durch die Störgröße $z[k]$ repräsentiert. Eine vorteilhafte Funktion bzw. Verknüpfung der einzelnen Zeitreihenkomponenten aus den Gleichungen (3.1), (3.2) und (3.3) stellt die additive Verknüpfung dar. Im Fall einer multiplikativen Verknüpfung der einzelnen Zeitreihenkomponenten wird die Überführung in ein additives Modell durch Logarithmierung angestrebt [14], [15]. In den folgenden Untersuchungen der vorliegenden Arbeit wird davon ausgegangen, dass ein additives Komponentenmodell besteht oder in ein solches überführt werden kann. Die beeinflusste Zeitreihe ergibt sich aus folgender Gleichung:

$$\begin{aligned} y[k] &= y_T[k] + y_P[k] + y_S[k] + y_M[k] + y_R[k] \\ &= y_U[k] + y_R[k] \end{aligned} \quad (3.4)$$

- mit:
- $y[k]$ - beeinflusste Lastzeitreihe,
 - $y_T[k]$ - durch Polynomansatz beschreibbare Zeitreihenkomponente,
 - $y_P[k]$ - durch periodischen Ansatz beschreibbare Zeitreihenkomponente,
 - $y_S[k]$ - durch stochastisches Signalmodell beschreibbare Zeitreihenkomponente,
 - $y_M[k]$ - musterbasierte Zeitreihenkomponente und
 - $y_R[k]$ - beeinflusste Zeitreihenkomponente.

Die in Abbildung 3.1 aufgeführte beeinflusste Verbrauchskomponente stellt den beeinflussbaren Anteil der Verbraucherseite dar. In Abhängigkeit der Eingangsgrößen ist die beeinflusste Zeitreihenkomponente $y_R[k]$ das Resultat des beeinflussten Anteils des Verbrauchs und wird, wie folgt, berechnet:

$$y_R[k] = f(p[k-j], \dots, p[k+H_p], y_R[k-1], \dots, y_R[k-i], k) \quad (3.5)$$

- mit:
- $p[k]$ - Anreiz- bzw. Preiszeitreihe,
 - $y_R[k-1]$ bis $y_R[k-i]$ - Zeitreihenvergangenheit von y_R ,
 - H_p - Horizont für den die Preiszeitreihe im Vorfeld bekannt ist,
 - k - Index des Zeitpunktes.

Die beeinflusste Zeitreihenkomponente ergibt sich als Reaktion auf eine sich zeitlich verändernde Preiszeitreihe $p[k]$ und entspricht der Abweichung vom normalen unbeeinflussten Verbrauchsverhalten. Bei unbeeinflusstem Verbrauchsverhalten wird die Verbraucherlast nicht von einem Anreiz- bzw. Preis- oder Steuersignal beeinflusst. Ist die Preiszeitreihe über einen längeren Zeitraum konstant, dann stellt sich unbeeinflusstes Verbrauchsverhalten ein. In diesem Fall ergibt sich die beeinflusste Zeitreihenkomponente zu $y_R[k] = 0$ (und $y[k] = y_U[k]$), da keine Veranlassung für eine Lastveränderung besteht. Weiterhin ist neben dem aktuellen Zeitpunkt (siehe Abschnitt 3.4.1) der Einfluss der eigenen Zeitreihenvergangenheit in Form von historischen Werten der beeinflussten Zeitreihenkomponente $y_R[k-1], \dots, y_R[k-i]$ auf die Verbraucherreaktion $y_R[k]$ relevant, da potenziell zur Verfügung stehendes Potenzial zur Lastverschiebung zum Zeitpunkt k abhängig von bereits abge-rufener Leistung vergangener Zeitpunkte $k-1, \dots, k-i$ ist. Dieser Effekt des Speicherverhaltens bei Lastverschiebung wird im Abschnitt 3.4.2 genauer beschrieben.

In [139] wird ein Konzept für die datengetriebene Analyse und Modellierung des Verbrauchsverhaltens als Reaktion auf variable Stromtarife vorgestellt. Das Konzept besteht aus verschiedenen Vorverarbeitungs-, Analyse und Modellierungsmethoden und behandelt die Prozesskette von der Erfassung der Smart-Meter-Rohdaten bis hin zur Analyse und Modellierung des preisbeeinflussten Verbrauchsverhaltens. Das Zeitreihen-Clustering wird als wichtiger Bestandteil vorgestellt und erlaubt Aussagen über saisonale, wochen- und typtagabhängige, tarifbedingte Unterschiede für eine DR-Maßnahme. Die Fragestellungen der Prognose und der Dekomposition in beeinflusste und unbeeinflusste Zeitreihenkomponenten bleiben dabei offen und werden in Ergänzung mit [139] im Rahmen der vorliegenden Arbeit untersucht.

Planung

Die einflussnehmende Preiszeitreihe $p[k+H_p]$ beim DSM ist das Ergebnis einer Betriebsplanung. Die Preiszeitreihe wird je nach Einsatzgebiet (siehe Abschnitt 3.1) durch die Planung generiert. Mittels geeigneter Optimierungsansätze berücksichtigt die Berechnung der Preiszeitreihen verschiedene verfügbaren Prognosen von Einflussgrößen auf das elektrische Energiesystem $\hat{\mathbf{u}}_{EES}[k]$ wie z. B. bestehende Netzrestriktionen, Marktkriterien oder die aktuellen Erzeugungs- und Lastprognosen. H_p ist dabei der Planungshorizont, für den die Preiszeitreihen im Vorfeld berechnet und den Verbrauchern vorgegeben werden. Beim Übergang von einer bedarfsfolgenden Erzeugung, hin zu einer Anpassung der Verbraucherseite an eine gegebene Erzeugung aus erneuerbaren Energien, richtet sich die Preiszeitreihenermittlung eher an der Erzeugungssituation (siehe Abschnitt 2.1.2) aus. Außerdem wird durch die Planung die Entscheidung zu einer Lastbeeinflussung getroffen. Um die Beeinflussung der Verbraucherseite zu planen und dafür eine Preiszeitreihe zu erzeugen, wird zunächst eine Vorhersage des unbeeinflussten Verbrauchsverhaltens $\hat{y}_U[k+H]$ benötigt. Erfüllt die Prognose der unbeeinflussten Verbraucherlast die Ansprüche der planenden Akteure (z.B. keine Verletzung von Netzrestriktionen oder unkritische Einspeise-Last-Situation), dann besteht keine Notwendigkeit für eine Verbrauchsbeeinflussung. Die Prognose der unbeeinflussten Zeitreihenkomponente $\hat{y}_U[k+H]$ bildet somit die Grundlage der Betriebsplanung bzgl. der Preiszeitreihenberechnung. Die Preiszeitreihe für einen beliebigen Planungshorizont H ergibt sich als Funktion der prognostizierten unbeeinflussten Zeitreihenkomponente $\hat{y}_U[k+H]$ und der Einflussgrößen des elektrischen Energiesystems $\hat{\mathbf{u}}_{EES}[k+H]$ nach folgender Gleichung:

$$p[k+H] = f(\hat{y}_U[k+H], \hat{\mathbf{u}}_{EES}[k+H]) \quad (3.6)$$

Einen Ansatz zur Planung eines optimalen Preises wird in [140] aus der Perspektive der Netzbetriebsplanung eines Verteilnetzbetreibers vorgestellt. Dabei erfolgen die Planung und damit die Preisbildung mit Hilfe einer Kostenoptimierung und Lastflussberechnungen des elektrischen Energieversorgungsnetzes.

Prognosemodell

Bei einer Beeinflussung der Verbraucherseite wird je nach Einsatzgebiet eine Preiszeitreihe auf Grundlage der aktuellsten Information gebildet. Wie weit in die Zukunft das Anreizsignal gebildet wird, hängt ebenfalls vom Einsatzgebiet und dem damit verbundenen DSM-Programm (siehe Abschnitt 3.1) ab. Die Eingangsgrößen für die Planung und die Eingangsgrößen für das Verbrauchsverhalten können dabei völlig unterschiedlich sein. Für das Prognosemodell sind die Eingangsgrößen der Planung unbekannt. Es werden Vorhersagen benötigt, um aus energiewirtschaftlichen und energiesystemtechnischen Gesichtspunkten die elektrische Last zur Einhaltung des permanenten Gleichgewichtes von Erzeugung und Verbrauch optimal zu beeinflussen. Die Prognose des unbeeinflussten Lastanteils $\hat{y}_U[k+H]$ bildet somit die Grundlage der Planungsentscheidung und der damit verbundenen Quantifizierung der Lastbeeinflussung mit Hilfe der Preiszeitreihenberechnung. Durch die wechselseitigen Auswirkungen der Lastprognose auf die Preiszeitreihenberechnung und wiederum von der Preiszeitreihe auf das Verbrauchsverhalten ergibt sich eine Rückkopplung. Durch die Systemrückkopplung besteht die Gefahr eines ansteigenden Schwingens des Systems. Die Dynamik bei der Preisgestaltung kann sich auf das Schwingungsverhalten des Systems auswirken. Inwieweit die Preisdynamik, beispielsweise durch eine längere feste Vorlaufzeit, in der die Preise fest determiniert werden, Effekte auf die Stabilität des Gesamtsystems aus Abbildung 3.1 hat, wird in der vorliegenden Arbeit nicht untersucht. Ein Stabilitätsnachweis im Rahmen von Untersuchungen des Gesamtsystems und damit verbunden das Zusammenspiel von Verbrauchsprozess (mit der Dynamik des preisbeeinflussten Verbraucherverhaltens), dessen Vorhersage (inklusive der eintretenden Fehlerdynamik) sowie die zugrundeliegende Betriebsplanung (inklusive der Preisbildung), ergeben vielversprechende Anknüpfungspunkte an die vorliegende Arbeit und konstatieren somit weiterführenden Forschungsbedarf.

Je nach Einsatzgebiet und Verwendungszweck wird neben der Prognose der unbeeinflussten Zeitreihenkomponente $\hat{y}_U[k+H]$ auch die Prognose der beeinflussten Lastzeitreihe $\hat{y}[k+H]$ berechnet. Die Anforderung an das Prognosemodell in Abbildung 3.1 besteht somit in der Vorhersage des beeinflussten und des unbeeinflussten Verbrauchsverhaltens $\hat{y}[k+H]$ und $\hat{y}_U[k+H]$ auf Basis der Prognose der exogenen Größen $\hat{u}[k+H]$, der Preiszeitreihe $p[k+H_p]$ und historischer Werte des beeinflussten Verbrauchsverhaltens $y[k-1]$ bis $y[k-n]$. In den nachfolgenden Abschnitten werden die Charakteristika von beeinflusstem und unbeeinflusstem Verbrauchsverhalten genauer erläutert. Die Prognose im Rahmen des Gesamtkonzeptes aus Abbildung 3.1 ergibt den zentralen Untersuchungsgegenstand der vorliegenden Arbeit. Dazu werden in den folgenden Abschnitten die Charakteristik des für die Prognose zu modellierenden Verbrauchsverhaltens (Abschnitt 3.3 und 3.4), die Relevanz von Methoden der Analyse (Abschnitt 3.5) und die sich ergebenden Anforderungen an zu entwickelnde Prognosemethoden (Abschnitt 3.6) detailliert diskutiert. Im Abschnitt 4 werden das Konzept und der Entwurf der entwickelten Prognosemethode vorgestellt und im Abschnitt 5 wird diese evaluiert.

3.3 Charakteristik der unbeeinflussten Lastkomponente

Für die Beschreibung von Zeitreihen und deren dynamischen Verhaltens bietet das bekannte Komponentenmodell (siehe Abschnitt 3.2) einen allgemeingültigen Ansatz [14]. Mit Hilfe des Komponentenmodells können so Zeitreihen beschrieben werden, welche eine Charakteristik speziell für das Umfeld der Energiewirtschaft aufweist. Mit Hilfe der klassischen Dekomposition werden Zeitreihen in bestimmte Grundkomponenten zerlegt. Das Komponentenmodell besteht aus den deterministischen Komponenten für den Trend $y_T[k]$ und Periode $y_P[k]$ sowie einer Komponente für die Stochastik $y_S[k]$. Die Komponenten für den Trend und Periode können Aufschluss über langfristige Veränderungen der Zeitreihen abbilden, welche beispielsweise durch konjunkturelle oder saisonale Schwankungen beim Verbrauchsverhalten verursacht werden. Die Gründe für langfristige Veränderungen können im Energiesektor beispielsweise auf einen erhöhten Beleuchtungs- und Heizbedarf im Winter oder Schwankungen der gesamtwirtschaftlichen Lage zurückgeführt werden. Der Verlauf von Lastzeitreihen ist jedoch maßgeblich charakterisiert von kurzfristigen Periodizitäten, welche durch Unterschiede im zeitlichen Bedarf der elektrischen Leistung entstehen. Diese entstehen beim Stromverbrauch aufgrund des individuellen Verbrauchsverhaltens von Haushalten, Gewerbe und Industrie. Es ergeben sich tagestypische Lastverläufe und somit Zusammenhänge zwischen dem Verbrauchsverhalten und Typtagen (Kalendereffekte) wie Werktagen, Samstagen, Sonntagen oder Feiertagen. Beispielsweise ist ein charakteristischer Wochenrhythmus typisch für Lastzeitreihen im Umfeld der Energiewirtschaft. Dieser ist gekennzeichnet durch unterschiedliche Lastniveaus und Verbrauchsmuster an Werktagen und Wochenenden. Zusätzlich kann ein vorliegender Wochenrhythmus durch ein ähnliches Bedarfsverhalten der einzelnen Wochentage im Vergleich zur Vorwoche erklärt werden oder es besteht eine Ähnlichkeit zwischen den Werktagen [15], [69], [70], [71], [94].

Weiterhin ergeben sich Unterschiede im Bedarf in Abhängigkeit der Tageszeit (Tagesrhythmus). Tagesverläufe der Last sind typischerweise geprägt von einem nichtlinearen Verbrauch, beispielsweise mit ausgeprägter Nachtabenkung sowie markanten Morgen- und Abendspitzen [15], [69], [70], [71], [94].

Neben der Zeit als Einflussfaktor sind weitere exogene Einflussgrößen möglich, die das Verbrauchsverhalten beeinflussen können. Sind beispielsweise bei Gruppen von Stromverbrauchern Klimaanlage oder elektrische Heizungen verbreitet, ist eine funktionale Abhängigkeit des Stromverbrauchs zur Temperatur zu erwarten. Dabei sind Sättigungseffekte zu beachten, wenn ab sehr hohen oder sehr niedrigen Temperaturen das gesamte Potenzial an Heiz- bzw. Kühlleistung ausgeschöpft ist und so eine Erhöhung des Bedarfs aufgrund von Klimaanlage oder elektrische Heizungen nicht mehr möglich ist. Wie stark exogene Größen das Verbrauchsverhalten beeinflussen oder welche exogenen Größen überhaupt Einfluss haben, kann in Abhängigkeit der Zusammensetzungen von Verbrauchergruppen sehr unterschiedlich sein.

Die stochastische Zeitreihenkomponente $y_S[k]$ des Komponentenmodells beschreibt zufällige Einflüsse. Zeitreihen, welche durch das Komponentenmodell beschrieben werden sollen, können als zeitlich geordnete Daten eines stochastischen Prozesses aufgefasst werden. Dabei können die Stochastik und die spezielle Struktur des Prozesses durch Modelle beschrieben werden und so bestimmte Eigenschaften aufweisen. Weist beispielsweise ein stochastischer Prozess autoregressives Verhalten auf, dann sind seine Werte von einem oder mehreren Vergangenheitswerten abhängig. Modellansätze für lineare stochastische Prozesse werden im Abschnitt 2.3.1.2 aufgeführt. Durch die Erweiterung des klassischen Komponentenmodells um eine Musterkomponente $y_M[k]$ [15] ist

die Beschreibung musterbasierter Zeitreihen möglich. Bei einer musterbasierten Zeitreihe sind Teilbereiche durch typische, wiederkehrende Teilverläufe (Muster) klassifizierbar und beschreibbar [94]. Diese Muster können periodisch oder auch nichtperiodisch auftreten und lineare und nichtlineare Ausprägungen annehmen [15], [50], [70], [71], [94].

3.4 Charakteristik der preissensitiven Lastkomponente

Es ist davon auszugehen, dass Anreize in der Praxis monetär in Form von Preiszeitreihen gesetzt werden. Im Abschnitt 2.1.2 werden verschiedene zeitvariable Tarifmodelle vorgestellt. Mit der Einführung von zeitvariablen Tarifen wird angenommen, dass nach einer gewissen Übergangszeit ein Regimewechsel eintritt, bei dem eine Änderung des Verbrauchsverhaltens stattfindet. In dieser Übergangszeit werden sich Verbraucher in ihrem Verbrauchsverhalten auf der bisherigen Grundlage fester Stromtarife, bei denen der Zeitpunkt der Leistungsabnahme für die Verbraucher zu vernachlässigen war, auf variable Stromtarife einstellen. Der Regimewechsel ist die Folge des sich ändernden Verbrauchsverhaltens und der damit verbundenen geänderten Verbrauchsmuster. Im Fall von Tarifmodellen mit einer festen Tarifstruktur (z.B. TOU) kann die Modellierung und Prognose mit marktüblichen Methoden bewältigt werden, da als Reaktion auf langfristig statisch festgelegten Preisen typische Verbrauchsmuster zu erwarten sind. Es ist anzunehmen, dass sich Verbrauchsmuster als Reaktion auf den Stromtarif mit einer festen Tarifstruktur im Vergleich zu Verbrauchsmustern als Reaktion auf einen konstanten Preis unterscheiden, diese aber dennoch als typisch (mit typischem Verbrauchsmuster) für die statisch festgelegte Preise anzusehen sind. Werden Preiszeitreihen mit dynamischen Anteilen generiert, dann besteht Bedarf an neuen Prognosemethoden, die die Charakteristik des Preiseinflusses abbilden können. Das Maß für die Sensibilität der Reaktion der Verbraucher auf Preisänderungen wird dabei als Preiselastizität bezeichnet und das beeinflusste Verbrauchsverhalten als preissensitives Verbrauchsverhalten.

In den folgenden Abschnitten 3.4.1 bis 3.4.4 werden die Eigenschaften der Preiselastizität und dem resultierenden preissensitiven Verbrauchsverhalten aufgeführt und analysiert. Mit dem Ziel der Modellierung und Prognose von preissensitivem Verbrauchsverhalten ergeben sich daraus spezifische Anforderungen an die zu entwickelnden Prognosemethoden, die in Abschnitt 3.6 zusammengefasst werden.

3.4.1 Preiselastizität

Ist das Verbrauchsverhalten durch Preisanreize beeinflussbar, dann stellt sich als Reaktion auf eine Preisänderung eine Laständerung ein. Wie stark die Laständerung dabei ausgeprägt ist, hängt von der Preiselastizität ab. Die Wirtschaftstheorie besagt, wenn der Energiepreis steigt, dann fällt der Energiebedarf, wenn alle anderen Faktoren konstant bleiben. Die Preiselastizität ist dabei ein Maß für die Sensibilität der Verbraucher, auf Preisänderungen zu reagieren, und hat typischerweise ein negatives Vorzeichen [16]. Die Preiselastizität ist die prozentuale Änderung des Verbrauchs im Verhältnis zur prozentualen Änderung des Preises und wird mit Hilfe folgender Gleichung dargestellt [75]:

$$\zeta = \frac{\Delta y/y}{\Delta p/p} = \frac{\Delta y}{\Delta p} \cdot \frac{p}{y} \quad (3.7)$$

- mit: ζ - Preiselastizität,
- y und Δy - Verbrauch und Änderung des Verbrauchs zu einem Referenzverbrauch und
- p und Δp - Preis und Änderung des Preises zu einem Referenzpreis.

Die typische Nachfragekurve, nach der die Nachfrage (meist Rohstoffe und Wirtschaftsgüter) mit steigenden Preisen abfällt, wird in Abbildung 3.2 dargestellt. Da die quantitative Bestimmung dieser Kurve schwierig ist, wird die Nachfragekurve in der Ökonomie oft mit Hilfe von Gleichung (3.7) um einen Referenzpunkt linearisiert [77]. Der Referenzpunkt wird dabei vom Initial- bzw. Referenzpreis p_{init} und vom Initial- bzw. Referenzverbrauch y_{init} bestimmt. Die Preiselastizität kann so als relativer Anstieg der Nachfragekurve definiert werden [74]. Eine Preiselastizität von -1 bedeutet, dass bei einem Preisanstieg von 1 % die Last um 1% reduziert wird. Eine Preiselastizität von 0 bedeutet, dass der Verbrauch nicht preissensitiv ist. Die Verbraucherreaktion auf Preiseinflüsse kann nach [74], [75] und [76] in Eigenpreiselastizität ζ_{ii} und Kreuzpreiselastizität ζ_{ij} unterschieden werden. Bei der Eigenpreiselastizität in (3.8) können die Verbraucher mit einer Verbrauchsänderung unmittelbar auf eine Preisänderung im selben Zeitintervall i reagieren. Bei der Kreuzpreiselastizität (siehe Abschnitt 3.4.4) können laut Gleichung (3.9) die Verbraucher den Verbrauch zeitlich verschieben (z.B. Verschiebung des Verbrauchs von Hoch- zu Niedrigpreiszeitabschnitten). Für die Eigenpreiselastizität gilt:

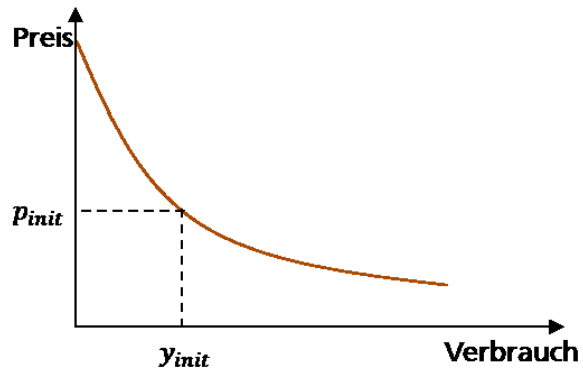


Abbildung 3.2: Typische Nachfragekurve (modifiziert nach [74] und [77])

$$\zeta_{ii} = \frac{\Delta y_i/y_{init}}{\Delta p_i/p_{init}} \quad (3.8)$$

- mit: ζ_{ii} - Eigenpreiselastizität,
- y_{init} und Δy_i - Initial- bzw. Referenzverbrauch und Änderung des Verbrauchs im Zeitintervall i und
- p_{init} und Δp_i - Initial- bzw. Referenzpreis und Änderung des Preises im Zeitintervall i .

Die Preiselastizität ist dabei von verschiedenen Faktoren abhängig und bestimmt die Charakteristik der beeinflussten Zeitreihenkomponente. Ein Einflussfaktor, der die Preiselastizität wesentlich bestimmt, ist der Zeitpunkt. Das Beeinflussungspotenzial einer Verbraucherlast kann aufgrund individuellen, uhrzeitabhängigen oder saisonalen Verbrauchsverhaltens der Haushalte, Gewerbe und der Industrie variieren. Verbraucher, deren Verbrauchsverhalten indirekt beeinflusst wird, sind

durch ihren eigenen Tagesrhythmus wie tägliche Routinen, Arbeitszeiten oder den Tag-Nacht-Rhythmus getriggert. Dementsprechend sind die Möglichkeit und die Motivation der Verbraucher, auf Preise zu reagieren, zu verschiedenen Uhrzeiten unterschiedlich, was sich in unterschiedlichen Werten der Preiselastizität quantifiziert. Aus den gleichen Gründen kann sich die Preiselastizität neben der Uhrzeit auch zu verschiedenen Typtagen unterscheiden, da sich das Verbrauchsverhalten beispielsweise an Werktagen, Feiertagen oder Wochenenden unterscheidet.

3.4.2 Speicherverhalten bei Lastverschiebung

Im Rahmen von DR können preissensitive Verbraucher als virtueller Speicher interpretiert werden [18], [115]. Das Verbraucherverhalten und die Reaktion von Verbrauchern auf monetäre Anreizzeitreihen können sich dabei als Lastverschiebung ohne eine Änderung des Energiebedarfs (P-DSM) oder mit Auswirkungen auf den Energiebedarf (PE-DSM) auswirken. Bei der Modellierung dieses Sachverhaltes als virtueller Speicher ist der aktuelle Speicherfüllstand für eine mögliche Ent- oder Beladung von entscheidender Bedeutung. Beispielsweise kann bei einem Speicherfüllstand von 0% der Speicher nicht weiter entladen und 100% nicht weiter beladen werden. Bezogen auf die preisbeeinflusste Lastzeitreihe steht der beeinflusste Lastanteil $y_R[k]$ somit in funktionaler Abhängigkeit der Zeitreihenvergangenheit des beeinflussten Lastanteils $y_R[k-1]$ bis $y_R[k-i]$ (siehe Abbildung 3.1). Aus der Zeitreihenvergangenheit des beeinflussten Lastanteils kann abgeleitet werden, wie groß der Anteil vom bereits ausgenutzten Beeinflussungspotenzial ist und somit aktuell nicht zur Verfügung steht. Bei der Interpretation des Verhaltens preissensitiver Verbraucher als virtueller Speicher liegen für das Speicherverhalten spezielle Eigenschaften und Freiheitsgrade vor. Dazu präsentiert [73] einen Ansatz zur dynamischen Modellierung des Verbrauchsverhaltens, welcher eine Speicherkomponente mit Speicherparametern wie obere und untere Speichergrenzen beinhaltet. In [18] wird ein Konzept vorgestellt, bei dem das Verbraucherverhalten von Haushaltskunden als virtueller Speicher modelliert wird. In [115] werden darauf aufbauend auf der Grundlage der Ergebnisauswertung verschiedener DR-Feldstudien mehrere Annahmen und Anforderungen für die Modellierung als virtueller Speicher gestellt. Eine wesentliche Grundannahme ist, dass das Modell nur eine Lastverschiebung ermöglicht. Eine Änderung des Energiebedarfs wird hingegen nicht zugelassen, womit nur P-DSM bei der Modellierung zulässig wäre. Eine Berücksichtigung von PE-DSM, bei dem eine Änderung des Energiebedarfs nicht ausgeschlossen ist, kann bei den Überlegungen im Rahmen der vorliegenden Arbeit allerdings nicht komplett verworfen werden. Energieeinsparungen aufgrund effizienterer Geräte, Vorgaben von regulatorischen Energieeffizienzmaßnahmen oder ein steigendes Verantwortungsbewusstsein der Bevölkerung im Umgang mit Ressourcen könnten grundsätzlich mögliche Gründe für einen sinkenden Energiebedarf darstellen. Technologien wie etwa Elektromobilität können zukünftig den Elektrizitätsbedarf erhöhen. Eine Kombination von DSM-Maßnahmen mit Wärmeumwandlung werden vor dem Hintergrund des Smart Grid Konzeptes als vielversprechende Technologie angesehen. Beispielsweise können Wärmepumpen verbunden mit thermischen Energiespeichern dazu eingesetzt werden, den Bedarf elektrischer Leistung entsprechend eines Preisanreizes zu verschieben [138]. Allerdings wird bei einer Zwischenspeicherung mittels Wärmespeicher der Energiebedarf über den Wirkungsgrad des Wärmespeichers verändert. Vor dem Hintergrund auch anderer technologischer Entwicklungen, die ebenfalls einen vielversprechenden Ansatz für den Einsatz von DSM darstellen, wie beispielsweise Elektromobilität, sind im Vorfeld weitere vielseitige und komplexe technische Aspekte zu berücksichtigen. Mit der Zielstellung der Entwicklung einer zeitreihenbasierten Prognosemethode, die allein aus Ein- und Ausgangsdaten das preisbeeinflusste Verbrauchsverhalten anlernen soll, muss

die Ermittlung eines expliziten Parameters für eine DSM-Speicherkapazität für die Modellierung im Rahmen der vorliegenden Arbeit hinterfragt werden.

Eine weitere Annahme, die in [115] aufgeführt wird, ist ein Zeitfenster, in dem die Lastverschiebung ausgeführt wird. Das Zeitfenster wird in [115] mit 24 Stunden angegeben. DSM kann demnach nicht als Mittel- oder Langfristspeicher eingesetzt werden, sondern eine Lastverschiebung ist nur in einem kurzfristigen Zeitbereich von 24 Stunden möglich. Unter der Annahme von P-DSM können Verbraucher anstehende Aktionen, welche einen Anstieg des Stromverbrauchs verursachen (z.B. Wäschetrocknen, Wäschewaschen, o.Ä. bei Haushalten), in Abhängigkeit des aktuellen Preises verschieben. Allerdings ist der zeitliche Aktionsrahmen begrenzt. Demnach wird die anstehende Aktion innerhalb des Aktionsrahmens ausgeführt, auch wenn der Preis zu diesem Zeitpunkt ungünstig ist. Diese Handlungsweise der Verbraucher spiegelt das nicht völlig ökonomisch rationale Verhalten als Reaktion auf Preisanreize wider.

Eine wesentliche Eigenschaft des preissensitiven Verbrauchsverhaltens, die explizit bei der Modellierung Berücksichtigung finden muss, ist ein begrenztes Lastverschiebungspotenzial. Nur ein begrenzter Anteil der Last ist preissensitiv und kann somit durch eine Preiszeitreihe beeinflusst werden. Die maximal mögliche Laständerung $y_{R,max}$ beschreibt die Obergrenze des beeinflussten Lastanteils. In Abschnitt 2.1.3 werden die Potenziale, die DSM bietet, genauer beschrieben und geben ein Indiz für die quantitative Ausprägung der maximal mögliche Laständerung $y_{R,max}$. Die beeinflusste Lastzeitreihe $y[k]$ kann dabei keine negativen Werte annehmen, da der beeinflussbare Anteil $y_R[k]$ nur einen Bruchteil von $y[k]$ ausmacht. Angaben zu konkreten Größenordnungen des beeinflussbaren Anteils sind in Abschnitt 2.1.3 in Abhängigkeit des eingesetzten Tarifmodells aufgeführt.

3.4.3 Auswirkungen des Planungshorizonts

Der Planungshorizont H_p ist der Zeitraum, für den die Preise im Vorfeld festgelegt werden und für die Verbraucher im Vorfeld bekannt sind. Bei einer längeren Vorlaufzeit ergibt sich eine bessere Planbarkeit der Verbraucher, sich auf Preisänderungen einzustellen, als mit einer kürzeren Vorlaufzeit. Somit ist davon auszugehen, dass die Preiselastizität und die resultierende Verbraucherreaktion in Abhängigkeit von der Vorlaufzeit entsprechend variiert. Somit besteht eine funktionelle Abhängigkeit der Verbraucherreaktion vom Planungshorizont. Der Planungshorizont hängt vom angewendeten Tarifmodell wie beispielsweise TOU, RTP oder CPP (siehe Abschnitt 2.1.2) ab.

3.4.4 Zeitversetzte Verbraucherreaktion

Bei einem kausalen Zusammenhang erfolgt die Reaktion auf ein einflussnehmendes Event unmittelbar oder mit einer Zeitverzögerung in Folge des auslösenden Events. Beispielsweise stellt sich der Einsatz von Klimaanlage aufgrund von Temperaturänderungen ein. In diesem Fall steigt der Stromverbrauch mit steigenden Temperaturen. Mit einer gewissen Zeitverzögerung (verursacht durch Reaktionszeit beim manuellen oder automatischen Ansteuern der Klimaanlage oder Wärmespeichereffekten von Gebäuden) folgt der Stromverbrauch der ansteigenden Temperatur in einem funktionalen kausalen Zusammenhang. Durch Stromtarife, bei denen den Verbrauchern die Preisinformationen mit einer entsprechenden Vorlaufzeit vorliegen, sind die reaktionsauslösenden Events vorab bekannt. Die Reaktion der Verbraucher ist nicht nur unmittelbar auf ein entsprechendes Preisevent zu erwarten. Vielmehr kann die Reaktion beispielsweise bei einer Lastverschiebung dynamisch a priori oder a posteriori zeitversetzt auftreten und führt potenziell zu „nichtkausalem“ Verbrauchsverhalten (siehe Abbildung 3.3). Die Auswirkungen des Planungshorizontes sind dabei zu beachten. In [74], [75] und [76] wird diese Eigenschaft der Preiselastizität als Kreuzpreiselastizität ζ_{ij} beschrieben. Die Kreuzpreiselastizität ist ein Maß für Verbraucherreaktion zu einem Zeitintervall i auf Preisänderungen im Zeitintervall j und ist in folgender Gleichung dargestellt:

$$\zeta_{ij} = \frac{\Delta y_i / y_{init}}{\Delta p_j / p_{init}} \quad (3.9)$$

mit: ζ_{ij} - Kreuzpreiselastizität,

y_{init} und Δy_i - Initial- bzw. Referenzverbrauch und Änderung des Verbrauchs im Zeitintervall i und

p_{init} und Δp_i - Initial- bzw. Referenzpreis und Änderung des Preises im Zeitintervall i .

Für einen preissensitiven Verbrauch über 24 Stunden mit einer Abtastzeit von 15 Minuten können die Preiselastizitäten in einer 96x96 Matrix \mathbf{Z} wie folgt dargestellt werden [75], [76]:




Abbildung 3.3: Zeitversetzte Reaktion der Verbraucher auf Preisevents

$$\mathbf{Z} = \begin{bmatrix} \zeta_{1,1} & \zeta_{1,2} & \cdots & \zeta_{1,95} & \zeta_{1,96} \\ \zeta_{2,1} & \zeta_{2,2} & \cdots & \zeta_{2,95} & \zeta_{2,96} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \zeta_{95,1} & \zeta_{95,2} & \cdots & \zeta_{95,95} & \zeta_{95,96} \\ \zeta_{96,1} & \zeta_{96,2} & \cdots & \zeta_{96,95} & \zeta_{96,96} \end{bmatrix}. \quad (3.10)$$

Dabei beschreiben die Diagonalelemente der Matrix die Eigenpreiselastizitäten und die Elemente der Nichtdiagonale die Kreuzpreiselastizität. Die Spalte j der Matrix \mathbf{Z} gibt an, wie eine Preisänderung in dem einzelnen Zeitintervall j den Verbrauch in allen anderen Zeitintervallen beeinflusst. Sind alle Elemente, die ungleich Null sind, über der Diagonalen, dann entspricht die Verbraucherreaktion auf hohe Preise einer Lastverschiebung vor dem verursachenden Preisevent. Sind alle Elemente, die ungleich Null sind, unterhalb der Diagonalen, dann wird die Last in einen Zeitbereich nach dem Preisevent verschoben. Ist das Flexibilitätspotenzial begrenzt, dann sind die Elemente, die ungleich Null sind, um die Diagonale zu den Zeitintervallen mit den niedrigsten Preisen angeordnet [77]. Der Planungshorizont hat ebenfalls Einfluss die Besetzung der Matrix \mathbf{Z} . Sind die Preise im Vorfeld nicht bekannt, dann wirkt sich das auf die Elemente oberhalb der Diagonalen aus. Die Laständerung über das Zeitintervall i als Resultat der Abweichung zum Initialpreis ergibt sich aus:

$$\Delta y_i = \sum_j^{96} \zeta_{ij} \cdot \left(\frac{\Delta p_j}{p_{init}} \right) \cdot y_{init}. \quad (3.11)$$

3.5 Relevante Methoden zur Analyse der Verbrauchscharakteristik

Die Tabelle 3.1 gibt einen Überblick über anzuwendende Methoden der Zeitreihenanalyse und deren Relevanz in Bezug auf Modellbildung im Rahmen der durchzuführenden Untersuchungen. Ziel ist die Identifikation relevanter Informationen, auf die die anstehende Modellbildung gestützt wird. Außerdem sind anzuwendende Methoden für die Analyse der Modellresiduen aufgeführt.

Tabelle 3.1: Analysemethoden und Identifikation relevanter Informationen für die Modellbildung

Analysemethode	Beschreibung	Identifikation	Relevant für Modellbildung
Grafische Darstellung (z.B. Visualisierung einer oder mehrerer Zeitreihen oder Heatmap-Darstellung)	Spezifische Abbildung eines Datensatzes, sodass die wesentlichen Eigenschaften besser zu erkennen sind	<ul style="list-style-type: none"> • Erster Eindruck • Saisonale Effekte • Augenscheinliche Auffälligkeiten • Grundlage für weitere Untersuchungen 	<ul style="list-style-type: none"> • Grundlegende Prozessinformationen
Autokorrelationsfunktion (AKF)	Beschreibung des linearen Zusammenhangs zwischen den Beobachtungswerten einer Variable unter Verschiebung des zeitlichen Abstands zwischen den Werten	<ul style="list-style-type: none"> • Aufschluss über die Abhängigkeit zu historischen Werten • Identifikation von typischen Rhythmen in der Zeitreihe 	<ul style="list-style-type: none"> • Zur Auswahl des zu verwendenden Modellansatzes • Berücksichtigung von Kalendereffekten
Autoleistungsdichtespektrum (ALDS)	Fourier-Transformation der Zeitreihe und Berechnung der spektralen Leistungsdichte (Verteilung der Signalleistung im Frequenzbereich)	<ul style="list-style-type: none"> • Identifikation der dominierenden Frequenzanteile über Identifikation von typischen Rhythmen in der Zeitreihe 	<ul style="list-style-type: none"> • Berücksichtigung von Kalendereffekten
Partielle Autokorrelationsfunktion (PAKF)	Beschreibung des linearen Zusammenhangs zwischen den Beobachtungswerten einer Variable unter Verschiebung des zeitlichen Abstands zwischen den Werten und unter Ausschaltung des Einflusses der dazwischenliegenden Werten	<ul style="list-style-type: none"> • Aufschluss über die Abhängigkeit zu historischen Werten • Identifikation von typischen Rhythmen in der Zeitreihe • Identifikation von autoregressiven Anteilen in der Zeitreihe • Aufschluss über die dynamischen und stochastischen Zeiteiheneigenschaften 	<ul style="list-style-type: none"> • Zur Auswahl des zu verwendenden Modellansatzes • Berücksichtigung von Kalendereffekten • Berücksichtigung von AR-Anteilen als Eingangsgrößen • Auswertung der Modellresiduen

Analysemethode	Beschreibung	Identifikation	Relevant für Modellbildung
Hauptkomponentenanalyse (HKA)	Überführung der Zeitreihe auf Basis eines mehrdimensionalen Merkmalsraums mittels der Hauptachsentransformation in mehrere Hauptkomponenten (Linearkombinationen der Daten und entsprechend den Eigenvektoren der Kovarianzmatrix des Datensatzes)	<ul style="list-style-type: none"> Identifikation von zusammengehörigen Zeitreihenabschnitten – je nach Anwendung z.B. Bewertung von datums- oder temperaturbezogenen relevanten Mustern (Tagestypen) 	<ul style="list-style-type: none"> Berücksichtigung von Typtagen und Kalendereffekten
Punktwolke/ x-y-Darstellung	Darstellung von Wertepaaren in einem Koordinatensystem.	<ul style="list-style-type: none"> Aufschluss über Wertebereich Aufschluss über funktionalen Zusammenhang und Streuung in den Wertepaaren 	<ul style="list-style-type: none"> Zur Auswahl des zu verwendenden Modellansatzes
Korrelationskoeffizient	Maßzahl für die Stärke des linearen Zusammenhangs zwischen zwei Variablen	<ul style="list-style-type: none"> Aufschluss über den Einfluss exogener Größen (lineare Abhängigkeit) 	<ul style="list-style-type: none"> Berücksichtigung relevanter exogener Eingangsgrößen
Kreuzkorrelationsfunktion (KKF)	Beschreibung des linearen Zusammenhangs zwischen den Beobachtungswerten zweier Variablen unter Verschiebung des zeitlichen Abstands zwischen den Werten	<ul style="list-style-type: none"> Aufschluss über den Einfluss exogener Größen (lineare Abhängigkeit) Aufschluss über den zeitlich verschobenen Einfluss von exogenen Größen 	<ul style="list-style-type: none"> Zur Auswahl des zu verwendenden Modellansatzes Berücksichtigung relevante exogener Eingangsgrößen Berücksichtigung einer zeitlichen Verschiebung von exogenen Einflüssen
Regressionsanalyse	modellbasierte Schätzung des linearen Zusammenhangs zwischen einer abhängigen und ein oder mehreren (voneinander) unabhängigen Variablen (üblicherweise Schätzung der Modellparameter über Kleinst-Quadrat-Methode oder Maximum-Likelihood-Methode)	<ul style="list-style-type: none"> Aufschluss über den Einfluss exogener Größen (lineare Abhängigkeit) Aufschluss über die Modellordnung 	<ul style="list-style-type: none"> Zur Auswahl des zu verwendenden Modellansatzes Berücksichtigung relevanter exogener Eingangsgrößen Zu verwendende Modellordnung

Analysemethode	Beschreibung	Identifikation	Relevant für Modellbildung
Klassifikation	Einteilung von Objekten anhand bestimmter Merkmale mit Hilfe einer Vorschrift bzw. eines Algorithmus	<ul style="list-style-type: none"> Identifikation typischer Klassen 	<ul style="list-style-type: none"> Hilfsmittel zur Ermittlung der Klassenkonfiguration bei urchzeitabhängiger und klassenbezogener Mehrschrittmodellierung
Kolmogoroff-Smirnoff-Test (KS-Test)	Statistischer Test zur Prüfung der Verteilungen zweier Stichproben auf Übereinstimmung der Wahrscheinlichkeitsverteilungen	<ul style="list-style-type: none"> Wahrscheinlichkeitsverteilung 	<ul style="list-style-type: none"> Hilfsmittel zur Ermittlung der Klassenkonfiguration bei urchzeitabhängiger und klassenbezogener Mehrschrittmodellierung
Histogramm	Beschreibung von absoluter oder relativer Häufigkeitsverteilung von Merkmalen in definierten Klassenbreiten	<ul style="list-style-type: none"> Aufschluss über Häufigkeitsverteilung/Verteilungsfunktion 	<ul style="list-style-type: none"> Zur Auswahl des zu verwendenden Modellansatzes Auswertung der Modellresiduen
Statistische Parameter (z.B. Mittelwert, Varianz, Standardabweichung usw.)	Beschreibung wesentlicher Informationen über die Häufigkeitsverteilung von Merkmalen über mathematische Kennwerte	<ul style="list-style-type: none"> Aufschluss über Häufigkeitsverteilung 	<ul style="list-style-type: none"> Auswertung der Modellresiduen
Test auf weißes Rauschen (z.B. mittels PAKF oder Periodogrammtest)	Prüfung, ob eine Zeitreihe die Eigenschaften des weißen Rauschens besitzt	<ul style="list-style-type: none"> Hinreichendes Kriterium für ein optimales Vorhersagemodell 	<ul style="list-style-type: none"> Auswertung der Modellresiduen

Die Abbildung 3.4 zeigt den Verarbeitungsworkflow für die Zeitreihenanalyse im Rahmen der vorliegenden Arbeit. Mit den angewendeten Methoden sollen die Auswahl des Modellansatzes, die Festlegung der Modellstruktur und die Wahl der Eingangsbelegung ermittelt werden.

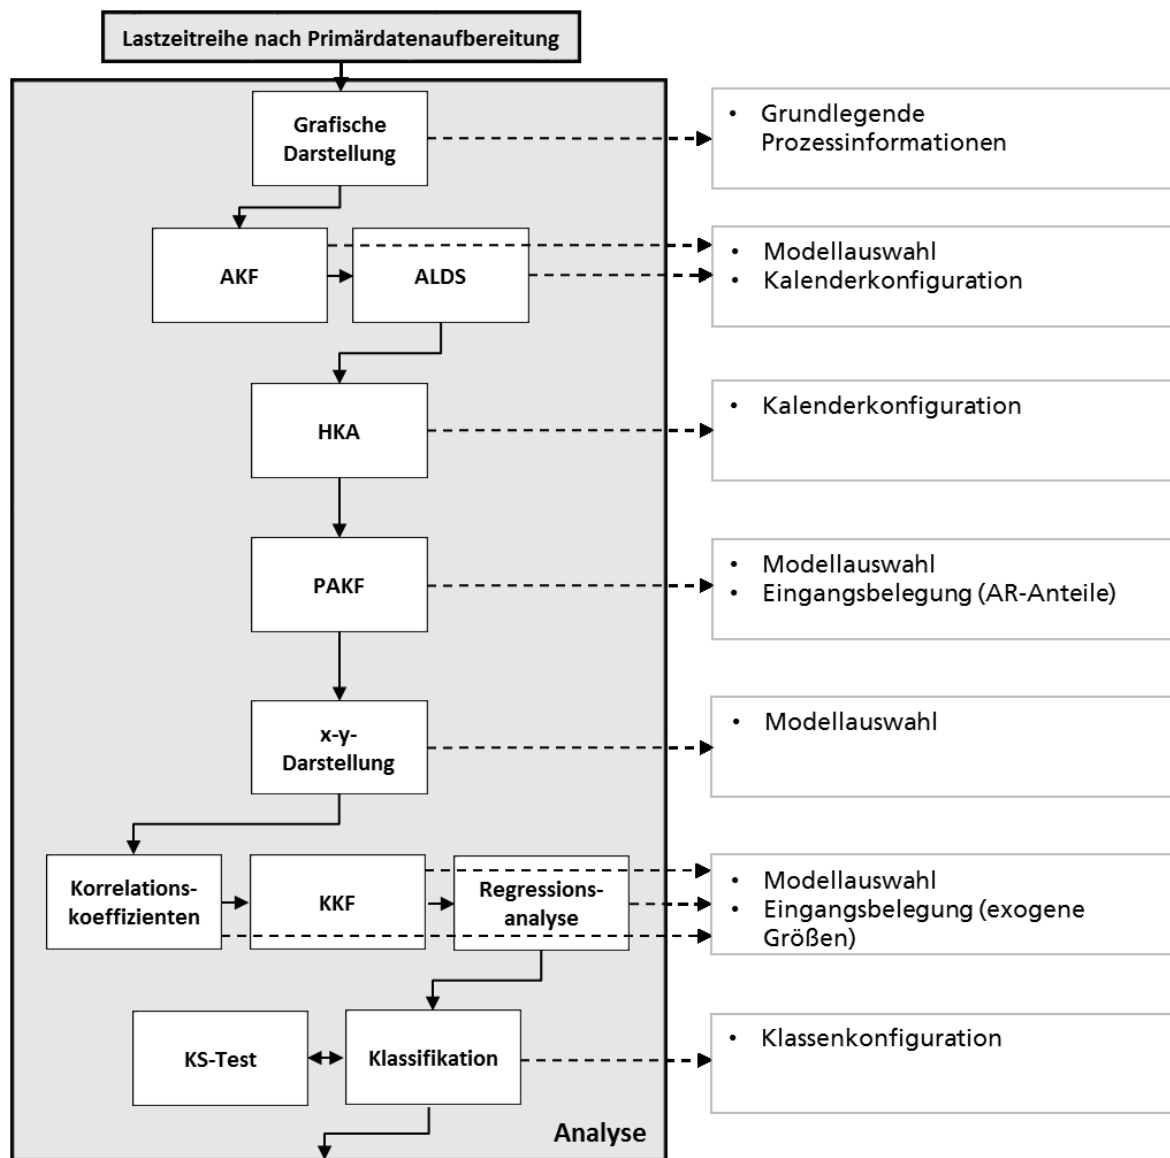


Abbildung 3.4: Darstellung des Verarbeitungsworkflows für die Analyse von Lastzeitreihen nach [15]

Die Abbildung 3.5 zeigt den Verarbeitungsworkflow für die Auswertung der Residuen im Rahmen der vorliegenden Arbeit. Mit der Ermittlung und Darstellung von Kennzahlen als Fehlermaße lassen sich Prognosen bewerten und vergleichen. Ein Nachweis für das Vorliegen eines optimalen Prognosemodells beendet die Modellbildung.

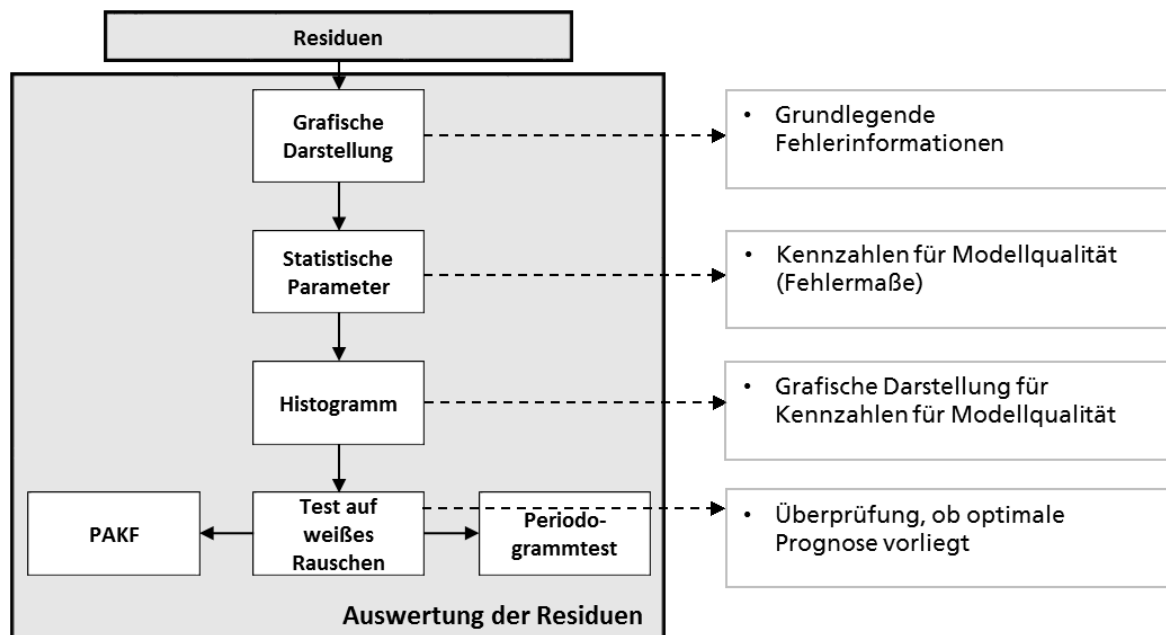


Abbildung 3.5: Darstellung des Verarbeitungsworkflows für die Auswertung der Residuen

Für eine weitergehende Analyse von preisbeeinflussten Lastzeitreihen, insbesondere wie die Veränderung der Verbrauchscharakteristik im Vergleich zu bisher typischen Verbrauchsmustern ohne eine Beeinflussung aussieht, bieten beispielsweise Clusteranalysen einen vielversprechenden Ansatz. Liegt bei der Analyse kein Vorwissen über die Charakteristik und damit über eine mögliche Klasseneinteilung vor, dann kann ein Clusterverfahren zur Anwendung kommen. Für eine Clusteranalyse wird keine Information über die Klassenstruktur der Daten (kein Klassen-Vorwissen) benötigt. Im Gegensatz zur Klassifikation, bei der Daten bestehenden Klassen zugeordnet werden, sollen mittels der Clusteranalyse neue Gruppen in den Daten identifiziert werden. Somit sind bei Clusterverfahren neben der Beschreibung der unterschiedlichen Cluster auch die entsprechenden Ausgangsgrößen zu ermitteln. Entsprechende Untersuchungen von preisbeeinflussten Zeitreihen mittels Clusterverfahren werden in [99] und [114] vorgestellt und analysieren die Reaktionen auf Preise. Der Ansatz der Analyse auf der Grundlage von Clusterverfahren wird in der vorliegenden Arbeit allerdings nicht weiterverfolgt.

3.6 Zusammenfassung und wichtigste Erkenntnisse

Im Rahmen der vorliegenden Arbeit soll ein Beitrag zur Vorhersage von preisbeeinflussten Lastzeitreihen geleistet werden. Hierzu wird der Entwurf einer, für diese Problemstellung geeigneten Prognosemethode ausgearbeitet und untersucht. Die fokussierte Prozessklasse stellt dabei einen erweiterten und zukünftig erwarteten Anwendungsfall der heutigen Lastprognose dar, welche bisher noch nicht ausreichend in der Literatur untersucht wurde.

Der Abschnitt 3.1 beschreibt die möglichen Anwendungsfälle für neue Prognosemethoden für preisbeeinflusste Lastzeitreihen und differenziert dabei nach Akteuren und Zielstellungen. Die untersuchte Prozessklasse wird durch die Einsatzgebiete (z. B. marktgeführten oder netzgeführten DSM-Maßnahmen) nicht eingeschränkt.

Im Abschnitt 3.2 wird eine neue Erweiterung des Komponentenmodells zur Beschreibung von Zeitreihen eingeführt. Dabei wird eine zusätzliche Komponente für die beeinflusste Zeitrei-

henkomponente vorgestellt, die den beeinflussbaren Anteil der Last beschreibt. Auf der Basis des so erweiterten Komponentenmodells wird das Zusammenspiel von preisbeeinflusstem Verbraucherverhalten, dessen Vorhersage sowie die zugrundeliegende Betriebsplanung inklusive der Preisbildung in einem Gesamtkonzept systemtechnisch aufgearbeitet. Es werden u. a. neue Anforderungen an die Prognose ermittelt, welche nachfolgend aufgeführt werden.

In den Abschnitten 3.3 und 3.4 wird die Charakteristik der unbeeinflussten und beeinflussten Verbrauchskomponente skizziert, welche sich in den resultierenden Lastzeitreihen widerspiegeln. Diese erweitern die Anforderungen an eine Prognosemethode um die mit der Beeinflussung einhergehenden Phänomene. Nachfolgend werden die Anforderungen, die sich aus der Kombination der in den Abschnitten 3.3 und 3.4 beschriebenen Charakteristika der unbeeinflussten und beeinflussten Verbrauchskomponente ergeben, zusammengefasst.

Der Abschnitt 3.5 stellt die für Untersuchungen im Rahmen der vorliegenden Arbeit relevanten Methoden der Zeitreihenanalyse vor. Es wird ein Verarbeitungsworkflow für die Analyse von preisbeeinflussten Lastzeitreihen vorgestellt, der das Vorgehen und die eingesetzten Methoden bei der Analyse festlegt. Der aufgeführte Verarbeitungsworkflow für die Analyse ist die Basis für die Entscheidungsfindung bei der Auswahl des Modellansatzes, der Festlegung der Modellstruktur und der Wahl der Eingangsbelegung im Rahmen des Entwurfs der neuen Prognosemethode für preisbeeinflusste Lastzeitreihen.

Anforderungen an Prognosemethoden für preisbeeinflusste Lastzeitreihen

Die neue Methode soll grundsätzlich auf Basis von Zeitreihen trainierbar sein und so die charakteristischen Eigenschaften des Verbrauchsverhaltens anlernen.

Der Nachweis der in den Abschnitten 3.3 und 3.4 beschriebenen Charakteristik der zu untersuchenden Zeitreihen wird im Abschnitt 5.3.1 anhand von zwei Datensätzen mit Hilfe des im Abschnitt 3.5 aufgeführten Verarbeitungsworkflows der Analyse erbracht. Es ist zu erwarten, dass die betroffenen Zeitreihen je Datensatz prinzipiell die gleichen charakteristischen Eigenschaften aufweisen, aber die anzulernenden Modellparameter können je nach Individualität der Verbraucher pro Datensatz unterschiedlich ausgeprägt sind. Bei der Modellierung werden demnach die charakteristischen Eigenschaften in der Modellstruktur abgebildet und die verbraucherindividuellen Ausprägungen werden durch die Modellparameter angelernt. Aufgrund der Vorüberlegungen und der Erkenntnisse aus den bisher vorgestellten Abschnitten werden zusammenfassend folgende Anforderungen an die zu entwerfende Prognosemethode gestellt:

- Es besteht ein Bedarf für die Prognose von Zeitreihen, die der **fokussierten Prozessklasse** zugeordnet werden können. Die Prognosemethode beschränkt sich im Rahmen der vorliegenden Arbeit auf Verbraucherprozesse mit **indirekter Beeinflussung mittels Preiszeitreihen**.
- Es wird eine **Vorhersage der beeinflussten und der unbeeinflussten Zeitreihenkomponente** für Lastzeitreihen der untersuchten Prozessklasse benötigt. Die Planung der quantitativen Lastbeeinflussung und das zugrundeliegende Setzen des Preisanreizes basieren auf der Prognose der unbeeinflussten Zeitreihenkomponente als Ausgangspunkt von DSM.
- Die auftretende Prozesscharakteristik bei Preisbeeinflussung und die damit verbundenen **charakteristischen Eigenschaften** der Lastzeitreihen müssen von der Prognosemethode

einbezogen und entsprechend verarbeitet werden können. Es sind folgende charakteristischen Eigenschaften der zu untersuchenden Prozessklasse zu berücksichtigen:

- **Saisonal-, typtag- und uhrzeitabhängige Preiselastizität,**
 - **Charakteristik des unbeeinflussten Verbrauchsverhaltens,**
 - Auswirkungen des **Planungshorizontes** (Vorlaufzeit),
 - Dynamische Verbraucherreaktionen in Abhängigkeit der Preisevents (**Eigen- und Kreuzpreiselastizität**).
- Die **zu einem Energiespeicher vergleichbaren Eigenschaften** müssen zum Teil bei der Modellierung berücksichtigt werden. Ein begrenztes Lastverschiebungspotenzial und die Unzulässigkeit negativer Werte sind bei der Modellierung mit einzubeziehen. Die Modellierung einer Speicherkapazität wird hingegen nicht vorgesehen.
- Die Prognosemethode muss auf Basis historischer Werte der preisbeeinflussten Lastzeitreihe $y[k]$ und der Preiszeitreihe $p[k]$ sowie evtl. zusätzlicher exogener Größen als Datengrundlage mit Berücksichtigung des Planungshorizontes trainierbar sein. Dabei sind die charakteristischen Eigenschaften von Zeitreihen der zu untersuchenden Prozessklasse mittels verbraucherindividueller Modellparameter anzulernen.

4 Konzept und Entwurf der Prognosemethode

4.1 Vorgehenskonzept für die Prognose beeinflusster Zeitreihen

Zur Erstellung eines Modells für die Prognose von beeinflussten Lastzeitreihen wird zunächst ein Vorgehensmodell als Gesamtkonzept von der Datenanalyse bis zum Modellentwurf vorgestellt und diskutiert. Das zu entwerfende Modell soll das Ein- Ausgangs-Verhalten mit geeigneten Modellansätzen wiedergeben und neben dem beeinflussten Verbrauchsverhalten auch das unbeeinflusste Verbrauchsverhalten beschreiben. Verbraucherprozesse, die durch indirekte Beeinflussung mittels Preiszeitreihen beeinflusst werden, sollen bei hinreichend genauer Beschreibung der Dynamik dieser Prozesse approximiert werden. Regelmäßige und unregelmäßige Änderungen des Verbrauchsverhaltens sollen durch das Modell erklärt werden. Im Fall eines zeitvarianten Verhaltens soll das Modell z.B. durch Methoden zur Parameteradaptation nachführbar sein. Für Prognoseanwendungen bei energiemarktspezifischen Problemstellungen existieren zahlreiche marktübliche und etablierte Prognosemethoden, die auf verschiedensten Modellansätzen beruhen (vgl. Abschnitt 2.3.1). Für die Problemstellung bei preisbeeinflussten Lastzeitreihen besteht allerdings noch Bedarf an objektiven Analyse- und Entwurfsalgorithmen für leistungsfähige Prognosemethoden. Dazu sollen mit der Erweiterung des Komponentenmodells (siehe Abschnitt 3.2) neben den bereits bekannten Zeitreihenkomponenten auch die beeinflusste Zeitreihenkomponente im Rahmen der Modellierung berücksichtigt werden.

Die Abbildung 4.1 zeigt das Grobkonzept zur Analyse und zum Modellentwurf als Erweiterung von [15], welches auf dem Box-Jenkins-Modell Entwurfsmodell [112] basiert.

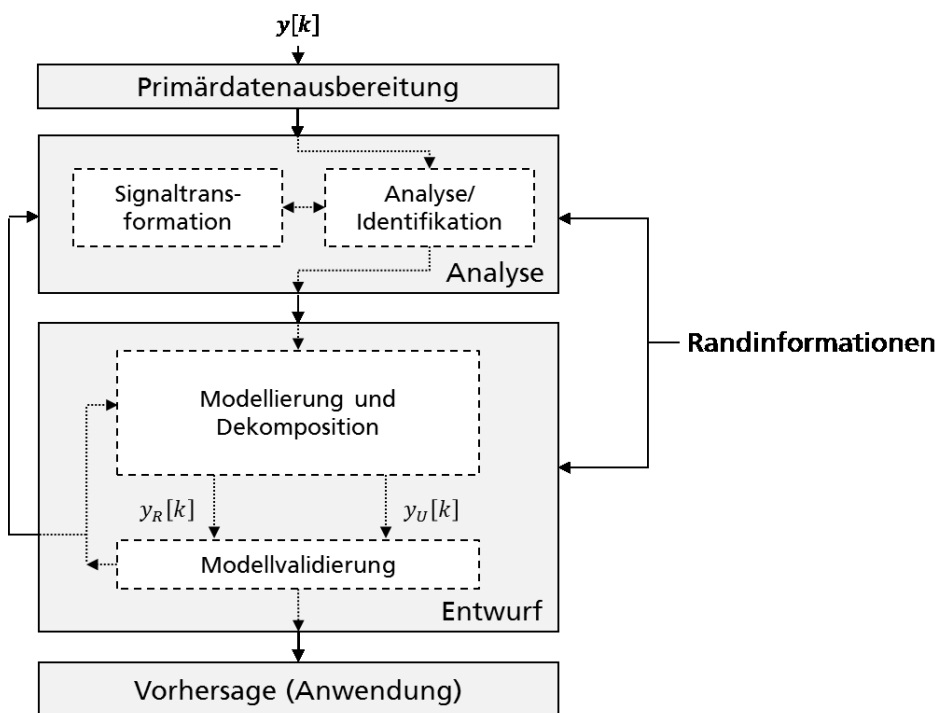


Abbildung 4.1: Grobkonzept für Analyse und Entwurf (modifiziert nach [15], [68], [112])

Der erste Schritt des in Abbildung 4.1 gezeigten Vorgehensmodells ist die Primärdatenaufbereitung. Diese dient zur Plausibilisierung der zugrundeliegenden Datenbasis. Dafür sind irreguläre Werte, Ausreißer und Datenlücken, welche beispielsweise durch Messfehler, Fehler bei der Speicherung oder der Übertragung von Zeitreihenwerten entstehen können, zunächst mittels entsprechender Detektionsverfahren zu identifizieren. Im Anschluss sind die identifizierten Werte mittels Ersatzwertverfahren zu beseitigen. Eine plausible und vollständige Datengrundlage bildet die Basis der weiteren Analyse und des Modellentwurfs und ist nötig, damit fehlerhafte und fehlende Werte die Analyse- und Modellierungsergebnisse nicht verfälschen oder unbrauchbar machen. Die Primärdatenaufbereitung wird im Rahmen der vorliegenden Arbeit allerdings nicht weiter thematisiert, da für die simulativen Untersuchungen auf eine plausible Datenbasis zurückgegriffen werden kann. Mit dem Anschluss der Primärdatenaufbereitung liegt eine plausible, vollständige und widerspruchsfreie Datenbasis vor. Es folgt die Analysephase, bei der Randinformationen einbezogen werden können. Die Ergebnisse der Analyse bilden die Grundlage der nachfolgenden Entwurfsphase. In der Analysephase werden die charakteristischen Zeitreiheneigenschaften und die Auswirkungen zusätzlicher Einflussfaktoren bestimmt. Dafür wird der in Abbildung 3.4 vorgestellte Verarbeitungsworkflow für die Analyse von Lastzeitreihen angewendet. Im Abschnitt 3.5 werden die relevanten Verfahren zur Untersuchung und Identifikation typischer Rhythmen, des Einflusses exogener Größen und Kalenderabhängigkeiten und die Charakteristik für musterbasierte Zeitreihen detailliert beschrieben. Auf der Grundlage historischer Daten sollen als Basis für die Modellierung die charakteristischen Zeitreihenanteile und Merkmale identifiziert und klassifiziert werden. Durch die Erweiterung des Komponentenmodells um die beeinflusste Zeitreihenkomponente müssen die Zusammenhänge und Verknüpfungen der einzelnen Zeitreihenkomponenten als Weiterführung zur rein musterbasierten Vorhersage neu untersucht und bewertet werden.

Während der Entwurfsphase sollen Modelle entwickelt werden, die mit mathematischen Verfahren die Zusammenhänge zwischen den Ein- und Ausgangsgrößen bei Verbrauchsprozessen unter Berücksichtigung von Preiszeitreihen abbilden können. Die Modelle sollen dabei generalisierungsfähig sein, damit diese für Prognoseanwendungen eingesetzt werden können. In der Entwurfsphase wird das Prognosemodell auf der Grundlage der in der Analysephase gewonnenen Erkenntnisse entwickelt. Dabei findet eine Dekomposition der beeinflussten Zeitreihe in die unbeeinflusste und beeinflusste Zeitreihenkomponente statt. Im Rahmen der Modellvalidierung wird anhand der Residuen die Modellgüte mittels spezifischer Fehlermaßen und der Forderung nach einer optimalen Prognose überprüft. Dafür wird der in Abbildung 3.5 vorgestellte Verarbeitungsworkflow für die Auswertung der Residuen angewendet. Sind die Anforderungen an die Modellgüte erfüllt, dann ist der Entwurf eines optimal angepassten Modells abgeschlossen, welches im Anschluss für die Vorhersage eingesetzt werden kann.

Bei der Analyse und auch beim Entwurf des Vorhersagemodells sollen verschiedene Randinformationen wie beispielsweise a priori-Wissen oder bestimmte Kennwerte einbezogen werden. Für eine Auswahl der in der Literatur aufgeführten Modellierungsansätze für preissensitives Verbrauchsverhalten werden solche Randinformationen aus sozioökonomischen Modellen oder Feldversuchen gewonnen. Ein Ziel dieser Arbeit ist die Generierung der nötigen Randinformationen aus allgemeingültigen Vorüberlegungen. Zusätzlich können Randinformationen, wenn möglich, aus den historischen Daten beispielsweise als statistische Kenngrößen und Merkmale gewonnen werden. Randinformationen, die aufgrund von Vorüberlegungen in die Analyse einbezogen werden können, sind:

- Gleichbleibender Energiewert bei P-DSM: Wird von P-DSM ausgegangen, dann bleibt der Energiewert über ein bestimmtes Zeitintervall konstant. Es werden nur die Leistungswerte verändert und zeitlich verschoben. Wird von PE-DSM ausgegangen, dann sind Änderungen des Energiewertes zulässig.
- DSM-Potenzial: Für bestimmte Verbraucher oder Verbrauchergruppen kann u.U. im Vorfeld das Lastverschiebe- bzw. Beeinflussungspotenzial durch Studien oder Feldversuche abgeschätzt werden (siehe Abschnitt 2.1.3).
- Negatives Vorzeichen der Preiselastizität: Die Preiselastizität hat im Allgemeinen ein negatives Vorzeichen. Das lässt sich dadurch erklären, dass der Verbrauch bei steigenden Preisen tendenziell sinkt und bei fallenden Preisen eher steigt. Es ergibt sich ein umgekehrt-proportionaler Zusammenhang zwischen Preis- und Laständerung und damit das negatives Vorzeichen der Preiselastizität.
- Tarifinformationen: Kennwerte über das Preissignal (z.B. Maximal- oder Minimalpreis) oder die Eckdaten des Tarifs (z.B. die Vorlaufzeit, für die die Preise im Vorfeld bekannt sind) können Aufschluss über die Ausprägung der Verbraucherreaktion geben.
- Keine negativen Werte: Bei der Interpretation des beeinflussten Verbrauchsprozesses als virtueller Speicher werden keine negativen Werte für die beeinflusste Lastzeitreihe $y[k]$ zugelassen, da der beeinflussbare Teil nur einen Bruchteil der Gesamtlast ausmacht.

Das detaillierte Konzept für das Vorhersagesystem wird im Abschnitt 4.4 vorgestellt.

4.2 Modellierung von preissensitivem Verbrauchsverhalten

Während der **Analysephase** des in der Abbildung 4.1 skizzierten Vorgehensmodells sollen Erkenntnisse gewonnen werden, die als Grundlage für die Modellierung und die Prognose von preisbeeinflussten Lastzeitreihen dienen. Für die Analyse von Zeitreihen steht eine Vielzahl von Werkzeugen und Methoden zur Verfügung. Eine Auswahl wird im Abschnitt 2.2 vorgestellt. Zur Analyse preisbeeinflusster Lastzeitreihen kommt der im Abschnitt 3.5 vorgestellte **Verarbeitungsworkflow** für die Analyse von Lastzeitreihen zum Einsatz. Als Datengrundlage für die Untersuchungen kommen Leistungszeitreihen von preisbeeinflussten und unbeeinflussten Verbrauchern in Betracht. Entsprechende Datensätze wurden beispielsweise in Pilotprojekten [63], [97] erhoben, bei denen der Verbrauch als äquidistante Zeitreihen von Smart-Metern gemessen wurde. Für die Bewertung des Einflusses von Preissignalen auf das Verbrauchsverhalten werden beispielsweise Gruppen von preisbeeinflussten Verbrauchern mit einer Kontrollgruppe von unbeeinflussten Verbrauchern verglichen [62], [97], [98], [99].

In der vorliegenden Arbeit wird der Einfluss von Preiszeitreihen auf das Verbrauchsverhalten mit dem Ziel der Prognose durch Modelle bewertet und abgebildet. Bei der Modellbildung soll der funktionale Zusammenhang zwischen Preis- und Lastverlauf auf der Grundlage historischer Daten der beeinflussten Lastzeitreihe $y[k]$ und der zugehörigen Preiszeitreihe $p[k]$ abgebildet werden. Die Schwierigkeit ist dabei, dass nur ein Bruchteil von $y[k]$ durch den Preis beeinflusst wird. Welche Größenordnung der beeinflussbare Anteil annehmen kann, wird im Abschnitt 2.1.3 verdeutlicht. Der größere Anteil von $y[k]$ wird durch andere exogene Faktoren beeinflusst. Bei der Betrachtung der Charakteristik von $y[k]$ überlagern sich die Auswirkungen der verschiedenen Einflussfaktoren auf die Lastzeitreihe. Eine qualitative Bewertung der Einflussgrößen wird im Abschnitt 3.3 vorgenommen.

Mit dem Konzept des Komponentenmodells und der im Abschnitt 3.2 vorgestellten Erweiterung soll $y[k]$ in die Komponenten für den beeinflussten Zeitreihenanteil $y_R[k]$ und den unbeeinflussten Zeitreihenanteil $y_U[k]$ zerlegt werden. Ein Vorteil dieser Herangehensweise liegt in der Möglichkeit, die beiden Zeitreihenanteile in separaten Teilmodellen zu beschreiben. Bei der Modellierung kann jeweils auf die spezielle Charakteristik der unbeeinflussten und der beeinflussten Lastkomponente eingegangen werden. Ein weiterer Vorteil besteht in der Dekomposition von $y[k]$ in $y_U[k]$ und $y_R[k]$. Im Zuge der Anwendung zur Vorhersage von $y[k+H]$ wird durch das Konzept des erweiterten Komponentenmodells ein Rückschluss auf $y_U[k+H]$ und $y_R[k+H]$ ermöglicht. Damit können separate Prognosen für die unbeeinflusste und beeinflusste Zeitreihenkomponente realisiert werden.

Im Rahmen der **Entwurfsphase** sollen Modelltyp, Modellstruktur und die Eingangsbelegung des Modells festgelegt werden. Modelltyp, Modellstruktur und die Eingangsbelegung werden dabei anhand der Ergebnisse und Erkenntnisse der Analysephase bestimmt. Das resultierende Prognosemodell soll dabei das zugrundeliegende Systemverhalten wiedergeben und zukünftige Werte optimal vorhersagen. Der Nachweis einer optimalen Prognose wird mit dem im Abschnitt 3.5 beschriebenen Verarbeitungsworkflow für die Auswertung der Residuen vorgenommen.

Das Ziel der Modellierung von preissensitivem Verbrauchsverhalten ist in der vorliegenden Arbeit eine Prognosemethode, bei der die charakteristischen Eigenschaften des Verbrauchsverhaltens von individuellen Verbrauchern und Verbrauchergruppen ermittelt und als Modellparameter hinterlegt werden. Die Methode kann auf der Basis von historischen Lastzeitreihen trainiert werden und so die charakteristischen Eigenschaften des Verbrauchsverhaltens anlernen. Dabei sind für verschiedene Beispielzeitreihen die angelernten Modellparameter je nach Individualität der Verbraucher unterschiedlich ausgeprägt (spezifisch). Für die Modellierung werden in den Abschnitten 3.3 und 3.4 die Eigenschaften für das preissensitive Verbrauchsverhalten diskutiert. Im Abschnitt 4.2 sind die entsprechenden Modellierungsansätze aufgeführt. Auf Grundlage des erweiterten Komponentenmodells zur Beschreibung von Zeitreihen wird die beeinflusste Zeitreihe in die beeinflusste und in die unbeeinflusste Zeitreihenkomponente zerlegt. Aufgrund der unterschiedlichen funktionalen Zusammenhänge werden für die beiden Zeitreihenkomponenten verschiedene Modellierungsansätze betrachtet, die in den folgenden Abschnitten vorgestellt werden. Der Modellansatz für die Beschreibung der beeinflussten Zeitreihenkomponente wird dabei als *TMR* (TeilModell Response) und der Modellansatz für die Beschreibung der unbeeinflussten Komponente als *TMU* (TeilModell Unbeeinflusst) bezeichnet. Der Modellansatz zur Beschreibung von preisbeeinflussten Lastzeitreihen als Kombination von *TMR* und *TMU* wird in der vorliegenden Arbeit als IARIMA-Modellansatz (Influenced Autoregressive Integrated Moving Average) bezeichnet. Die Begründung des Namens IARIMA wird im Abschnitt 4.4.2 gegeben. Ein erster Entwurf des Modellierungsansatzes ist in [100] aufgeführt.

4.2.1 Modellansatz für die beeinflusste Zeitreihenkomponente (TMR)

Die Charakteristik der Preiselastizität und damit die beeinflusste Zeitreihenkomponente sind von verschiedenen Faktoren abhängig. Diese wurden im Abschnitt 3.4 umfassend diskutiert. Für die Modellierung der beeinflussten Zeitreihenkomponente in *TMR* werden in der vorliegenden Arbeit die Abhängigkeiten zum Einflussparameter Zeit (Uhrzeit, Typtag, saisonal) beachtet. Die Matrix \mathbf{Z} nach Gleichung (3.10), welche die Eigen- und die Kreuzpreiselastizität beschreibt, ist für individuelle Lastzeitreihen in Abhängigkeit der Uhrzeit individuell besetzt. Durch die Abhängigkeit des Verbrauchsverhaltens und der Preiselastizität von saisonalen Einflüssen und Kalenderabhängigkei-

ten können sich jeweils individuelle Matrizen \mathbf{Z} ergeben. Für diese saisonalen Einflüsse und Kalenderabhängigkeiten werden c Klassen unterschieden. Einer Klasse werden dabei alle Zeitreihenabschnitte zugeordnet, welche die gleiche Matrix \mathbf{Z} aufweisen. Für c Klassen ergeben sich die individuellen Matrizen \mathbf{Z}_c . Für die Modellierung der c unterschiedlichen Ausprägungen der Preiselastizität wird im Abschnitt 4.3 die klassenbezogenen- und uhrzeitabhängige Mehrschrittmodellierung vorgestellt. Diese lässt eine Aufteilung der erforderlichen Klassenkonfiguration zu und ermöglicht somit die Unterscheidung der c verschiedenen Ausprägungen der Preiselastizität, welche durch die Matrizen \mathbf{Z}_c repräsentiert werden.

Die beeinflusste Zeitreihenkomponente wird je Klasse c mit einem Modell abgebildet, welches auf der multiplen linearen Regression basiert. Die Regressionsanalyse ist eine der meistverwendeten Methoden in der Statistik und wird dazu verwendet, den Zusammenhang zwischen einer abhängigen Variable und einem oder mehreren Einflussfaktoren (unabhängigen Variablen) zu modellieren. Im Fall der Prognose einer Lastzeitreihe wird die Regressionsanalyse üblicherweise verwendet, um den linearen Zusammenhang zwischen der zu prognostizierenden abhängigen Variable (Last) und anderen Einflussgrößen wie Wetter oder Kalenderabhängigkeiten oder Typtagen abzubilden. Werden mehrere unabhängige Variablen in dem Regressionsmodell verwendet, dann spricht man von multipler Regression [30]. In Gleichung (4.1) wird ein allgemeines Modell als gewichtete Summe unabhängiger Variablen zur Beschreibung einer abhängigen Variable vorgestellt. Die Modellparameter (Gewichte) können mittels linearer Regression geschätzt werden. Dabei gelten die unter Abschnitt 2.2.1 aufgeführten BLUE-Bedingungen:

$$x[k] = \delta_0 + \sum_{l=1}^L [\delta_l \cdot u_l[k]] \quad (4.1)$$

mit: $x[k]$ - abhängige Variable,
 $u_l[k]$ - unabhängige Variablen und
 δ_0, δ_l - Modellparameter.

Die beeinflusste Zeitreihenkomponente und damit die funktionalen Zusammenhänge zwischen Preis und Last sollen über die Parameter $\boldsymbol{\delta} = \delta_0, \dots, \delta_L$ der Modellgleichung abgebildet werden. $\Psi_l[k]$ beschreibt dabei die $l=1, \dots, L$ unabhängigen Variablen des Modellansatzes, welche die beeinflusste Komponente modellieren. Für die Beschreibung der Preisänderung $\Delta p[k]$ wird die aktuelle Abweichung zu einem Initial- bzw. Referenzpreis p_{init} berechnet. Ein konstanter Preis würde zu einem unbeeinflussten Verbrauchsverhalten mit $y_R[k] = 0$ führen. Die Gleichung (4.2) beschreibt die Überführung des in Gleichung (4.1) aufgeführten allgemeinen Ansatzes der multiplen Regressionsanalyse zur Beschreibung der beeinflussten Zeitreihenkomponente. Die in Gleichung (4.2) eingehenden Terme $\Psi_l[k]$ sind die unabhängigen Variablen des entworfenen Modells und sollen zur Erklärung der abhängigen Variable $y_R[k]$ bzw. $y[k]$ beitragen. Es ist dabei zu prüfen, ob einzelne Terme einen signifikanten Einfluss auf die abhängige Variable ausüben [30]. Grundsätzlich sind nur Terme mit signifikantem Einfluss zu berücksichtigen. Es gilt:

$$y_R[k] = \delta_0 + \sum_{l=1}^L \delta_l \Psi_l[k]. \quad (4.2)$$

Ausgehend von der Gleichung (3.11) kann die Preiselastizität alternativ auch mit Hilfe von Gleichung (4.3) wie folgt beschrieben werden:

$$y_R[k] = \Delta y[k, h] = \sum_{j=-n}^n \delta_{h,j+n+1} \frac{\Delta p[k+j]}{p_{init}} \cdot y_{init} \quad (4.3)$$

- mit: $\delta_{1,1}, \dots, \delta_{D,2n+1}$ - Parameter,
 h - Uhrzeitindex mit $h = 1, \dots, D$,
 y_{init} - Initial- bzw. Referenzverbrauch und
 p_{init} und $\Delta p[k+i]$ - Initial- bzw. Referenzpreis und Änderung des Preises im Zeitintervall $k+i$.

Die Eigen- und Kreuzpreiselastizitäten sollen dabei durch die Modellparameter δ wiedergegeben werden. Dabei ergibt sich die resultierende Laständerung (Änderung der Verbrauchswerte als Abweichung zu einem Referenzwert der Last) über ein Zeitintervall als Ergebnis der Abweichung des Preises zu einem Referenzpreis. Das Maß dieser Änderung ($\hat{=}$ Preiselastizität) wird in dem Modell durch die Parameter $\delta_{1,1}, \dots, \delta_{D,2n+1}$ beschrieben. Die Kreuzpreiselastizität wird über ein gleitendes Zeitfenster $-n \leq k \leq n$ abgebildet. Die Größe des gleitenden Zeitfensters sollte dabei so gewählt werden, dass nur relevante Kreuzpreiselastizitäten in Form der Modellparameter $\delta_{1,1}, \dots, \delta_{D,2n+1}$ vorkommen. Die Relevanz der Kreuzpreiselastizität und damit der nötigen Terme innerhalb des relevanten gleitenden Zeitfensters $-n \leq k \leq n$ kann dabei über entsprechende Signifikanztests ermittelt und abgesichert werden. Durch die Gleichung (4.3) wird eine Zeile der Matrix \mathbf{Z} abgebildet und damit der Einfluss von Preisänderungen im gleitenden Zeitfenster $-n \leq k \leq n$ auf die Laständerung zum Zeitpunkt k beschrieben. Für den Zeitpunkt k sind dabei der aktuelle Uhrzeitindex h und die Klasse c zu beachten, da je Uhrzeitindex h und je Klasse c ein individueller Parametersatz vorliegt.

Aufgrund der in der Praxis nicht messbaren beeinflussten Zeitreihenkomponente kann sich die Identifikation der signifikanten Terme aus Gleichung (4.3) allerdings erheblich erschweren. Auch die Größe der Matrix \mathbf{Z} und die damit verbundene Anzahl der zu schätzenden Parameter stellt eine sinnvolle Identifikation und Parameterschätzung für ein Modell auf Basis der multiplen linearen Regression in Frage. Für die Modellierung der Eigen- und Kreuz- Preiselastizitäten mit Hilfe der Matrix \mathbf{Z} werden dabei mit Hinblick auf die Anzahl der zu schätzenden Parameter für die Modellierung von $y_R[k]$ Vereinfachungen getroffen. Es werden alternative Terme $\Psi_l[k]$ als unabhängige Variablen des entworfenen Modells in Gleichung (4.2) benötigt, welche die funktionalen Zusammenhänge zwischen Preis- und Laständerung substituieren können und die Parameter der Eigen- und Kreuz- Preiselastizitäten der Matrix \mathbf{Z} reduzieren.

Im folgenden Abschnitt werden die Terme $\Psi_l[k]$ vorgestellt, welche für die vereinfachte Modellierung des im Abschnitt 4.4 vorgestellten und für die simulativen Untersuchungen genutzten Vorhersagesystems angewendet werden. Im Abschnitt 5 werden dazu verschiedenen Varianten der Modellierung preisbeeinflusster Lastzeitreihen miteinander verglichen, um die Leistungsfähigkeit des vorgestellten Modellansatzes zu erproben und zu evaluieren. Prinzipiell sind alternativ zu den in der vorliegenden Arbeit verwendeten Termen $\Psi_l[k]$ auch weitere vereinfachte Ansätze der Modellierung denkbar. Zum Beispiel können vereinfachte bzw. reduzierte Strukturen der Matrix \mathbf{Z} für

eine Vereinfachung der Modellierung in Betracht gezogen werden. Es kann beispielsweise angenommen werden, dass alle Elemente auf der Hauptdiagonalen gleich sind oder dass die Matrix \mathbf{Z} nur punktuell besetzt ist. Die Untersuchung dieser und weiterer Alternativen der Modellierung von Eigen- und Kreuz- Preiselastizitäten wurden in der vorliegenden Arbeit nicht weiterverfolgt und ergeben anknüpfenden Forschungsbedarf für weiterführende Arbeiten.

Zur Beschreibung der Eigenpreiselastizität wird die Gleichung (4.3) zunächst für $j = 0$ als Term der Modellgleichung (4.2) übernommen. So geht der aktuelle Preis in die Berechnung ein und beschreibt den vom aktuellen Preis verursachten Anteil der Laständerung. Weiterhin wird ein Referenzpreis $p_{ref}[k]$ eingeführt. Der Referenzpreis beschreibt den Preis zu einem Referenzzeitpunkt $k - \tau$ in der Vergangenheit. Der Verschiebeoperator τ wird dabei von der Kalenderkonfiguration des Gesamtmodells (siehe auch Abschnitt 4.2.2) vorgegeben. Mit der Einführung des Referenzpreises in die Modellgleichung kommt die Anwendung eines Differenzenfilters für die von der Eigenpreiselastizität verursachten Preiskomponente zum Einsatz. Es gilt:

$$\Psi_1[k] = \frac{\Delta p[k]}{p_{init}} \cdot y_{init} \quad \text{und} \quad \Psi_2[k] = \frac{\Delta p_{ref}[k]}{p_{init}} \cdot y_{init}. \quad (4.4)$$

Als alternativer und vereinfachter Modellierungsansatz zu Gleichung (4.3) wird die Laständerung, welche durch die Kreuzpreiselastizität verursacht wird, über die Varianz der Preiszeitreihe σ_p^2 in einem gleitenden Zeitfenster Δk abgebildet (siehe Abbildung 4.2) und als weiterer Term in TMR eingeführt [150]. Folgende Gleichung beschreibt den Term für die Varianz des Preises:

$$\Psi_3[k] = \sigma_p^2[\Delta k] \quad (4.5)$$

mit: $\sigma_p^2[\Delta k]$ - Varianz der Preiszeitreihe in einem gleitenden Zeitfenster Δk .

Die Überlegungen basieren auf dem ARCH-Modellansatz, welcher im Abschnitt 2.3.1.3 vorgestellt wurde. Dabei wird ein funktionaler Zusammenhang zwischen den Parametern der Verteilung des Preises und den der Verteilung des beeinflussten Lastanteils unterstellt. Es wird davon ausgegangen, dass eine hohe Varianz des Preises eine hohe Laständerung zur Folge hat. Die so berechnete Varianz $\sigma_p^2[\Delta k]$ soll anstelle der Kreuzpreiselastizität den zeitversetzten funktionalen Zusammenhang zwischen Preis- und Laständerung modellieren. Kommen für das betrachtete gleitende Zeitfenster Δk für den aktuellen Zeitpunkt k hohe Werte in der entsprechenden Zeile der Matrix \mathbf{Z} vor, dann ist bei einer hohen Preisänderung eine hohe Laständerung die Folge. Die Varianz $\sigma_p^2[\Delta k]$ substituiert also für Δk die für den Zeitpunkt k relevanten Parameter der Kreuzpreiselastizität in Kombination mit den Preisänderungen. Die Information, welche Parameter der Preiselastizität (Parameter der entsprechenden Zeile der Matrix \mathbf{Z}) die Laständerung bewirkt haben und wie hoch der Einfluss im Einzelnen war (die genaue Besetzung der Matrix \mathbf{Z}), geht dabei allerdings verloren. In einer Datenvorverarbeitung kann $\sigma_p^2[\Delta k]$ vorab berechnet werden und als zusätzlicher Eingang in die Berechnung der beeinflussten Zeitreihenkomponente in die Gleichung (4.2) eingehen.




Abbildung 4.2: Beispielhafte Darstellung für Preisvarianz in gleitendem Zeitfenster

Als weiterer Term für eine genauere Beschreibung der beeinflussten Zeitreihenkomponente wird der Term der Gleichung (4.6) eingeführt, der die Wechselwirkungen zwischen dem aktuellen Preis und der Preisvarianz beschreibt:

$$\Psi_4[k] = \sigma_p^2[\Delta k] \cdot p[k]. \quad (4.6)$$

Weiterhin wird analog zum im *TMU* verwendeten ARIMA-Modellansatz ein Referenzwert $y_{R,ref}[k]$ für die beeinflusste Zeitreihenkomponenten in Gleichung (4.7) wie folgt eingeführt:

$$\Psi_5[k] = y_{R,ref}[k] \quad (4.7)$$

mit: $y_{R,ref}[k]$ - Referenzwert für $y_R[k]$.

Der Referenzwert $y_{R,ref}[k]$ beschreibt den beeinflussten Verbrauch zu einem Referenzzeitpunkt $k - \tau$ in der Vergangenheit. Der Verschiebeoperator τ wird dabei von der Kalenderkonfiguration des Gesamtmodells vorgegeben und im Rahmen der Zeitreihenanalyse ermittelt. In Verbindung mit DSM-Maßnahmen und einer Kombination mit Wärmeumwandlung und anderen potenziellen Technologien (siehe Abschnitt 3.4.2) wird im Rahmen der vorliegenden Arbeit davon ausgegangen, dass bei einem Speichereffekt der Bezug zu einer ausweisbaren Speicherkapazität nicht mehr gegeben bzw. ableitbar ist. Eine explizite Berücksichtigung einer Speicherkapazität bei der Modellierung wird daher nicht verfolgt. Eine mögliche Speicherkapazität und der damit verbundene aktuelle Speicherfüllstand werden indirekt in dem Modell berücksichtigt, insofern die zugehörigen Ein- und Ausgangsdaten ein solches Verhalten widerspiegeln.

4.2.2 Modellansatz für die unbeeinflusste Zeitreihenkomponente (TMU)

Die Modellansätze, die in der Literatur zur Lastprognose und -modellierung zum Einsatz kommen, werden im Abschnitt 2.3.1 ausführlich beschrieben. Für die Modellierung der beeinflussten Zeitreihenkomponente in *TMU* wird in der vorliegenden Arbeit ein ARIMA-Ansatz verwendet. Das in Gleichung (2.10) aufgeführte $\text{ARIMA}(p,d,q)$ -Modell bietet einen einfachen und vielfach erprobten

Modellansatz zur Lastprognose. Der ARIMA-Modellansatz erweitert den klassischen ARMA-Modellansatz um einen Differenzenfilter der Ordnung d und bietet einen Ansatz zur Beschreibung instationärer stochastischer Prozesse. Dabei wird die d -te Differenz $\nabla^d y[k]$ als ARMA(p, q)-Modell der Ordnung p und q modelliert. Durch die Differenzenbildung wird der instationäre Teil in Form polynomialer Trends benachbarter Zeitreihenwerte miterfasst und beseitigt. Der Einsatz von Differenzenfiltern verringert den Grad polynomialer Trends. Zur Beseitigung linearer Trends werden somit Differenzenfilter 1. Ordnung eingesetzt. Zur Beseitigung nichtlinearer Trends kommen Differenzenfilter der Ordnung $d > 1$ zum Einsatz. Der Einsatz von Differenzenfiltern dient der Linearisierung, d.h. der Überführung in Zeitreihen mit (quasi-)stationären Eigenschaften. Die Gleichung (4.8) beschreibt einen Differenzenfilter 1. Ordnung und die Gleichung (4.9) mit d -ter Ordnung mit dem Backshift-Operator τ [15]. Es gilt:

$$\nabla_\tau y[k] = y[k] - y[k - \tau] \text{ und} \quad (4.8)$$

$$\nabla_\tau^d y[k] = \nabla_\tau^{d-1} y[k] - \nabla_\tau^{d-1} y[k - \tau] \quad (4.9)$$

mit: $\nabla_\tau y[k]$ - Differenzenfilter 1. Ordnung mit dem Backshift-Operator τ und

$\nabla_\tau^d y[k]$ - Differenzenfilter d -ter Ordnung mit dem Backshift-Operator τ .

Lastzeitreihen mit typischen wiederkehrenden Mustern (z.B. Kalenderabhängigkeiten) sollen in Zeitreihen mit quasistationären Eigenschaften überführt werden. Werden Differenzenfilter mit einem entsprechenden Backshift-Operator τ kombiniert, dann erlaubt das die Berücksichtigung von Referenzwerten $y[k - \tau] = y_{ref}[k]$. Wird der Backshift-Operator τ beispielsweise durch ein datumsbasiertes Regelwerk vorgegeben, dann können solche Kalenderabhängigkeiten bei der Modellierung berücksichtigt werden. Je nach Komplexität des Regelwerkes können einfache Regeln eine feste Verschiebung, beispielsweise zur Vorwoche, vorgeben oder pro Zeiteinheit eine separate Regel (z.B. individueller Backshift-Operator τ in Abhängigkeit des Typtags, Wochentags, Feiertags, Brückentags, usw.) anwenden [15]. Die Anwendung von typtagabhängigen und datumsbasierten Regeln für die Verschiebung des Backshift-Operators τ wird in der vorliegenden Arbeit als Kalenderkonfiguration bezeichnet. Wenn von der Kalenderkonfiguration des Gesamtmodells die Rede ist, dann gelten diese Regeln für die Ermittlung sämtlicher benötigter Referenzwerte in allen Komponenten des Modells.

Das Modell für die beeinflusste Zeitreihenkomponente TMU wird in Gleichung (4.10) mit den zu bestimmenden Modellparametern β_i und η_j aufgeführt:

$$y_U[k] = \sum_{i=1}^p \left[\beta_i \cdot \nabla_\tau^d y_U[k - i] \right] + \varepsilon[k] + \sum_{j=1}^q \eta_j \varepsilon[k - j] + \eta_0 y_{U,ref}[k] \quad (4.10)$$

mit: $\nabla_\tau^d y[k]$ - Differenzenfilter d -ter Ordnung mit dem Backshift-Operator τ ,

$y_{U,ref}[k]$ - Referenzwert für unbeeinflusste Zeitreihenkomponente,

$\varepsilon[k]$ - weißes Rauschen und

β_i, η_j - Modellparameter.

4.3 Vorhersagestrategie und Konzept für die Anwendung der Prognose

4.3.1 Das Konzept von globaler und lokaler Prognose

Für den Betrieb von Energiesystemen und in der Energiewirtschaft werden klassischerweise Prognosen für mehrere Zeitschritte in die Zukunft benötigt. Die ausgehend vom Prognosestartzeitpunkt relativen Zeitschritte in die Zukunft werden in Abhängigkeit der Abtastzeit als Vorhersagehorizonte H bezeichnet. Für den Einsatz von Prognosemodellen für mehrere Vorhersagehorizonte werden in [15] die Konzepte von Ein- und Mehrschrittmodellen vorgestellt (siehe Abbildung 4.3 und Abbildung 4.4). Diese Konzepte beschreiben ein Framework, wie ein beliebiges Modell für eine Prognose für $k + H$ mit $H = 1, \dots, N_H$ angewendet werden kann.

Einschrittmodell:




Abbildung 4.3: Einschrittmodell laut [15]

Beim Einschrittmodell, welches in Abbildung 4.3 dargestellt ist, wird der Zusammenhang zwischen dem Zeitreihenwert für den Zeitpunkt $k + 1$ und n Vergangenheitswerten über ein einzelnes Modell abgebildet. Die Anwendung für mehrere Vorhersagehorizonte erfolgt rekursiv. Ein sich ausprägender Vorhersagefehler setzt sich dabei in allen folgenden Vorhersagehorizonten fort. Bei der Modellierung mit einem Einschrittmodell steigt die Varianz des Vorhersagefehlers mit dem Anstieg des Vorhersagehorizontes gegen die Prozessvarianz [45]. Die Fehlerfortpflanzung je Vorhersagehorizont erschwert die prinzipielle Erfassung des Prozesses durch das Modell.

Mehrschrittmodell:

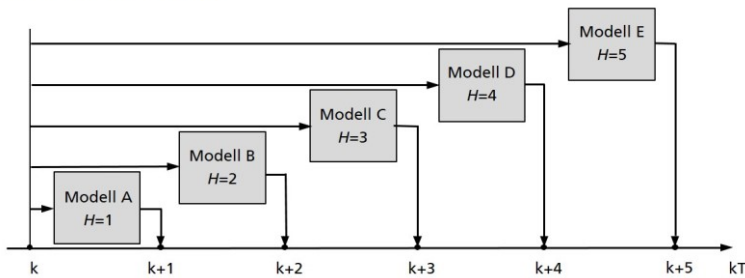


Abbildung 4.4: Mehrschrittmodell laut [15]

Mehrschrittmodelle (siehe Abbildung 4.4) setzen für jeden Vorhersagehorizont ein separates Modell ein. In [15] werden Mehrschrittmodelle favorisiert, da eine optimale Beschreibung mehrerer Vorhersagehorizonte besonders bei nichtlinearen Zusammenhängen zwischen den Zeitreihenwerten oder zu exogenen Einflussgrößen durch Einschrittmodelle nicht gegeben ist.

Im Rahmen der vorliegenden Arbeit wird im Einklang mit der Argumentation von [15] das Mehrschrittmodell für die Prognose von $k + H$ mit $H = 1, \dots, N_H$ präferiert. Dementsprechend wird

das Einschnittmodell aufgrund der zu erwartenden Fehlerfortpflanzung als Modellierungsansatz verworfen.

Die bei der Prognose vorherzusagenden Verbrauchsprozesse sind durch statistische Fluktuationen beeinflusst, welche auf eine Vielzahl von Störursachen zurückzuführen sind. Resultierende Lastzeitreihen sind in der Regel durch deterministische und stochastische Prozesseigenschaften charakterisiert und sind bspw. über den Ansatz des Komponentenmodells unter Verwendung deterministischer und stochastischer Zeitreihenmodelle beschreibbar. Störursachen lassen sich in der Regel nicht auf eine geringe Anzahl von Faktoren reduzieren und bilden so eine Folge von mehr oder minder zufälligen Einflüssen. Werden konkrete Realisierungen eines Prozesses unter gleichen Bedingungen beobachtet, dann sind diese Werte einer statistischen Schwankung unterworfen. Die Werte folgen somit einer Wahrscheinlichkeitsverteilung mit bestimmten Parametern. Bei der Betrachtung lokaler Abschnitte von Lastzeitreihen lassen sich in der Regel verschiedene Arbeitspunkte mit sich unterscheidenden Verteilungen beobachten. Für die Modellierung und damit die Prognose von Prozessen wird in der vorliegenden Arbeit das Konzept der globalen und lokalen Prognose verfolgt [15]. Gegenüber [15] wird allerdings ein typtag- und uhrzeitabhängiger Ansatz gewählt, der nachfolgend erläutert wird. Wird die gesamte Zeitreihe betrachtet und modelliert, so sind die ermittelten Modelle oder Modellkomponenten globaler Art. Globale Modelle oder Modellkomponenten sind so für den gesamten Zeitreihenverlauf gültig. Bei der lokalen Modellierung werden Teilbereiche der Zeitreihe mit dem Ziel betrachtet, für diesen lokalen Teilbereich eine bessere Abschätzung zu finden. Lokale Modelle oder Modellkomponenten sind so nur stückweise für den Zeitreihenverlauf gültig. Dabei werden für die Modellierung lokaler Abschnitte des Prozesses separate Modelle verwendet. Separate Modelle sollen dabei lokale Wahrscheinlichkeitsverteilungen des Prozesses, welche lokal individuelle Parameter aufweisen, optimal abbilden. Globale Modellkomponenten justieren den jeweiligen Arbeitspunkt, während die lokale Stochastik mit spezialisierten stochastischen Zeitreihenmodellen abgebildet wird. Die Länge und Position eines lokalen Abschnittes werden in der Anwendung des Konzeptes der globalen und lokalen Prognose in der vorliegenden Arbeit durch uhrzeitabhängige Modelle beschrieben. Mit der Identifikation charakteristischer Eigenschaften in der Analysephase (siehe Abschnitt 4.1) werden lokale Abschnitte des Prozesses durch die Anwendung der Klassifikation identifiziert.

Aufgrund von zu erwartenden typtagindividuellen Verbrauchsmustern werden für die Länge und Position lokaler Abschnitte grundsätzlich Tagesabschnitte betrachtet. Mit Hilfe der vorab durchzuführenden Datenanalyse lassen sich $c = 1, \dots, C$ typische Klassen ermitteln. C gibt dabei die Anzahl der zu unterscheidenden Typtagklassen an. Infolge unterschiedlicher Lastniveaus zu unterschiedlichen Tageszeitpunkten innerhalb einer Typtagklasse liegen je Typtagklasse für jeden Uhrzeitindex h lokale Abschnitte mit lokaler Verteilungsfunktion vor (siehe exemplarisches Beispiel in Abbildung 4.5). Bei einer Abtastzeit von 15 Minuten ergeben sich $h = 1, \dots, 96$ lokale Abschnitte je Typtagklasse.

Für die weiteren Ausführungen in der vorliegenden Arbeit wird die Betrachtung von C typischen Klassen und jeweils 96 uhrzeitindexabhängigen lokalen Abschnitten festgelegt. Für die Werte je Klasse c und je Uhrzeitindex h liegt dabei eine individuelle Verteilungsfunktion $F_{c,h}$ mit individuellen Parametern vor, welche in Gleichung (4.11) wie folgt beschrieben werden:

$$\begin{aligned}
& F_{c=1,h=1}(y_{1,1}) \text{ für Datenbeispiel } y_{1,1} = y[k|c = c_1, h = 1] \\
& \quad \dots \\
& F_{c=1,h=D}(y_{1,D}) \text{ für Datenbeispiel } y_{1,D} = y[k|c = c_1, h = 96] \\
& \quad \dots \\
& F_{c=C,h=D}(y_{C,D}) \text{ für Datenbeispiel } y_{C,D} = y[k|c = C, h = 96].
\end{aligned} \tag{4.11}$$

In Abbildung 4.5 werden dazu exemplarisch individuelle typtagabhängige Häufigkeitsverteilungen und deren Verteilungsfunktionen für 3 zu unterscheidende Klassen $c = 1$ (Werktag), $c = 2$ (Samstag) und $c = 3$ (Sonntag) sowie individuelle uhrzeitabhängige Häufigkeitsverteilungen mit $h = 1, \dots, 96$ für die Klasse $c = 1$ dargestellt.

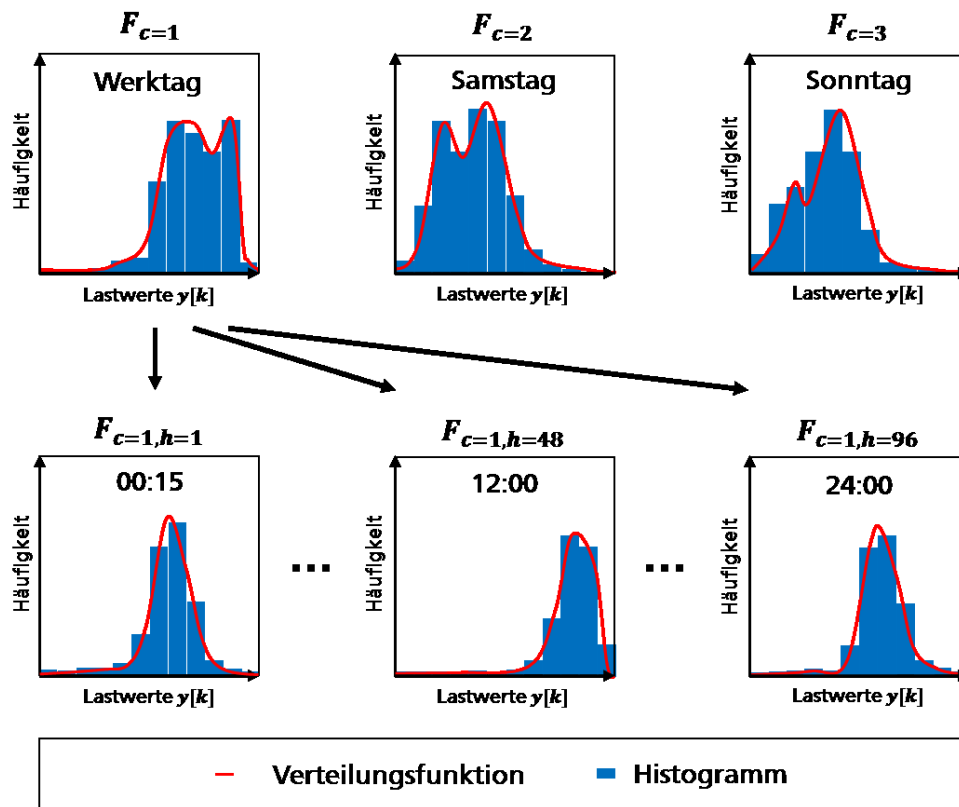
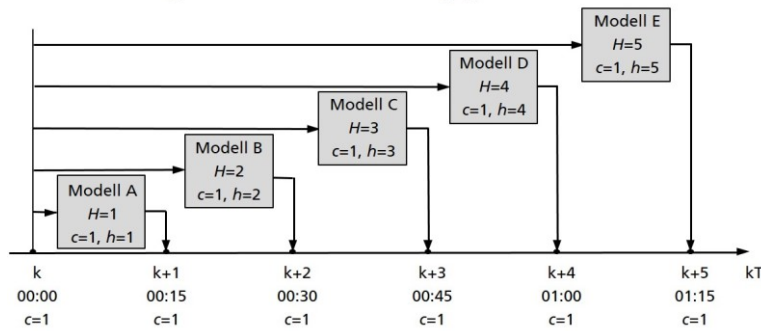
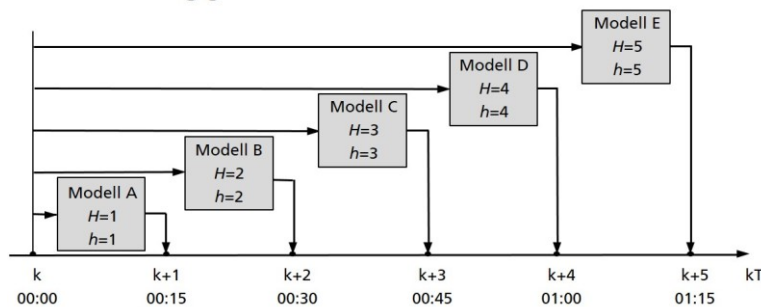


Abbildung 4.5: Exemplarische Darstellung der Häufigkeitsverteilung (Histogramm) für klassen- und uhrzeitspezifische Beispielzeitreihe

Als Erweiterung der Mehrschrittmodelle wird in der vorliegenden Arbeit die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung eingeführt, welche in Abbildung 4.6 dargestellt wird.

Klassenbezogenes und uhrzeitabhängiges Mehrschrittmodell:**Abbildung 4.6:** Klassenbezogenes und uhrzeitabhängiges Mehrschrittmodell

Ist nur eine einzige Klasse vorhanden, dann ergibt sich die uhrzeitabhängige Mehrschrittmodellierung laut Abbildung 4.7.

Uhrzeitabhängiges Mehrschrittmodell:**Abbildung 4.7:** Uhrzeitabhängiges Mehrschrittmodell

Mit der Anwendung des Konzeptes der lokalen Prognose werden für die zu unterscheidenden Klassen jeweils separate Modelle verwendet. Die klassenbezogenen Einzelmodelle werden nur zur Modellierung der jeweiligen Klasse eingesetzt und somit nur lokale Abschnitte $\hat{y}[k|c = 1, \dots, C]$ vorhergesagt. Bei der Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung werden dazu die benötigten Eingangsdaten auf Basis der ermittelten Typtagklassen $c=1, \dots, C$ zerlegt und in die identifizierte Klassenstruktur eingeordnet. Eine geeignete Klassenstruktur, in welche die Eingangsdaten eingeordnet werden, ist vorab durch eine entsprechende Analyse der Eingangsdaten im Rahmen der Analysephase zu ermitteln. Die Analyse zur Ermittlung der Klassenstruktur wird im Abschnitt 4.3.2 vorgestellt. Die ermittelte Klassenstruktur wird als globale Modellkomponente angesehen.

Bei der uhrzeitabhängigen Mehrschrittmodellierung als zusätzliche globale Erweiterung werden separate Modelle für die Beschreibung des Prozesses in Abhängigkeit der Uhrzeit eingesetzt. Für äquidistante Zeitreihen entspricht die Anzahl der eingesetzten Modelle in Abhängigkeit der Abtastzeit T der Anzahl der Werte pro Tag D . Ein uhrzeitabhängiges Modell mit dem Uhrzeitindex h beschreibt den stochastischen Prozess für eine Uhrzeit. Jeder Uhrzeitindex h kann dabei genau einer Uhrzeit zugeordnet werden. Die für uhrzeitspezifische Modelle benötigten Eingangsdaten werden entsprechend des Uhrzeitindex h in D lokale Abschnitte zerlegt. Mit den uhrzeitspezifischen Modellen können jeweils nur lokal uhrzeitabhängige Abschnitte $\hat{y}[k|h = 1, 2, \dots, D]$ eines jeweiligen lokal klasseabhängigen Abschnittes $\hat{y}[k|c = 1, \dots, C]$ vorhergesagt werden. Die Vor-

schrift für die Zerlegung bei der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung ist deterministisch und wird als globale Modellkomponente verstanden. Das prinzipielle Vorgehen bei der Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung für die Vorhersage wird in der Abbildung 4.8 für den Zeitpunkt $k_0 + H$ erläutert. Zunächst werden c und h entsprechend der vorab ermittelten Klassenkonfiguration für den Zeitpunkt $k_0 + H$ ermittelt. Anschließend wird die für die Vorhersage benötigte Eingangsmatrix in Abhängigkeit von c und h für $k_0 + H$ generiert, welche in den folgenden Abschnitten als Entscheidungsvektor $d_{c,h}[k_0 + H]$ interpretiert und dargestellt wird. Im nächsten Schritt wird das in Bezug auf c , h und H spezialisierte Einzelmodell aufgeschaltet, welches im Anschluss für die Vorhersage angewendet wird.

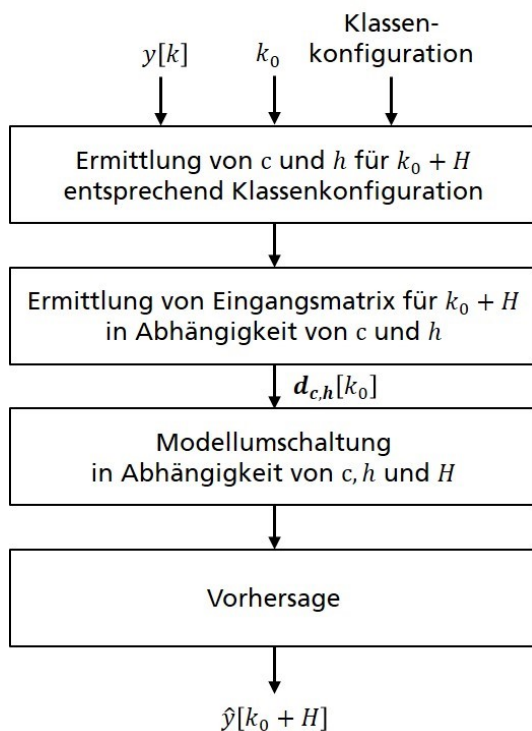


Abbildung 4.8: Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung für die Vorhersage

In Bezug auf die Anzahl der Werte eines Datenbeispiels für einen lokalen Abschnitt, die Streuung dieser Werte, den Aufwand für das Datenmanagement und die Qualität der resultierenden Prognose ist ein Kompromiss für eine „optimale“ Zerlegung der zu untersuchenden Zeitreihe zu finden. Grundsätzlich ist darauf zu achten, dass eine genügend große Anzahl von Trainingsdaten zur Verfügung steht, damit lokale Abschnitte auch hinreichend durch die vorhandenen Daten repräsentiert werden. Entscheidend ist dabei, dass die Trainingsdaten plausibel sind. Ausreißer oder andere unplausible Werte können sich vor allem bei geringem Datenumfang eines jeweiligen Einzelmodells gravierend auf die Robustheit auswirken. Prinzipiell ist es nicht auszuschließen, Datensätze lokaler Abschnitte mit unterschiedlichen Uhrzeitindizes, welche aber dieselbe Verteilungsfunktion aufweisen, durch nur ein Modell zu beschreiben. Ebenfalls ist es denkbar, Datensätze lokaler Abschnitte unterschiedlicher Klassen und unterschiedlicher Uhrzeitindizes durch nur ein Modell zu beschreiben, wenn diese ebenfalls eine identische Verteilungsfunktion besitzen. Der Trainingsdatenumfang kann somit für Einzelmodelle vergrößert werden. Die Anzahl der Modelle und damit die Anzahl

der zu schätzenden Modellparameter ließe sich mit dieser Vorgehensweise ebenfalls verringern. Problematisch können hingegen die Ermittlung der zueinander passenden lokalen Abschnitte und der damit verbundene zusätzliche Aufwand für das Datenmanagement sein. Außerdem ist für alle Einzelmodelle ein ausreichend großer Trainingsdatenumfang sicherzustellen. Da eine Verbesserung der Prognosegüte hingegen nicht plausibel zu erwarten ist, wird eine pauschale Zerlegung nach Uhrzeitindizes favorisiert. Mit der Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung wird unterstellt, dass in lokalen Abschnitten unterschiedliche Gesetzmäßigkeiten wirken, sodass eine Modellierung lokaler Abschnitte mit spezialisierten Einzelmodellen hinsichtlich einer Verbesserung der Prognosequalität des Gesamtmodells sinnvoll ist. Dabei wird die höchste Granularität bei der Zerlegung angestrebt, sodass alle lokalen Abschnitte separat modelliert werden. Mit der Kombination von Mehrschrittmodellen mit der klassenbezogenen sowie der uhrzeitabhängigen Mehrschrittmodellierung und einer hohen Granularität bei der Zerlegung erhöht sich der Aufwand für das Datenmanagement, der durch eine erhöhte Prognosequalität des Gesamtmodells gerechtfertigt werden muss. Weiterhin ergeben sich eine Vielzahl von spezialisierten Einzelmodellen und eine große Anzahl von Modellparametern. Ein annehmbarer Kompromiss in Bezug auf die Klassenkonfiguration bei der Modellierung kann nicht pauschal beantwortet werden. Im Abschnitt 5.3.1 wird die Klassenkonfiguration für die im Rahmen der Arbeit untersuchten Beispielzeitreihen ermittelt und begründet.

Beispiel: Bei äquidistanten Zeitreihen mit einer Abtastzeit von 15 Minuten werden für ein normales Jahr mit 365 Tagen 35040 Werte gemessen. Werden bei einer klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung mit einem Vorhersagehorizont $H = 1, \dots, 96$ $c = 1, \dots, 3$ Klassen (Werktag, Samstag und Sonntag) unterschieden, dann ergeben sich bei einer Abtastzeit von 15 Minuten $3 \times 96 = 288$ Einzelmodelle. Bei einem Trainingsdatensatz von einem Jahr für das Gesamtmodell stehen für das 00:15 Uhr-Einzelmodell für $h = 1$ für den Typtag $c = \text{Sonntag}$ demnach 52 Werte für die Ermittlung der Modellparameter zu Verfügung.

4.3.2 Ermittlung der Klassenkonfiguration

Mit der Anwendung des Konzeptes der globalen und lokalen Prognose soll in einer vorab durchzuführenden Analyse die optimale Klassenkonfiguration ermittelt werden. Ziel ist es, globale Regeln zu finden, die lokale Abschnitte der zu prognostizierenden Zeitreihen in eine Klassenkonfiguration einteilt, welche im Hinblick auf eine Verbesserung der Prognosequalität durch separate Modelle beschrieben werden sollen. Die Abbildung 4.9 zeigt exemplarisch das Vorgehen zur Ermittlung der Klassenkonfiguration.

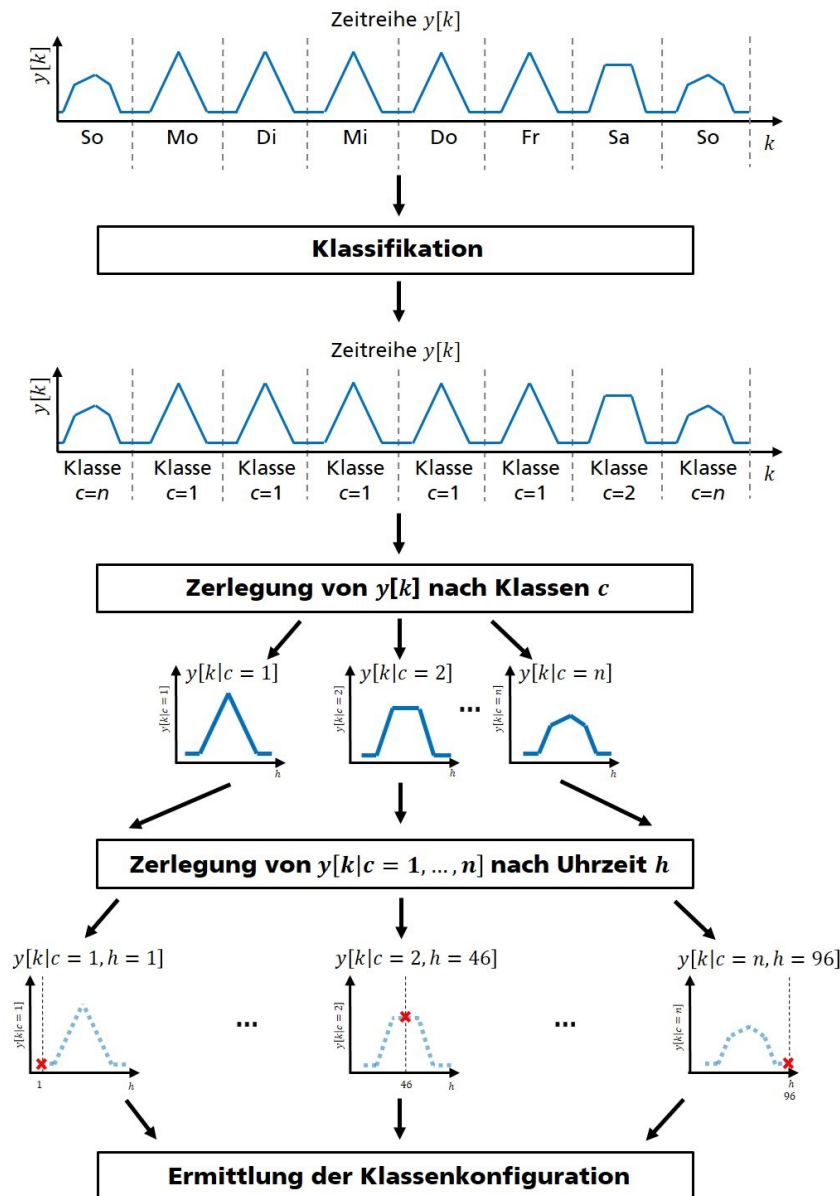


Abbildung 4.9: Analyse zur Ermittlung der Klassenkonfiguration für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung mit Zerlegung in n Klassen und für eine Abtastzeit von 15 Minuten mit $n \times 96$ Datensätzen in Anlehnung an [15]

Zunächst wird durch eine qualitative Bewertung eine mögliche Klassenstruktur aufgezeigt, die mögliche typische Klassen beinhalten soll. Im Abschnitt 3.3 wird die zugrundeliegende Bewertung durchgeführt, bei der die Charakteristik des Verbrauchsverhaltens qualitativ beschrieben und bewertet wird. Die charakteristischen Eigenschaften von Lastzeitreihen aus der Energiewirtschaft lassen sich auf das Verbrauchsverhalten von Haushalten, Gewerbe, Handel und Industrie zurückführen. Im Allgemeinen lassen sich bei Zeitreihen, die der Prozessklasse Lastzeitreihen aus der Energiewirtschaft zugeordnet werden können, charakteristische Verbrauchsmuster erkennen, die auf Unterschieden im zeitlichen Bedarf beruhen. Dementsprechend bietet sich der Einflussfaktor Zeit für ein Aufspannen einer möglichen Klassenstruktur an. Enthaltene Klassen sind beispielsweise verschiedene Typtage, welche auf ein typisches Verbrauchsverhalten zu verschiedenen Wochentagen, Werktagen oder Wochenenden zurückgeführt werden können. Die Klassenstruktur, die für

die Analyse im Rahmen der vorliegenden Arbeit festgelegt wird, unterscheidet die sieben Wochentage als $c = 1 \dots 7$ Typtagklassen. Feiertage werden dabei der Klasse Sonntag zugeordnet. Eine zusätzliche saisonale Unterscheidung von Typtagen (z.B. Sommer, Winter, Übergangszeit) kann darüber hinaus sinnvoll sein. Allerdings verringert sich der Datenumfang für die Schätzung der Modellparameter bei der Modellierung. Eine saisonale Unterscheidung bei der Klassenstruktur wird im Rahmen der vorliegenden Arbeit nicht vorgenommen, da beim gewählten Modellansatz saisonale Phänomene durch die Anwendung von Differenzenfilter eliminiert werden. Innerhalb einer Klasse liegen aufgrund von typtagindividuellen Verbrauchsmustern je Uhrzeitindex h zusätzlich $1, \dots, D$ lokale Abschnitte mit lokal Verteilungsfunktion vor. Für Zeitreihen aus dem Stromsektor mit einer Abtastzeit von 15 Minuten (Uhrzeitindex $h = 1, \dots, 96$) liegen nach der Zerlegung 7×96 Datenbeispiele vor.

Für die Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung wird im Rahmen der vorliegenden Arbeit angenommen, dass, wenn zwei Stichproben die gleiche Wahrscheinlichkeitsverteilung besitzen, diese der gleichen Grundgesamtheit entstammen und so mit dem gleichen Modell beschrieben werden können. In der Anwendung entspricht eine Stichprobe einem lokalen Abschnitt. Lokale Abschnitte, welche nicht die gleiche Verteilung aufweisen, sind auch bei der Modellierung im Hinblick auf die Qualität des Gesamtmodells separat zu behandeln. Die tatsächlich für die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung angewendete Klassenkonfiguration wird mittels eines Kreuzvergleiches der Werteverteilungen der vorliegenden Datenbeispiele lokaler Abschnitte der Zeitreihe vorgenommen, bei der die vorab definierte Klassenstruktur die Ausgangslage darstellt.

Für den Kreuzvergleich von Verteilungen wird der Kolmogoroff-Smirnoff-Test (KS-Test) angewendet. Der KS-Test ist ein statistischer Test zur Prüfung der Verteilungen zweier unabhängiger Stichproben auf Übereinstimmung der Wahrscheinlichkeitsverteilungen. Der KS-Test arbeitet verteilungsunabhängig, d. h. die zugrundeliegenden Variablen müssen keiner Normalverteilung folgen. Verglichen werden jeweils zwei Datenbeispiele $y_1 = y[k|c = c_1, h = h_1]$ und $y_2 = y[k|c = c_2, h = h_2]$ mit unbekannten Verteilungsfunktionen F_1 und F_2 , ob es sich um die selbe Verteilung der Beobachtungen handelt. Von den Datenbeispielen liegen $1 \dots n_1$ bzw. $1 \dots n_2$ Werte vor. Die Verteilungsfunktionen F_1 und F_2 werden an der Stelle $x = \{y_{1,1} \dots y_{1,n_1}, y_{2,1} \dots y_{1,n_2}\}$ miteinander verglichen. Überprüft wird die Nullhypothese:

$$H_0: F_1(x) = F_2(x). \quad (4.12)$$

mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ und $\alpha = 1\%$. Bei dem durchzuführenden Kreuzvergleich werden die Verteilungen $F_{c,h}$ der aufgespannten Klassenstruktur mit $c = 1 \dots 7$ Typtagklassen und je $h = 1, \dots, 96$ Uhrzeitindizes aller vorliegenden Datenbeispiele jeweils miteinander verglichen. Überprüft wird jeweils die Nullhypothese:

$$\begin{aligned} H_{0,1,1,1}: F_{c=1,h=1}(x_{1,1,1,1}) &= F_{c=1,h=1}(x_{1,1,1,1}) \\ H_{0,1,1,2}: F_{c=1,h=1}(x_{1,1,1,2}) &= F_{c=1,h=2}(x_{1,1,1,2}) \\ &\dots \\ H_{0,7,7,95,96}: F_{c=7,h=95}(x_{7,7,95,96}) &= F_{c=7,h=96}(x_{7,7,95,96}) \end{aligned} \quad (4.13)$$

$$H_{0,7,7,96,96}: F_{c=7,h=96}(x_{7,7,95,96}) = F_{c=7,h=96}(x_{7,7,96,96}) .$$

Trifft die Nullhypothese beim Vergleich zweier Datenbeispiele zu, dann besitzen die beiden Datenbeispiele eine identische Werteverteilung und können folglich durch ein Modell beschrieben werden.

Beim Vergleich zweier Typtagklassen werden die Verteilungen aller Datenbeispiele, die jeweils den gleichen Uhrzeitindex $y_1 = y[k|c = c_1, h = h_1 = h_2]$ und $y_2 = y[k|c = c_2, h = h_1 = h_2]$ haben, miteinander verglichen. Überprüft wird jeweils die Nullhypothese:

$$\begin{aligned} H_{0,c_1,c_2,1,1}: F_{c=c_1,h=1}(x_{c_1,c_2,1,1}) &= F_{c=c_2,h=1}(x_{c_1,c_2,1,1}) \\ H_{0,c_1,c_2,2,2}: F_{c=c_1,h=2}(x_{c_1,c_2,2,2}) &= F_{c=c_2,h=2}(x_{c_1,c_2,2,2}) \\ &\dots \\ H_{0,c_1,c_2,96,96}: F_{c=c_1,h=96}(x_{c_1,c_2,96,96}) &= F_{c=c_2,h=96}(x_{c_1,c_2,96,96}) . \end{aligned} \quad (4.14)$$

Treffen alle Nullhypothesen aus der Gleichung (4.20) zu, dann besitzen alle Datenbeispiele mit jeweils dem gleichen Uhrzeitindex $y_1 = y[k|c = c_1, h = h_1 = h_2]$ und $y_2 = y[k|c = c_2, h = h_1 = h_2]$ eine identische Verteilung und werden einer Typtagklasse zugeordnet. Gibt es Nullhypothesen aus Gleichung (4.20), die nicht zutreffen, dann gibt es Datenbeispiele mit sich unterscheidenden Verteilung für den gleichen Uhrzeitindex und die verglichenen Typtagklassen sind zu unterscheiden.

4.4 Vorhersagesystem für preisbeeinflusste Zeitreihen

4.4.1 Aufbau des Vorhersagesystems

Die Abbildung 4.10 zeigt eine schematische Darstellung des Vorhersagesystems für beeinflusste Zeitreihen. Mit dem Situationsvektor $s[k]$ werden neben den aktuellen Prozessgrößen auch die Preiszeitreihe, Randinformationen und weitere Informationen wie Datum, Uhrzeit oder Typtag als Eingang für das Vorhersagesystem zusammengefasst. Im Allgemeinen können Prozessgrößen aus Eingangs-, Ausgangs-, Zustands- und Störgrößen bestehen, die beim Anwendungsfall der Prognose teilweise vorherzusagen sind. Die in der Abbildung 4.10 relevanten Prozessgrößen sind die historischen Werte der beeinflussten Zeitreihe $y[k-1]$ bis $y[k-j]$ sowie die Prognosewerte potenzieller exogener Einflussgrößen $\hat{u}[k+H]$.

Das Vorhersagesystem ist in die zwei Module Klassifikationsmodul und Vorhersagemodul unterteilt, welche den Situationsvektor verarbeiten und die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung aus Abschnitt 4.3.1 umsetzen. Ziel ist neben der Vorhersage der beeinflussten Zeitreihe die Prognose der unbeeinflussten Zeitreihenkomponente auf der Basis historischer Werte preisbeeinflusster Lastzeitreihen. Die für die Adaption der Modellparameter (Training) herangezogenen historischen Daten werden als Trainingsdaten bezeichnet. Der Zeitbereich, der die Trainingsdaten umfasst, wird als Trainingszeitraum definiert. Dabei wird in die Trainings- und in die Prognosephase unterschieden. In der Trainingsphase werden die Modellparameter anhand der Trainingsdaten mit Hilfe eines Parameterschätzverfahrens so adaptiert, dass der quadratische Prognosefehler $(e[k])^2$ minimal wird. Das Ziel ist der Erfüllung des Kriteriums der optimalen Prognose,

welche im Abschnitt 2.2.1 vorgestellt wurde. Der Prognosefehler $e[k]$ ist dabei die Differenz zwischen dem Modellausgang $\hat{y}[k]$ und den Istwerten $y[k]$ und wird nach Gleichung (4.17) berechnet. Die Strategie für die Vorhersage sieht vor, dass während der Trainingsphase mit Hilfe der Unterteilung in die Teilmodelle *TMR* und *TMU* eine Dekomposition des gesamten Trainingsdatensatzes vorgenommen wird, bei der für die beeinflusste Zeitreihe $y[k]$ die unbeeinflusste und die beeinflusste Zeitreihenkomponente $\hat{y}_U[k]$ und $\hat{y}_R[k]$ für den gesamten Trainingszeitbereich geschätzt werden. Die beeinflusste Zeitreihe $y[k]$ wird entsprechend des erweiterten Komponentenmodells aus Abschnitt 3.2 bei Annahme einer additiven Verknüpfung der Zeitreihenkomponenten zerlegt. Während der Prognosephase werden mit Hilfe von *TMR* und *TMU* die Prognosen für einen Vorhersagehorizont H für die beiden Zeitreihenkomponenten erstellt.

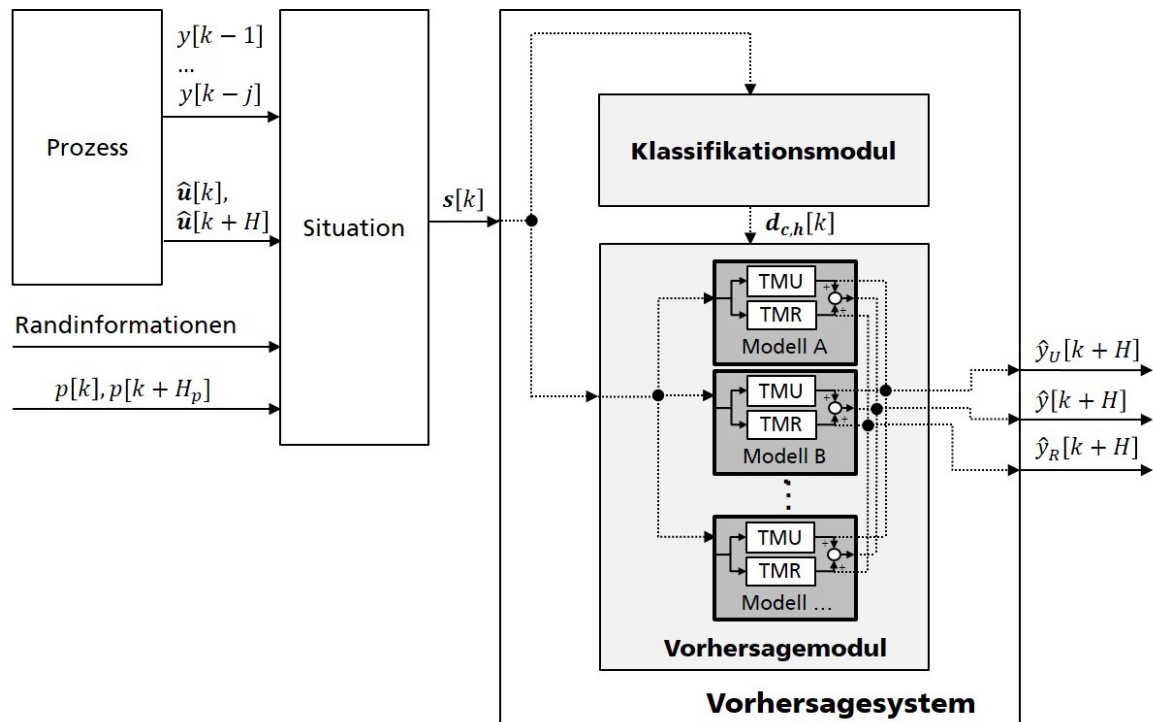


Abbildung 4.10: Vorhersagesystem für beeinflusste Zeitreihen (modifiziert nach [15])

Ziel des in Abbildung 4.10 eingeführten Klassifikationsmoduls ist die Einteilung des Datenbestandes in zusammengehörige Abschnitte. Die Charakteristik von Lastzeitreihen aus der Energiewirtschaft lässt sich auf das Verbrauchsverhalten typischer Verbrauchergruppen, z. B. Haushalte, Gewerbe oder Industrie, zurückführen. Dabei lassen sich charakteristische Verbrauchsmuster in Abhängigkeit des Typtages beobachten. Wie im Abschnitt 4.3 beschrieben, werden Tagesmuster als zusammengehörige Abschnitte festgelegt. Prinzipiell sind aber auch Zeitreihenabschnitte anderer Fensterlängen möglich, sofern diese charakteristische Muster oder Teilmuster ausbilden (z.B. charakteristische ansteigende bzw. absteigende Flanken oder Lastspitzen bzw. Lastsenken).

Die Motivation hinter der Kombination eines Klassifikations- und eines Vorhersagemoduls liegt in der Linearisierung von nichtlinearen Zeitreihen und damit im besten Fall in der Erzeugung zeitinvarianten Verhaltens. Dazu wird in Abbildung 4.11 die prinzipielle Verarbeitung des Situationsvektors nach [15] als Modell mit Linearisierungskomponente aufgegriffen. Dieser Ansatz wurde erstmals in [15] entwickelt und untersucht. In [94] wurde dies aufgegriffen.

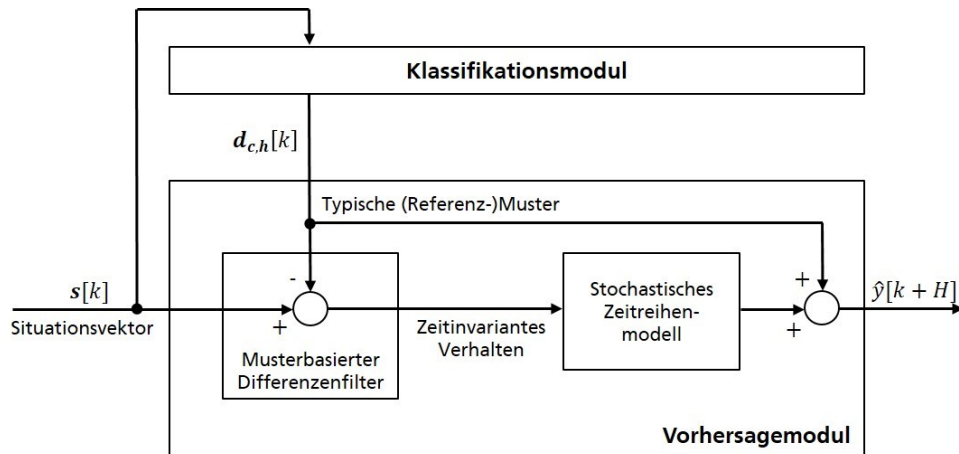


Abbildung 4.11: Vorhersagesystem mit Linearisierungskomponente (modifiziert nach [15], [94])

Dabei wird in einem Vorhersagemodul ein sogenannter musterbasierter Differenzenfilter als nicht-lineares statisches Teilmodell mit einem stochastischen Zeitreihenmodell kombiniert. Der musterbasierte Differenzenfilter berechnet die Differenz zwischen Situationsvektor und einem Referenzwert als Repräsentant des klassifizierten Musters und eliminiert somit die nichtlinearen musterbasierten Anteile einer Zeitreihe und erzeugt eine linearisierte Zeitreihe mit im besten Fall zeitinvariantem Verhalten. Liegt eine linearisierte Zeitreihe mit zeitinvariantem normalverteilten Verhalten vor, dann können klassische Parameterschätzmethoden zur Bestimmung der Modellparameter genutzt werden [15], [94]. Im Rahmen der vorliegenden Arbeit hat das Klassifikationsmodul die Aufgabe, den Entscheidungsvektor $d_{c,h}[k]$ als Funktion des Situationsvektors $s[k]$ nach folgender Gleichung zu ermitteln:

$$d_{c,h}[k] = f(s[k]). \quad (4.15)$$

Die Funktion f wird durch das im Abschnitt 4.3.2 aufgeführte Vorgehen zur Ermittlung der Klassenkonfiguration beschrieben. Bei der Klassifikation findet mit Hilfe einer Vorschrift bzw. eines Algorithmus eine Einteilung von Objekten anhand bestimmter Merkmale statt [15], [86], [94]. Für die Untersuchungen im Umfeld von Energieverbrauchszeitreihen bietet sich das Klassifikationskriterium Zeit an, da typische Verbraucher beispielsweise typtag- oder uhrzeitabhängige Verbrauchsmuster ausprägen (siehe Abschnitt 3.3). Die Klassen können beispielsweise nach Typtagen, Wochentagen, der Uhrzeit und/oder saisonalen Einflüssen zugeordnet werden [15], [69], [70], [71], [94]. Auch eine Klassifikation nach anderen exogenen Einflussgrößen ist denkbar. Sind beispielsweise bei Gruppen von Stromverbrauchern Klimaanlage oder elektrische Heizungen verbreitet, dann kann der Stromverbrauch in funktionaler Abhängigkeit zur Temperatur stehen. Eine Klassifikation der Verbrauchsdaten nach Temperaturbereichen wäre somit denkbar und wurde beispielsweise in [15] für die Fernwärme untersucht. Für das aufgeführte Vorhersagesystem für preisbeeinflusste Zeitreihen wird das Klassifikationsmodul nach dem im Abschnitt 4.3 beschriebenen Konzept der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung eingesetzt. Durch die Vorüberlegungen zur Charakteristik des Verbrauchsverhaltens (siehe Abschnitt 3.3) lässt sich das Vorwissen für die im Abschnitt 4.3.2 aufgeführte Klassenstruktur für Lastzeitreihen ableiten. Die Kriterien der Klassifikation wurden dabei so gewählt, dass die Volatilität der Klassenrepräsentanten untereinander möglichst nur noch durch die preisbasierte Beeinflussung erklärt werden kann. Der Preis soll daher als Klassifikationskriterium keine Verwendung finden. Die in der vorliegenden

Arbeit angewendete Klassifikation basiert auf einem Regelwerk in Abhängigkeit des Typtages und des Uhrzeitindex. Das Klassifikationsmodul übergibt dem Vorhersagemodul den Entscheidungsvektor $d_{c,h}[k]$. Der ermittelte Entscheidungsvektor enthält einerseits das Referenzmuster welches als typischer Repräsentant des klassifizierten Musters ermittelt wurde (siehe Abbildung 4.11). Für jede separierte Klasse wird im Vorhersagemodul im Anschluss an die Klassifikation ein separates Modell verwendet. Damit sollen die entstehenden Einzelmodelle spezialisiert werden. Der Entscheidungsvektor enthält dafür zusätzlich die Entscheidung für das Umschalten zwischen den jeweiligen Einzelmodellen (siehe Abbildung 4.12). Jedes Einzelmodell basiert auf dem IARIMA-Modellansatz und ist jeweils in die Teilmodelle *TMR* und *TMU* zur Abbildung der beeinflussten und unbeeinflussten Zeitreihenkomponente unterteilt.

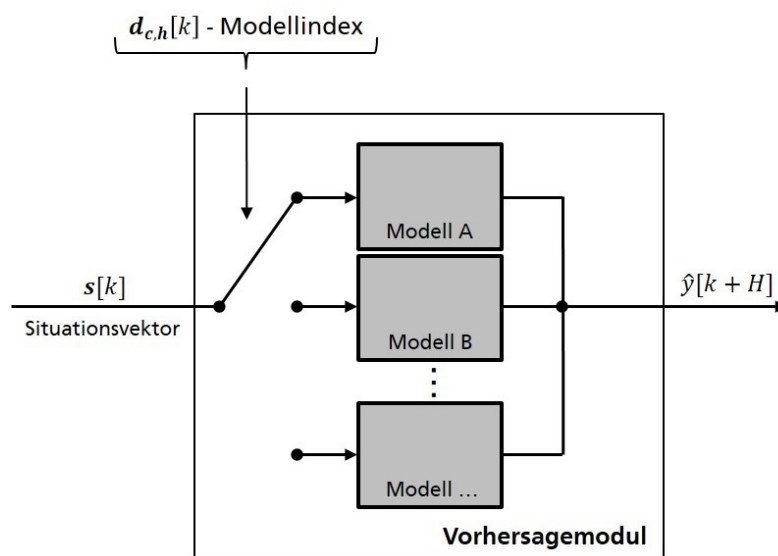


Abbildung 4.12: Modellumschaltung nach [15]

Beim Training wird entsprechend Abbildung 4.8 für das aufgeschaltete Einzelmodell die jeweilige Eingangsmatrix ermittelt und vorgegeben. Es ist allerdings darauf zu achten, dass pro Klasse genügend Repräsentanten als Trainingsdaten für die Modellierung zur Verfügung stehen.

Die Dekomposition und das Vorhersagemodul werden in den folgenden Abschnitten beschrieben.

4.4.2 Modellbasierte Dekomposition

Das Vorhersagemodul (siehe Abbildung 4.13) umfasst jeweils in einem Einzelmodell die beiden Teilmodelle *TMR* und *TMU*, welche in den Abschnitten 4.2.1 und 4.2.2 beschrieben werden, ein Parameterschätzverfahren und ein Nebenbedingungsmodell. Das Gesamtmodell erstellt aus dem Entscheidungsvektor $d_{c,h}[k]$ und dem Situationsvektor $s[k]$ eine Schätzung für die beeinflusste Zeitreihe $\hat{y}[k]$. Das dabei verwendete Parameterschätzverfahren schätzt die Modellparameter unter Beachtung einer Nebenbedingung, welche mit Hilfe eines Nebenbedingungsmodells ermittelt wird. Es wird davon ausgegangen, dass die einzelnen Zeitreihenkomponenten $y_U[k]$ und $y_R[k]$ nicht separat messbar sind. Nur die beeinflusste Zeitreihe $y[k]$ kann als beobachtbare Ausgangsgröße des durch den Preis beeinflussten Verbrauchsprozesses messtechnisch erfasst werden. Somit liegen für das Training nur historische Werte von $y[k]$ vor. Die Modellparameter werden mittels des angewendeten Parameterschätzverfahrens mit dem Ziel einer optimalen Prognose so eingestellt, dass der quadratische Fehler des Gesamtmodells minimal wird. In den folgenden Ausführungen werden die einzelnen Funktionsblöcke dazu genauer beschrieben und diskutiert.

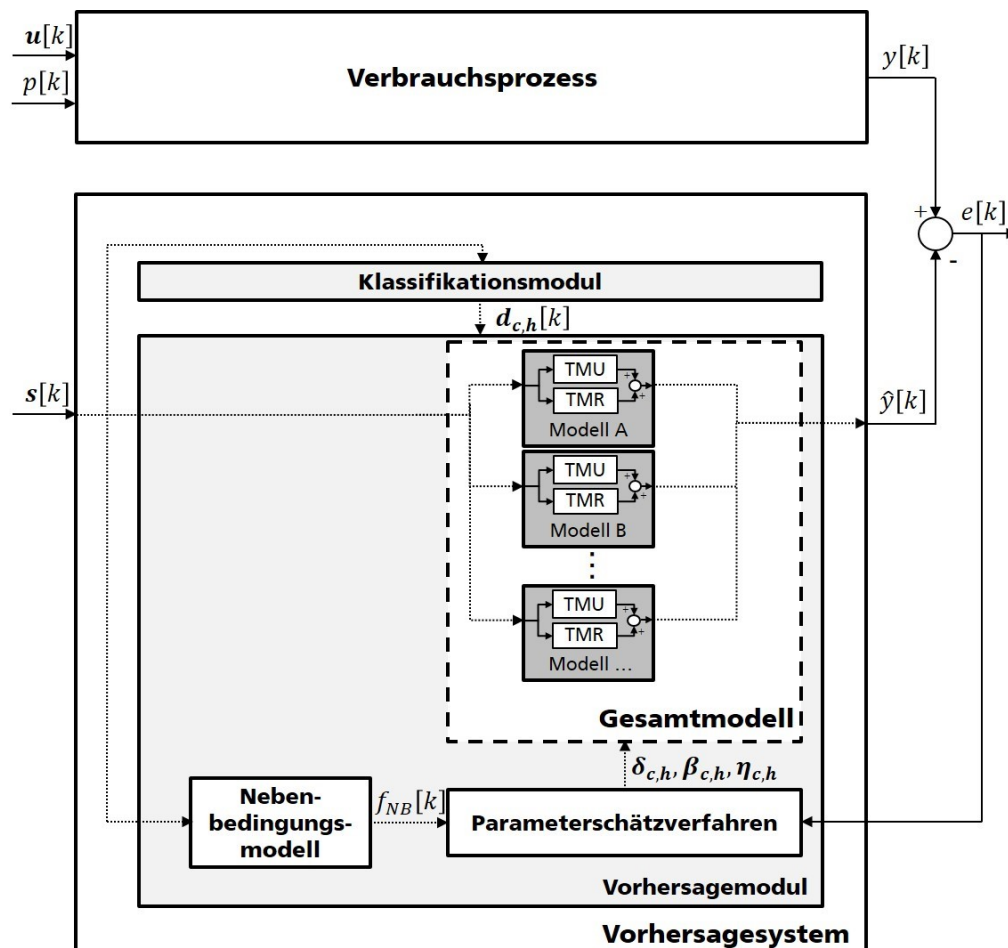


Abbildung 4.13: Vorhersagesystem mit Nebenbedingungsmodell und Parameterschätzverfahren

Das Gesamtmodell zur Beschreibung preisbeeinflusster Zeitreihen ergibt sich aus den Teilmodellen *TMR* und *TMU* und wird in der Gleichung (4.16) aufgeführt und folgend als IARIMA-Modell (Influenced Autoregressive Integrated Moving Average) bezeichnet. Dabei wird die beeinflusste Zeit-

reihenkomponente mit Hilfe des im Abschnitt 4.2.1 diskutierten Modellansatzes auf Basis der multiplen linearen Regression ermittelt, während die unbeeinflusste Zeitreihenkomponente mit Hilfe des in Abschnitt 4.2.2 aufgeführten ARIMA-Modells umgesetzt wird. Es gilt:

$$\begin{aligned}
 y[k] &= \{y_R[k]\} + \{y_U[k]\} \\
 &= \left\{ \delta_0 + \sum_{l=1}^L \delta_l \Psi_l[k] \right\} \\
 &\quad + \left\{ \sum_{i=1}^p \left[\beta_i \cdot \nabla_{\tau}^d y_U[k-i] \right] + \varepsilon[k] + \sum_{j=1}^q \eta_j \varepsilon[k-j] + \eta_0 \cdot y_{U,ref}[k] \right\}.
 \end{aligned} \tag{4.16}$$

Das IARIMA-Modell unterscheidet sich von einem klassischen ARIMAX-Modell (Kombination aus ARIMA-Modell mit exogener Größe) einerseits durch die spezialisierte Berücksichtigung der Preisinformationen mit der dazu nötigen Datenvorverarbeitung, und andererseits dadurch, dass beim *TMU* nicht die abhängige Variable $y[k]$ selbst verwendet wird, sondern nur das „Teilergebn“ $y_U[k]$. Die Abbildung 4.14 zeigt eine grafische Darstellung von Gleichung (4.16).

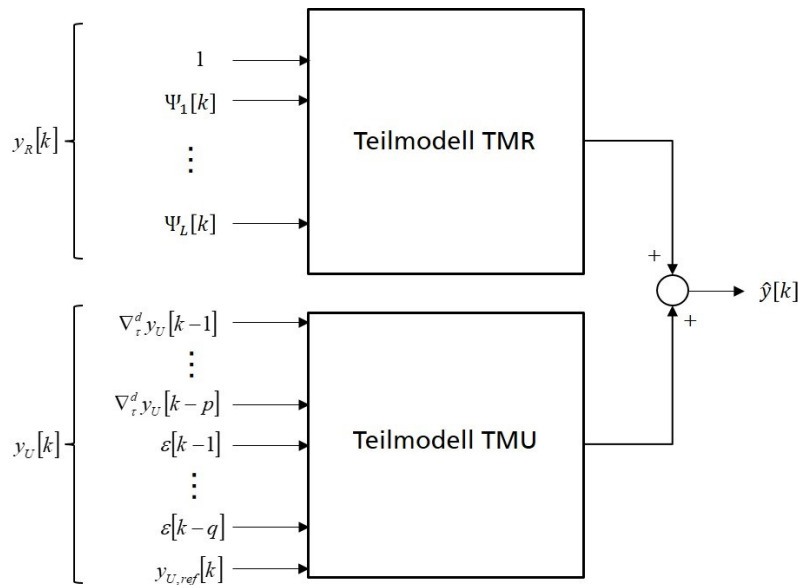


Abbildung 4.14: Grafische Darstellung der Modellgleichung

Mit dem Gesamtmodell und dessen an den Trainingsdatensatz adaptierten Modellparametern kann eine Schätzung für die preisbeeinflusste Lastzeitreihe $\hat{y}[k]$ vorgenommen werden. Durch die angenommene additive Verknüpfung der einzelnen Zeitreihenkomponenten lassen sich nach der Adaption der Modellparameter für das Gesamtmodell die beeinflusste und die unbeeinflusste Zeitreihenkomponente durch die Anwendung der beiden Teilmodelle separieren. Für die Rekonstruktion der beiden Zeitreihenkomponenten werden nur die jeweiligen Teilmodelle *TMU* und *TMR* für die Schätzung der beeinflussten und der unbeeinflussten Zeitreihenkomponenten $\hat{y}_R[k]$ und $\hat{y}_U[k]$ verwendet. Die beiden Teilmodelle werden nach dem Training separat betrachtet.

Durch die Minimierung des Modellfehlers des Gesamtmodells wird auch eine Minimierung der Fehler der beiden Teilmodelle *TMU* und *TMR* erreicht. Die Residuen ergeben sich laut den Gleichungen (4.17) bis (4.19) zu:

$$e[k] = y[k] - \hat{y}[k], \quad (4.17)$$

$$e_R[k] = y_R[k] - \hat{y}_R[k], \quad (4.18)$$

$$e_U[k] = y_U[k] - \hat{y}_U[k], \quad (4.19)$$

mit:	$e[k]$	- Residuen des Gesamtmodells,
	$e_R[k]$	- Residuen von <i>TMR</i> und
	$e_U[k]$	- Residuen von <i>TMU</i> .

Damit eine exakte Modellierung gelingen kann, müssen bei der Modellierung für die Residuen die Modellannahmen der BLUE-Bedingungen für eine optimale Prognose aus Abschnitt 2.2.1 erfüllt werden. Das Modell liefert nur dann optimale Ergebnisse, wenn diese Voraussetzungen je Einzelmodell erfüllt sind. Die Annahmen betreffen die Art und Weise des Zusammenhangs zwischen den abhängigen und den unabhängigen Variablen [116] und entsprechen dem Kriterium der optimalen Prognose. Zur Überprüfung der Modellannahmen kommen verschiedene Tests in Frage. In der vorliegenden Arbeit beschränken sich diese Tests auf die Untersuchungen der Residuen, bei denen auf die Eigenschaften des weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell geprüft wird [45] (siehe Abschnitt 5.2.2). Für die Auswertung der Modellresiduen wird der in Abbildung 3.5 aufgeführte Verarbeitungsworkflow angewendet. In einem praktischen Anwendungsfall können die Modellannahmen nur für das Gesamtmodell überprüft werden, da nur die Residuen $e[k]$ mit dem Einlaufen der Messwerte im Nachhinein ermittelt werden können. Die Residuen von *TMR* und *TMU* können nicht berechnet werden, was die Prüfung der Modellbedingungen für $e_R[k]$ und $e_U[k]$ unmöglich macht. Sind die unabhängigen Variablen von *TMU* mit den unabhängigen Variablen von *TMR* korreliert, dann können die Gewichte durch das angewendete Parameterschätzverfahren nicht exakt auf die beiden Teilmodelle „aufgeteilt“ werden. Allerdings ist eine Korrelation zwischen der Preiszeitreihe und der unbeeinflussten Zeitreihenkomponente möglich bzw. kann diese nicht ausgeschlossen werden. Der Grund dafür liegt bei der Preisbildungsvorschrift und deren Einflussgrößen beim DSM und DR. Beispielsweise ist das Load Shifting oder Peak Clipping eine Zielstellung beim DSM (siehe 2.1.2). Dabei sollen mit hohen Preisen Lastspitzen verschoben oder gekappt werden. Die Preisbildungsvorschrift erzeugt also zu Spitzenlastzeiten hohe Preise. Niedrige Preise werden eher zu Schwachlastzeiten erwartet. Als Resultat ist eine Korrelation zwischen der Preiszeitreihe und der unbeeinflussten Zeitreihenkomponente zu erwarten. Die Verteilung der Gewichte auf die Teilmodelle durch das Parameterschätzverfahren kann somit durch die bestehende Korrelation erschwert werden. Da der Fokus auf der Einzelschätzung der beiden Zeitreihenkomponenten $\hat{y}_R[k]$ und $\hat{y}_U[k]$ liegt, soll die Einführung einer Nebenbedingung als Ergebnis eines Nebenbedingungsmodells (siehe Abbildung 4.13) bei der Parameterschätzung die wirklichkeitsnahe Aufteilung der Gewichte unterstützen und somit die Genauigkeit der Teilmodelle verbessern.

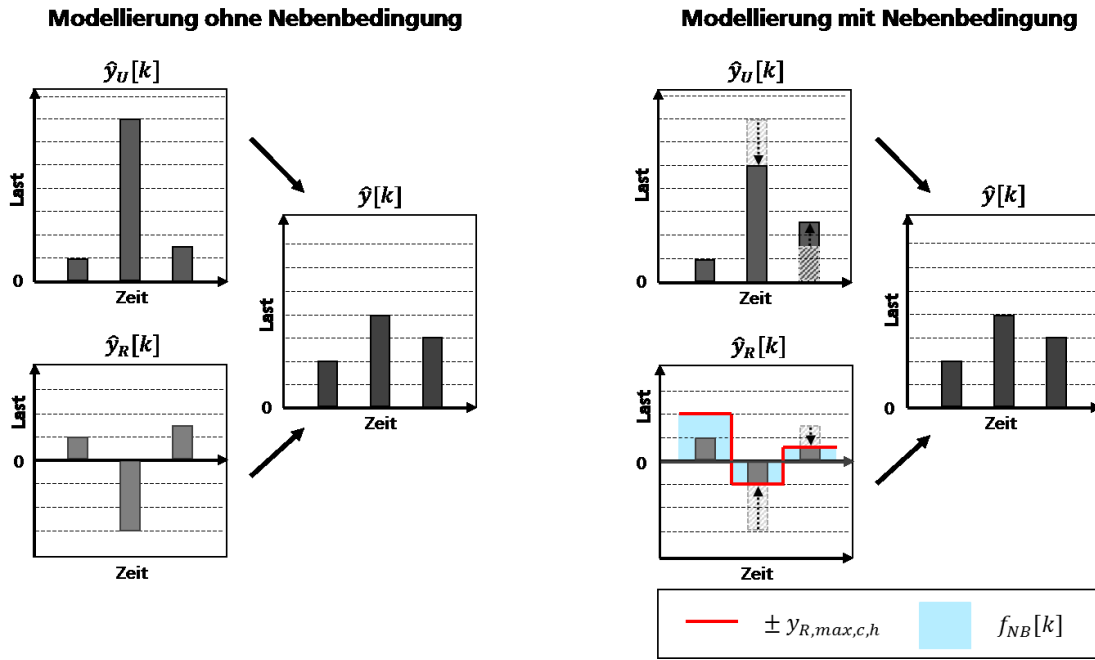


Abbildung 4.15: Exemplarische Darstellung der Wirkweise der Nebenbedingung

Das Parameterschätzverfahren muss dabei die Modellparameter so vorgeben, dass nicht nur der quadratische Fehler minimal wird, sondern die Zeitreihenkomponenten $y_U[k]$ und $y_R[k]$ eine realistische Aufteilung bzw. Größenordnung annehmen. Die Nebenbedingung soll dabei die Schätzung der beeinflussten Zeitreihenkomponente einschränken und somit mögliche Randinformationen, welche im Abschnitt 4.1 beschrieben werden, in die Modellbildung einbeziehen. In Abbildung 4.15 wird die Wirkweise exemplarisch dargestellt. Ein Indikator für reale Größenordnungen kann durch die Randinformationen wiedergegeben werden. Das Beeinflussungspotenzial beim DSM und damit der beeinflussbare Zeitreihenanteil sind begrenzt. Die Nebenbedingung soll diese Begrenzung bei der Modellierung realisieren. Das in Abbildung 4.13 aufgeführten Nebenbedingungsmodell erstellt aus dem Situationsvektor $s[k]$ eine Nebenbedingung, bei der die Randinformationen verarbeitet werden und die Größenordnung der Zeitreihenkomponenten $y_R[k]$ bei der Parameterschätzung entsprechend der Indikation über die reale Größenordnung eingeschränkt wird. Weiterhin soll die Nebenbedingung dazu führen, dass die mögliche funktionale Abhängigkeit zwischen den Teilmodellen vermieden wird. Das bedeutet, dass preisverursachte Auswirkungen möglichst aus dem *TMU* eliminiert werden sollen und umgekehrt. Ziel ist es, dass die Terme aus *TMU* keine funktionalen Auswirkungen auf die Schätzung der beeinflussten Zeitreihenkomponente haben und andersherum. Durch die Einführung der Nebenbedingung kann die Aufteilung der Modellparameter auf die Teilmodelle beeinflusst werden. Mit der Einführung einer Nebenbedingung, die die Modellparameter in die vorgegebene Richtung verschiebt, kann die klassische Methode der kleinsten Fehlerquadrate nicht als Parameterschätzverfahren angewendet werden. Stattdessen kommt ein numerisches Verfahren zur Anwendung. Die Gleichung (4.20) beschreibt das Optimierungsproblem bei der Parameterschätzung:

$$\min \sum_{i=1}^n (y[k] - \hat{y}[k])^2 = \min \sum_{i=1}^n (y[k] - (\hat{y}_R[k] + \hat{y}_U[k]))^2 \quad (4.20)$$

mit der nichtlinearen Nebenbedingungsfunktion:

$$f_{NB}[k] = \begin{cases} 0 \leq \hat{y}_R[k] \leq y_{R,max,c,h} & \text{für } p < p_{init} \\ 0 \geq \hat{y}_R[k] \geq -y_{R,max,c,h} & \text{für } p \geq p_{init} \end{cases}$$

mit: $y_{R,max,c,h}$ - maximal mögliche Laständerung in Abhängigkeit der Klasse c und Uhrzeitindex h und

p_{init} - Initial- bzw. Referenzpreis.

Zur Beschreibung der nichtlinearen Nebenbedingungsfunktion wird von einem Referenzpreis p_{init} ausgegangen. Der Referenzpreis wird dabei so bestimmt, dass dieser einem mittleren Preisniveau für den aktuellen Zeitpunkt entspricht. Preise über- und unterhalb des Referenzpreises werden somit als „teuer“ bzw. „billig“ angesehen. Bei einem konstanten Preis würde sich ein unbeeinflusstes Verbrauchsverhalten mit $y_R[k] = 0$ einstellen. Entsprechend der allgemeinen Annahme, dass die Preiselastizität ein negatives Vorzeichen besitzt, wird sich bei einer Preisänderung über den Referenzpreis tendenziell eine Leistungsabsenkung einstellen ($\Delta p > 0$ ergibt $\Delta y < 0$) und bei einer Preisänderung unter den Referenzpreis eine Leistungssteigerung ($\Delta p < 0$ ergibt $\Delta y > 0$). Diese Randinformation wird in die Nebenbedingung einbezogen, indem bei Preisen über dem Referenzpreis nur Lastabsenkungen bei der Optimierung möglich sind und Laststeigerungen nur bei Preisen unterhalb des Referenzpreises. Die Nebenbedingung begrenzt die maximal mögliche Laständerung für eine aktuelle Preissituation. Für die Bestimmung der maximal möglichen Laständerung $y_{R,max,c,h}$ wird die Gleichung (3.7) und die im Abschnitt 3.4.1 beschriebene Abhängigkeit der Preiselastizität von Verbrauchern oder Verbrauchergruppe von Uhrzeit und Kalenderabhängigkeiten herangezogen. Die maximale Ausprägung der Preiselastizität ergibt sich als Funktion der maximalen Laständerung und der mittleren Preisänderung $\overline{\Delta p}_{c,h(k)}$ unter Berücksichtigung aller Werte je Klasse c und Uhrzeitindex h . Als maximale Ausprägung der Laständerung wird dabei das 95%-Quantil $Q_{95}(\Delta y_{c,h})$ für eine negative mittlere Preisänderung und das 5%-Quantil $Q_{05}(\Delta y_{c,h})$ für eine positive mittlere Preisänderung angenommen. Durch die Verwendung des 5%- bzw. 95%-Quantils anstatt der Maximalwerte soll eine Verfälschung durch statistische Ausreißer verhindert werden. Die Gleichung (4.21) beschreibt die maximale Ausprägung der Preiselastizität in Abhängigkeit der Klasse c und des Uhrzeitindex h :

$$\zeta_{max,c,h} = \begin{cases} \frac{Q_{95}(\Delta y_{c,h})/y_{init}}{\overline{\Delta p}_{c,h}/p_{init}} & \text{für } \overline{\Delta p}_{c,h} < p_{init} \\ \frac{Q_{05}(\Delta y_{c,h})/y_{init}}{\overline{\Delta p}_{c,h}/p_{init}} & \text{für } \overline{\Delta p}_{c,h} \geq p_{init} \end{cases} \quad (4.21)$$

mit: $\zeta_{max,c,h}$ - maximale Ausprägung der Preiselastizität in Abhängigkeit der Klasse c und des Uhrzeitindex h ,

$Q_{95}(\Delta y_{c,h})$ - 95%-Quantil der Laständerung,

$Q_{05}(\Delta y_{c,h})$ - 5%-Quantil der Laständerung,

$\overline{\Delta p}_{c,h}$ - mittlere Preisänderung im Vergleich zum Initial- bzw. Referenzpreis p_{init} und

$\Delta y_{c,h}$ - Änderung des Verbrauchs zu einem Referenzverbrauch in Abhängigkeit der Klasse c und des Uhrzeitindex h .

Die maximale Laständerung $y_{R,max,c,h}$ ergibt sich je Klasse c und Uhrzeitindex h in Abhängigkeit der Preisabweichung vom Referenzpreis $\Delta p[k]$ und $\zeta_{max,c,h}$ zum aktuellen Zeitpunkt. Durch die Nebenbedingung wird für die Schätzung der Modellparameter der Lösungsraum bei der Optimierung eingeschränkt. Die Gleichung (4.22) gibt die maximal mögliche Laständerung an, welche als Nebenbedingungsfunktion in Gleichung (4.20) die $y_R[k]$ begrenzt:

$$y_{R,max,c,h} = \zeta_{max,c,h} \cdot (\Delta p[k]/p_{init}) \cdot y_{init} \quad (4.22)$$

mit: $y_{R,max,c,h}$ - maximal mögliche Laständerung in Abhängigkeit der Klasse c und des Uhrzeitindex h und

Δp - Änderung des Preises zu einem Initial- bzw. Referenzpreis.

Die Abbildung 4.16 zeigt ein exemplarisches Beispiel der Berechnung von $y_{R,max,c,h}$ für die Nebenbedingungsfunktion. Auf der linken Seite der Abbildung sind beispielhaft die maximale Ausprägung der Preiselastizität $\zeta_{max,c,h}$, der Preis $p[k]$ im Vergleich zu einem konstanten Referenzpreis p_{init} und die zugehörige maximal mögliche Laständerung jeweils für verschiedene Klassen c und Uhrzeitindex h für einige Zeitschritte abgebildet. Für den rot umrahmten Bereich ist bei einer negativen Preiselastizität und einem aktuellen Preis über dem Referenzpreis ($\Delta p > 0$) die maximal mögliche Laständerung $y_{R,max,c,h}$ für $c = 1$ und $h = 40$ dargestellt. Die hellblauen Flächen markieren den Wertebereich, indem sich die beeinflusste Zeitreihenkomponente $y_R[k]$ mit der Parameterschätzung für den Trainingsdatensatz einstellen wird. Die zur Berechnung von $y_{R,max,c,h}$ nötigen Größen in Abhängigkeit der Werteverteilung der Last- und Preiszeitreihe sind auf der rechten Seite abgebildet. Betrachtet man die Werteverteilung der Preiszeitreihe für $c = 1$ und $h = 40$ im Trainingszeitbereich, dann ist im Mittel ein Preis höher dem Referenzpreis auszumachen. Dementsprechend ist eine im Mittel negative Laständerung (Lastabsenkung) bei den Werten der Lastzeitreihe für $c = 1$ und $h = 40$ zu erkennen.

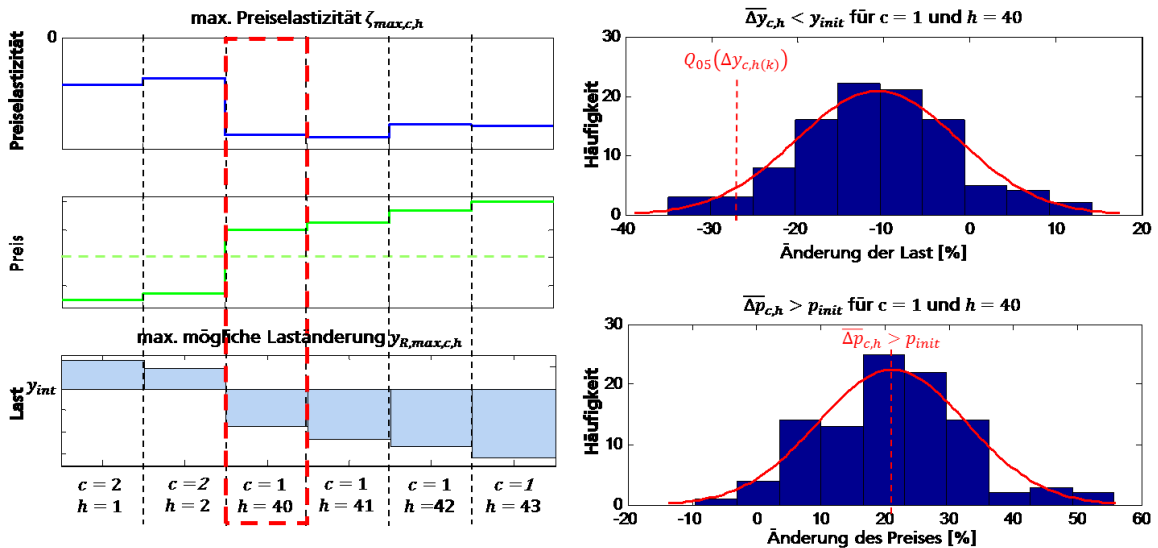


Abbildung 4.16: Exemplarisches Beispiel für die Berechnung der maximal möglichen Laständerung für die Nebenbedingungsfunktion

4.4.3 Alternative Strategie der Dekomposition

Für die Dekomposition einer preisbeeinflussten Lastzeitreihe in die beeinflusste und die unbeeinflusste Zeitreihenkomponente wird im Abschnitt 4.4.2 die modellbasierte Dekomposition vorgestellt. Das Modell wird dabei auch zur Vorhersage eingesetzt. Ein alternatives Vorgehen für die Lösung der Aufgabe der Prognose von beeinflussten Zeitreihen wird im vorliegenden Abschnitt aufgezeigt und diskutiert. Die Vorgehensweise sieht dabei zwei Verarbeitungsschritte vor. Zunächst wird im ersten Schritt die Dekomposition der beeinflussten Zeitreihe vorgenommen. Im zweiten Schritt wird die benötigte Zeitreihenkomponente vorhergesagt. Wenn eine Dekomposition historischer Werte der beeinflussten Zeitreihen in die beeinflusste und die unbeeinflusste Zeitreihenkomponente vorab gelingt, dann kann die Prognose der unbeeinflussten Zeitreihenkomponente anhand etablierter Methoden der Lastprognose vorgenommen werden. Der Trainingsdatensatz besteht dann aus der ermittelten unbeeinflussten Zeitreihenkomponente.

Der alternative Ansatz zur modellbasierten Dekomposition wird in Abbildung 4.17 und Abbildung 4.18 schematisch dargestellt [61]. Wenn ein Modell alle systematischen Einflussgrößen auf das Verbrauchsverhalten explizit berücksichtigt, dann umfassen die Modellresiduen $e[k]$ nur noch zufällig auftretende Abweichungen zwischen den Messwerten und den Modellausgängen [30]. In diesem Fall besteht der Modellfehler $e[k]$ nur noch aus weißem Rauschen [14], [45]. Für die Lastprognose von Verbrauchsprozessen (ohne Preisbeeinflussung) existiert in der Literatur eine Vielzahl von Modellansätzen. Ein Überblick über etablierte Modellansätze für Lastprognosen wird im Abschnitt 2.3.1 vorgestellt. Für die folgende Diskussion wird angenommen, dass ein etablierter Ansatz zur Prognose einer Lastzeitreihe existiert, für den die Fehlerzeitreihe nur noch aus weißem Rauschen besteht (siehe Abbildung 4.17). Kann nachgewiesen werden, dass die Modellresiduen weißem Rauschen entsprechen, dann wurde die optimale Prognosemethode entworfen [14], [45]. Einer Verbesserung des Modells ist somit nicht mehr möglich.

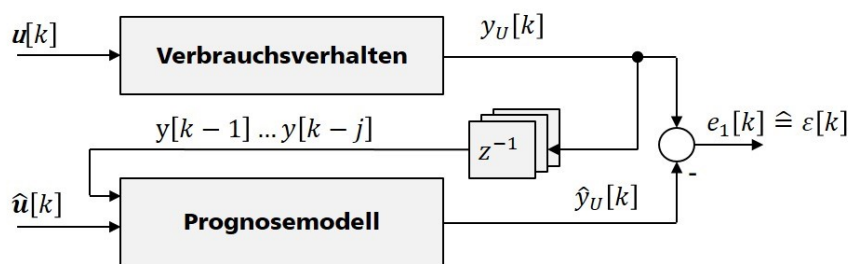


Abbildung 4.17: Optimales Prognosemodell

Wird der Verbrauchsprozess in der Folge durch DSM und somit durch eine Preiszeitreihe beeinflusst, dann kann die Beeinflussung durch die Preiszeitreihe auch als Störgröße interpretiert werden. Das Prognosemodell kann ohne Kenntnis der Preiszeitreihe die Auswirkungen, die der Preis auf die Lastzeitreihe ausübt, nicht berücksichtigen. Folglich ist zu erwarten, dass der entstehende Modellfehler in den Situationen, in denen der Preis einen signifikanten Einfluss auf die Last ausübt, deutlich ausgeprägt ist und somit mit der Preiszeitreihe korreliert. Der funktionale Zusammenhang zwischen Preis und Laständerung findet sich in der Fehlerzeitreihe wieder. Kann für einen Verbrauchsprozess ein optimales Prognosemodell nachgewiesen werden, dann kann der funktionale Zusammenhang zwischen Preis- und Laständerung auf die Modellresiduen übertragen werden, indem das optimale Prognosemodell des vorher unbeeinflussten Verbrauchsprozesses auf den in

der Folge durch Preise beeinflussten Verbrauchsprozess angewendet wird. Der Preis findet dabei keine Verwendung als Eingangsgröße des Prognosemodells (siehe Abbildung 4.18). In [61] werden dazu zwei Fallbeispiele aufgeführt, in denen diese alternative Dekompositionsstrategie diskutiert wird.

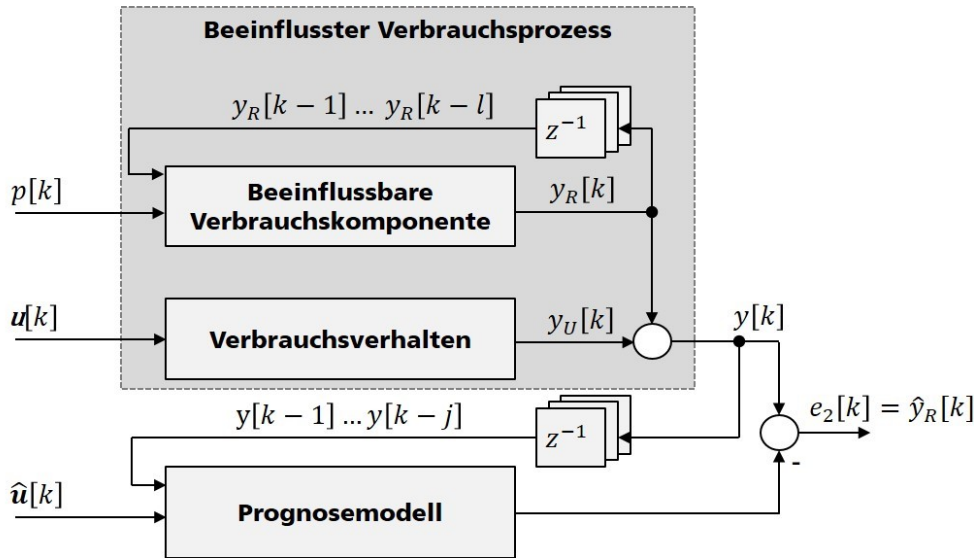


Abbildung 4.18: Prognosemodell ohne Berücksichtigung des Preises (modifiziert nach [61])

In der praktischen Anwendung können in der Regel nicht alle systematischen Einflussgrößen berücksichtigt werden, da die Datenerfassung technisch nicht möglich oder zu aufwendig ist oder nicht alle relevanten Einflussgrößen bekannt sind. Folglich besteht die Fehlerzeitreihe nicht aus weißem Rauschen, sondern die Werte beinhalten noch funktionale Zusammenhänge zu nicht bekannten Einflussgrößen oder sind untereinander korreliert. Als Folge kann nicht unterschieden werden, ob Residuen auf den Preiseinfluss oder auf das nicht optimale Prognosemodell zurückzuführen sind. Die Unsicherheit durch das nicht optimale Prognosemodell wird somit auf die Residuen übertragen. Das benötigte optimale Prognosemodell für die unbeeinflusste Zeitreihenkomponente kann für den beeinflussten Verbrauchsprozess nur mit Hilfe der gemessenen Größe der beeinflussten Zeitreihen $y[k]$ nicht zweifelsfrei ermittelt und nachgewiesen werden. Aus diesem Grund wird die im vorliegenden Abschnitt vorgestellte alternative Strategie zur Dekomposition verworfen und für das Konzept und den Entwurf zur Prognose von preisbeeinflusstem Verbrauchsverhalten in den weiteren Abschnitten nicht weiter berücksichtigt.

4.4.4 Ablauf bei der Anwendung des Vorhersagesystems

Für die Anwendung des Vorhersagesystems von preisbeeinflussten Lastzeitreihen wird ein iteratives und rekursives Vorgehen vorgeschlagen. In der Abbildung 4.19 wird ein detailliertes Ablaufdiagramm für die Anwendung des Vorhersagesystems dargestellt. Für einen Trainingszeitbereich wird das IARIMA-Modell dabei nur für die Dekomposition eingesetzt. Pro Iteration wird die Dekomposition für ein Betrachtungsintervall ΔT durchgeführt. Das Betrachtungsintervall umfasst bei der Anwendung des Modells im Rahmen der vorliegenden Arbeit einen Tag (96 Tastschritte). Die Berechnung für die Dekomposition für ΔT stützt sich dabei rekursiv auf die Berechnungsergebnisse für $\hat{y}_R[k]$ und $\hat{y}_U[k]$ mit $k = 1 \dots k_0$ der vorigen Iteration. Die Schätzungen für die beeinflusste und

die unbeeinflusste Zeitreihenkomponente $\hat{y}_R[k]$ und $\hat{y}_U[k]$ werden unter Verwendung der aktuellen Modellparameter für den gesamten bisherigen Trainingszeitbereich $k = 1 \dots k_0$ neu berechnet und dienen als Datengrundlage für die nächste Iteration. Mit jeder Iteration werden die entsprechenden Modellparameter des IARIMA-Modells $\boldsymbol{\delta} = \delta_{c,h}$, $\boldsymbol{\beta} = \beta_{c,h}$ und $\boldsymbol{\eta} = \eta_{c,h}$ mit $c = 1, \dots, C$ und $h = 1, \dots, D$ auf Grundlage der aktuellen Trainingsdaten aktualisiert. In Abhängigkeit der Klasse c und des Tageszeitindex h dienen die Modellparameter als Startwerte für die nächste Iteration. Die Datenbasis erweitert sich bei diesem Vorgehen pro Iteration um ein Betrachtungsintervall. Für jede Kombination von c und h wird ein individuelles Modell (klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung – siehe Abschnitt 4.3) mit individuellen Modellparametern eingesetzt. Mit diesem Vorgehen ist nach dem Training die Dekomposition für den kompletten Trainingsdatensatz abgeschlossen und die Schätzungen der einzelnen Zeitreihenkomponenten $\hat{y}_R[k]$ und $\hat{y}_U[k]$ liegen vor.

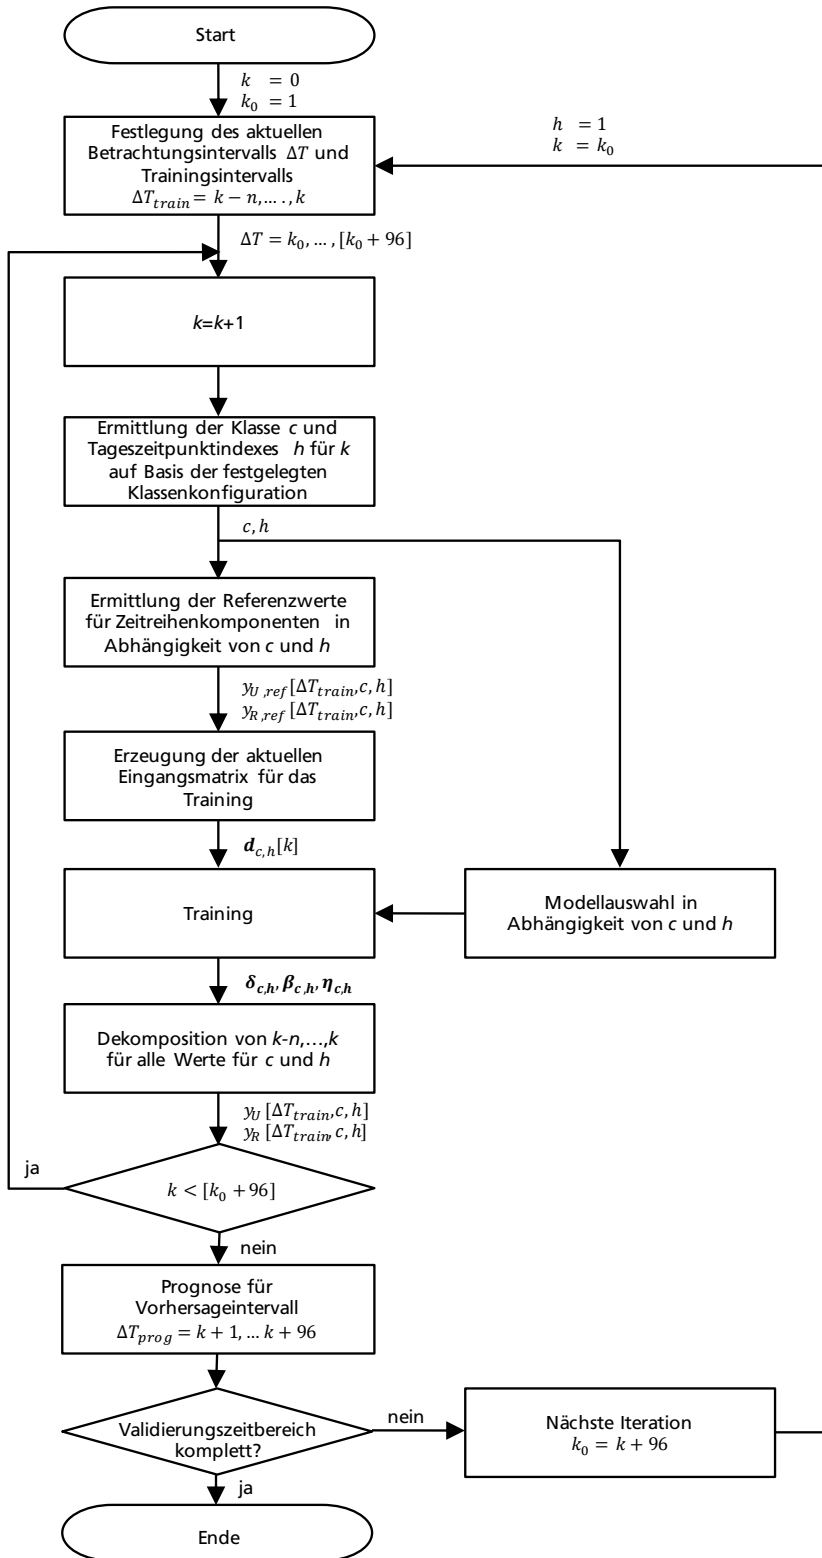


Abbildung 4.19: Ablauf der modellbasierten Dekomposition und Prognose

Für die Prognose wird das Modell für das Prognoseintervall ΔT_{prog} eingesetzt. Für die Untersuchungen im Rahmen der vorliegenden Arbeit wird ein Prognoseintervall $\Delta T_{prog} = k + 1, \dots, k + 96$ festgelegt. Der Ablauf der Prognose wird in Abbildung 4.20 als Ablaufdiagramm dargestellt.

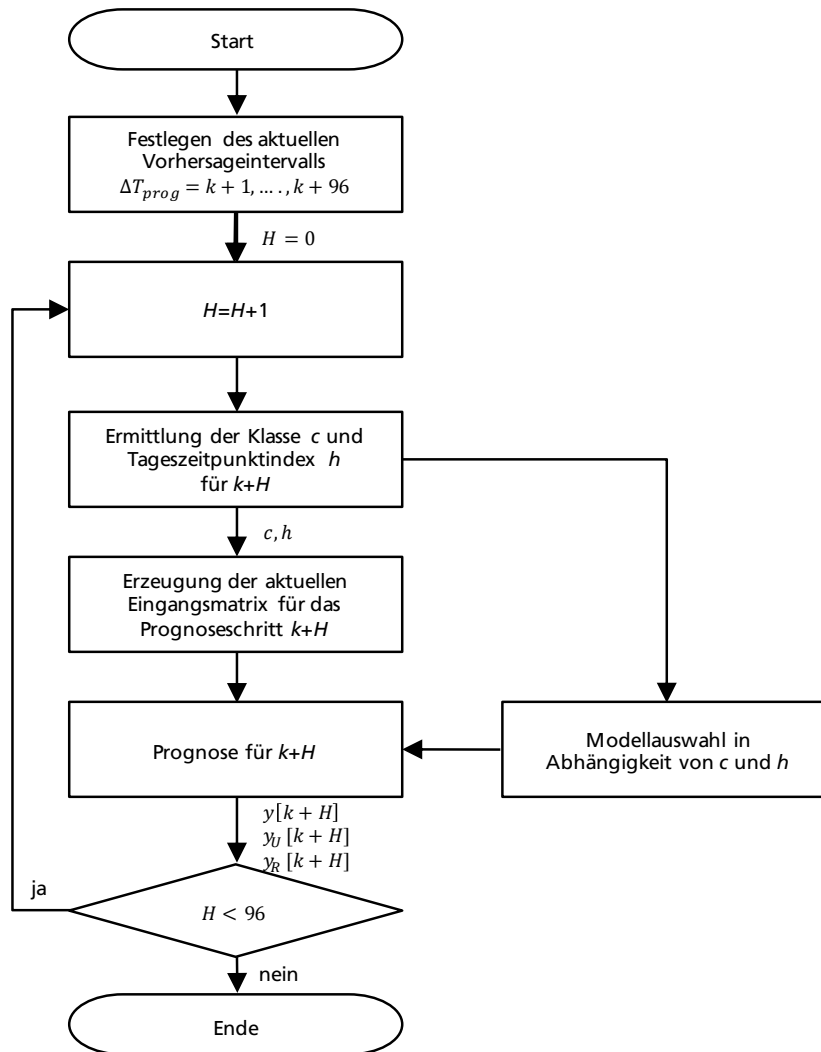


Abbildung 4.20: Ablauf der Prognose für Vorhersageintervall $\Delta T_{prog} = k + 1, \dots, k + 96$

4.5 Zusammenfassung und wichtigste Erkenntnisse

Im Abschnitt 4 wird das Konzept für den Entwurf der neuen Prognosemethode für preisbeeinflusste Lastzeitreihen erörtert. Die Modellierung der Prognosemethode berücksichtigt dabei die spezifischen Anforderungen an die Prognose, die aus dem Abschnitt 3 hervorgehen. Zunächst wird im Abschnitt 4.1 ein geeignetes Vorgehenskonzept für den Modellentwurf skizziert. Dieses beschreibt die Herangehensweise als Gesamtkonzept für die Modellbildung im Rahmen der vorliegenden Arbeit und umfasst die Primärdatenaufbereitung, die Analyse und den Entwurf bis hin zur Anwendung.

Im Abschnitt 4.2 wird der Modellansatz zur Beschreibung preisbeeinflusster Lastzeitreihen vorgestellt. Dabei wird auf der Grundlage des erweiterten Komponentenmodells die beeinflusste Zeitreihe in die beeinflusste und in die unbeeinflusste Zeitreihenkomponente zerlegt. Die Vorteile dieser Herangehensweise liegen einerseits in der Möglichkeit, die beiden Zeitreihenanteile in separaten Teilmodellen zu beschreiben, welche jeweils die spezifische Charakteristik der unbeeinflussten und der beeinflussten Zeitreihenkomponente berücksichtigen. Ein weiterer Vorteil besteht in der Dekomposition der beeinflussten Lastzeitreihe in die beeinflusste und die unbeeinflusste Zeitreihenkomponente. Es werden verschiedene Modellansätze verwendet, um die beiden Zeitreihenkomponenten zu beschreiben.

ponenten zu beschreiben. Das Teilmodell zur Abbildung der beeinflussten Zeitreihenkomponente (*TMR*) wird als gewichtete Summe dargestellt und berücksichtigt verschiedene unabhängige Variablen, die in Abhängigkeit von Preisinformationen den preissensitiven Anteil der beeinflussten Lastzeitreihe modellieren. Das Teilmodell zur Beschreibung der unbeeinflussten Zeitreihenkomponente (*TMU*) wird als ARIMA-Modell realisiert. Der ARIMA-Modellansatz basiert auf Differenzenfiltern. Für die Berücksichtigung von Kalendereffekten wird für diese Differenzenfilter ein typ-tagabhängiges und datumsbasiertes Regelwerk (Kalenderkonfiguration) eingesetzt. Die lastzeitreihenspezifische Kalenderkonfiguration wird jeweils als Ergebnis einer vorab durchzuführenden Zeitreihenanalyse festgelegt.

Im Abschnitt 4.3 wird die neue Methodik für die Anwendung des Prognosemodells vorgestellt. Für eine Prognose mehrerer Zeitschritte in die Zukunft wird hierfür das Framework der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung genutzt. Dieses ermöglicht die Anwendung eines beliebigen Prognosemodells für die Vorhersage für $k + H$ mit $H = 1, \dots, N_H$. Das Framework basiert auf der Herangehensweise eines Mehrschrittmodells, bei dem je Vorhersagehorizont H ein separates Modell verwendet wird. Dabei wird auf das Konzept von lokaler und globaler Prognose zurückgegriffen. Globale Modelle oder Modellkomponenten sind für den gesamten Zeitreihenverlauf gültig. Lokale Modelle oder Modellkomponenten gelten hingegen nur stückweise für den Zeitreihenverlauf. Lokale Abschnitte werden als Klassen unterteilt. Jede Klasse wird durch ein separates klassenbezogenes Einzelmodell abgebildet. Für eine weitere Spezialisierung wird zusätzlich je Uhrzeit ein separates Einzelmodell verwendet. Beim Framework der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung wird also je Klasse, je Uhrzeit und je Vorhersagehorizont jeweils ein separates Einzelmodell eingesetzt. Globale Modellkomponenten sind beispielsweise die zu ermittelnde Klassen- und Kalenderkonfiguration. Mit der Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung wird unterstellt, dass in lokalen Abschnitten unterschiedliche Gesetzmäßigkeiten wirken, sodass eine Modellierung lokaler Abschnitte mit spezialisierten Einzelmodellen hinsichtlich einer Verbesserung der Prognosequalität des Gesamtmodells sinnvoll ist. Für die Ermittlung einer geeigneten Klassenkonfiguration wird auf Grundlage einer qualitativen Bewertung typischer elektrischer Lastzeitreihen der Einflussfaktor Zeit für das Aufspannen einer möglichen Klassenstruktur verwendet. Die festgelegte Klassenstruktur unterscheidet bis zu sieben Typtage als $c = 1, \dots, 7$ Typtagklassen, welche im Rahmen der qualitativen Bewertung auf ein typisches Verbrauchsverhalten an verschiedenen Wochentagen (Montag bis Sonntag) zurückgeführt wird. Die lastzeitreihenspezifische Klassenstruktur wird mit Hilfe eines Kreuzvergleichs der Werteverteilungen der lokalen Abschnitte vorgenommen. Wenn zwei Stichproben die gleiche Verteilung besitzen, dann kann angenommen werden, dass diese der gleichen Grundgesamtheit entstammen und somit mit dem gleichen Modell beschrieben werden können. Alle Klassen mit der gleichen Verteilung werden zusammengefasst und durch das gleiche Modell abgebildet. Im Rahmen der vorliegenden Arbeit wird für die Anwendung des Konzeptes der globalen und lokalen Prognose folgendes Vorgehen festgelegt:

- Global: Globale Modellkomponenten sind die zu ermittelnde Klassenkonfiguration, die im Abschnitt 4.3.2 vorgestellt wird, die Anwendung des Konzeptes der Mehrschrittmodelle, die zu ermittelnde Kalenderkonfiguration sowie die Verwendung des IARIMA-Modellansatzes (Siehe Abschnitt 4.2).
- Lokal: Die festgelegte Klassenstruktur unterscheidet die sieben Wochentage als $c = 1, \dots, 7$ Typtagklassen. Feiertage werden dabei der Klasse Sonntag zugeordnet. Innerhalb einer

Klasse werden aufgrund von typntagindividuellen Verbrauchsmustern je Uhrzeitindex h zusätzlich $1, \dots, 96$ lokale Abschnitte (entsprechend Zeitreihen aus dem Stromsektor mit einer Abtastzeit von 15 Minuten) unterschieden. Die aufgespannte Klassenstruktur separiert 7×96 lokale Abschnitte, die jeweils durch ein separates Einzelmodell beschrieben werden. Die tatsächlich für die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung angewendete Klassenkonfiguration wird mittels eines Kreuzvergleiches der Verteilungen der vorliegenden Datenbeispiele über die aufgespannte Klassenstruktur vorgenommen. Lokale Abschnitte, die untereinander die gleiche Verteilung aufweisen, werden zusammengefasst. Lokale Abschnitte, welche nicht die gleichen Verteilungen aufweisen, werden jeweils mit einem separaten Einzelmodell beschrieben.

Im Abschnitt 4.4 wird das neue Vorhersagesystem für preisbeeinflusste Lastzeitreihen vorgestellt. Im Abschnitt 4.4.1 wird der grobe Aufbau beschrieben. Das Vorhersagesystem besteht aus dem Klassifikations- und dem Vorhersagemodul. Das Klassifikationsmodul teilt den Datenbestand in zusammengehörige lokale Bereiche entsprechend der im Abschnitt 4.3 beschriebenen Klassenkonfiguration ein. Das Vorhersagemodul umfasst entsprechend des Frameworks der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung und der jeweiligen Klassenkonfiguration die entsprechenden Einzelmodelle. Jedes Einzelmodell basiert auf dem IARIMA-Modellansatz und ist jeweils in die Teilmodelle *TMR* und *TMU* zur Abbildung der beeinflussten und unbeeinflussten Zeitreihenkomponente unterteilt.

Der Abschnitt 4.4.2 beschreibt die modellbasierte Dekomposition. Für jedes Einzelmodell werden die spezifischen Modellparameter mit Hilfe eines Parameterschätzverfahrens ermittelt. Dabei wird der quadratische Fehler des Einzelmodells mittels eines numerischen Optimierungsverfahrens mit Berücksichtigung einer nichtlinearen Nebenbedingung minimiert. Durch die Nebenbedingung werden folgende Randbedingungen (siehe auch Abschnitt 4.1) bei der Parameterschätzung Berücksichtigung:

- Maximal mögliche Laständerung: Das DSM-Potenzial und somit auch die maximal mögliche Laständerung kann vorab abgeschätzt werden. Die Nebenbedingung begrenzt die maximal mögliche Laständerung, also die beeinflusste Zeitreihenkomponente entsprechend der Abschätzung des DSM-Potenzials je Einzelmodell.
- Negatives Vorzeichen der Preiselastizität: Es werden nur Laständerungen umgekehrt proportional zu Preisänderungen zugelassen. Wird der Preis in Bezug zu einem Referenzpreis als „teuer“ eingeschätzt, dann sind nur Lastabsenkungen (beeinflusste Zeitreihenkomponente ist negativ) zugelassen und umgekehrt.

Die alternative Strategie der Dekomposition, die Abschnitt 4.4.3 enthält, wird bei der Modellierung im Rahmen der vorliegenden Arbeit nicht berücksichtigt.

Im Abschnitt 4.4.4 wird der spezifische Ablauf bei der Anwendung des neuen Vorhersagesystems dargestellt. Der Ablauf bei der Anwendung wird in Abbildung 4.21 in einer vereinfachten Darstellung aufgezeigt. Neben dem vereinfachten Ablaufdiagramm werden alle für die Evaluierung angewendeten Elemente des Methodenentwurfs aus Abschnitt 4 nochmal zusammenfassend aufgeführt. Der Ablauf umfasst folgende Punkte:

- Zunächst wird die Eingangsmatrix je Einzelmodell entsprechend der ermittelten Klassenkonfiguration durch das Klassifikationsmodul mit dem Entscheidungsvektor $d_{c,h}[k]$ erstellt (siehe Abschnitt 4.3).

- Anschließend wird das Einzelmodell basierend auf dem IARIMA-Modellansatz für die Trainingsphase als Teil des Vorhersagemoduls angewendet. Die Modellgleichung wird in Abbildung 4.21 aufgezeigt und in den Abschnitten 4.2.1 und 4.2.2 erläutert. Für die Schätzung der Modellparameter δ , β und η wird ein numerisches Optimierungsverfahren mit Berücksichtigung einer nichtlinearen Nebenbedingung aus dem Nebenbedingungsmodell als Teil des Vorhersagemoduls eingesetzt. Die Modellgleichung des Nebenbedingungsmodells wird in Abbildung 4.21 aufgeführt und wird im Abschnitt 4.4.2 erklärt.
- Mit den ermittelten Modellparametern wird die Dekomposition der Trainingsdaten durchgeführt. Die in beeinflusste und unbeeinflusste Zeitreihenkomponente zerlegte preisbeeinflusste Lastzeitreihe wird rekursiv für die nächste Iteration beim Training und für die Ermittlung der Eingangsmatrix für die Anwendung der Prognose erzeugt (siehe Abschnitt 4.2.2).
- Als nächster Schritt werden entsprechend des Vorhersagehorizonts und des Zeitstempels die jeweiligen Einzelmodelle für die Prognose angewendet. Die nächste Iteration kann nach dem Anpassen des Betrachtungshorizontes beginnen.

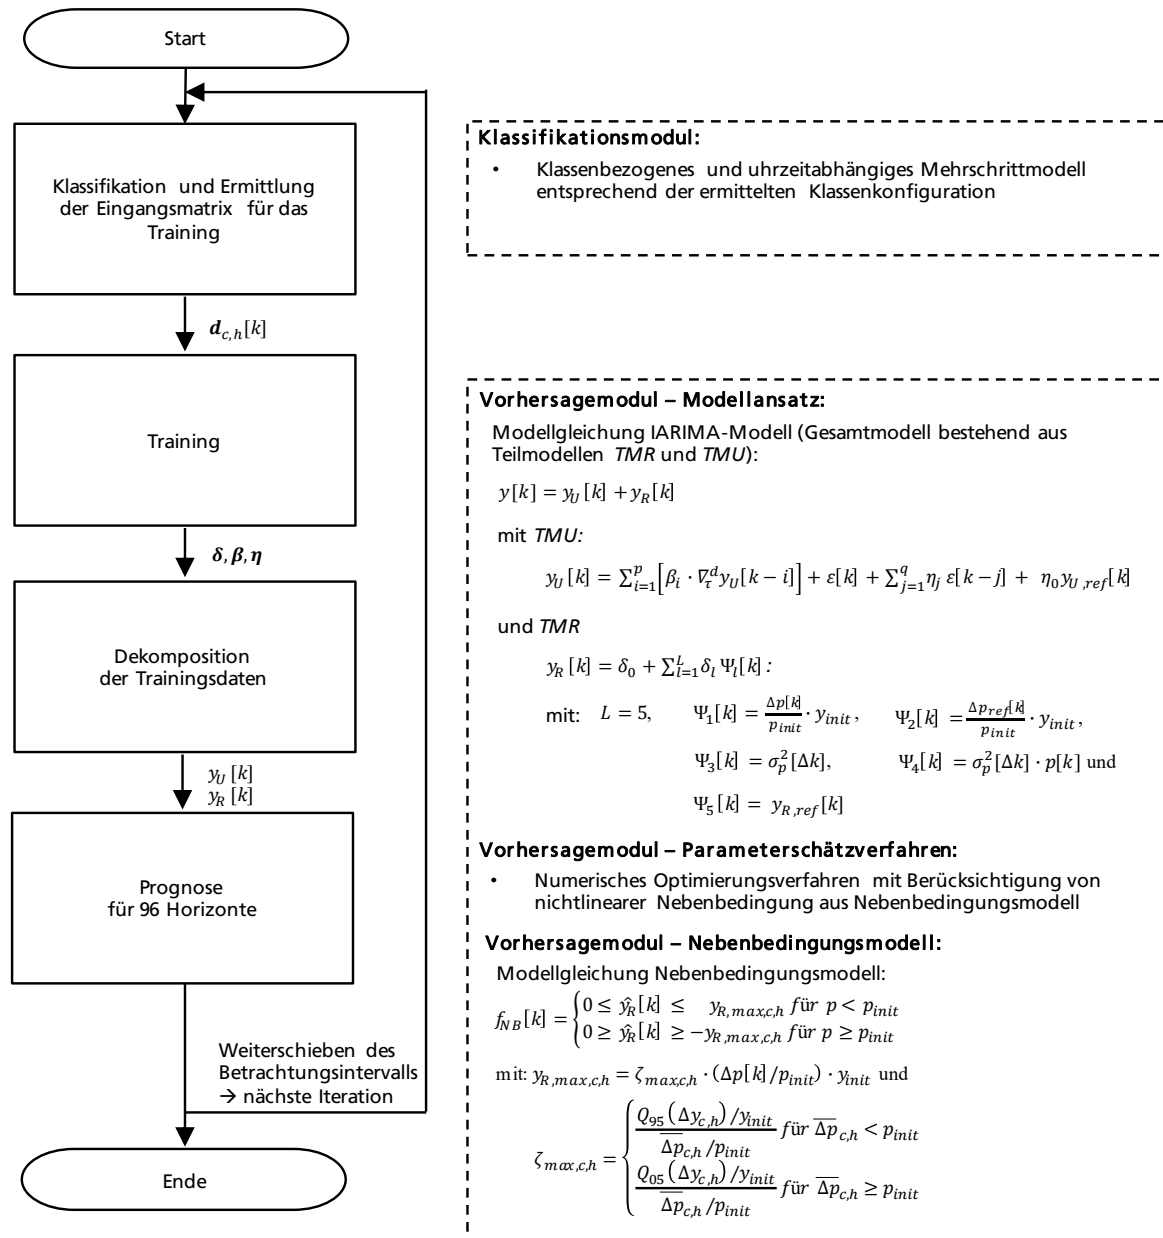


Abbildung 4.21 Vereinfachte Darstellung des Ablaufs der Methodenanwendung und Zusammenfassung der Elemente des Methodenentwurfs

5 Evaluierung des Lösungskonzeptes

5.1 Datengrundlage

Für die Validierung des aufgeführten Modellansatzes werden ein synthetischer und ein realer Smart-Meter-Beispieldatensatz verwendet. Der synthetische Beispieldatensatz wird im Abschnitt 5.1.1 und der aus einer Feldstudie stammende real gemessene Datensatz im Abschnitt 5.1.2 vorgestellt.

5.1.1 Synthetischer Datensatz und Zeitreihengenerator für Energiezeitreihen

Im Abschnitt 5.1.1.1 wird der synthetische Beispieldatensatz beschrieben. Dieser wurde mit Hilfe eines Zeitreihengenerators für Energiezeitreihen erstellt. Der Zeitreihengenerator wurde im Rahmen der vorliegenden Arbeit entwickelt und wird im Abschnitt 5.1.1.2 eingeführt.

5.1.1.1 Synthetischer Datensatz

Die synthetischen Beispieldatensätze werden mit Hilfe des im Abschnitt 5.1.1.2 beschriebenen Zeitreihengenerators erzeugt. In realen Datensätzen für preissensitive Lastzeitreihen sind die Zeitreihenkomponenten $y_R[k]$ und $y_U[k]$ nicht separat messbar. Der Vorteil bei der Verwendung synthetischer Datensätze besteht darin, dass die einzelnen Zeitreihenkomponenten bekannt sind und die Untersuchungen unter kontrollierten Bedingungen durchgeführt werden können. Dabei können die erwarteten Phänomene der zu untersuchenden Prozessklasse explizit in den synthetischen Zeitreihen erzeugt und in verschiedenen Ausprägungen vorgegeben werden. Eine separate Ermittlung der Residuen $e_R[k]$ und $e_U[k]$ (siehe Gleichungen (4.17) bis (4.19)) der beiden Teilmodelle *TMR* und *TMU* ist somit möglich. Die Leistungsfähigkeit des gewählten Ansatzes zur Prognose kann in Folge dessen für die beiden einzelnen Zeitreihenkomponenten $y_R[k]$ und $y_U[k]$ validiert werden. Mit Hilfe des erweiterten Komponentenmodells aus Abschnitt 3.2 werden die synthetischen Beispielzeitreihen für ein Jahr mit einer Abtastzeit von 15 Minuten generiert. Es werden synthetische Zeitreihen erzeugt, die über ihre charakteristischen Eigenschaften die zu untersuchende Prozessklasse definieren. Dafür wird die Gültigkeit des aufgeführten Modellansatzes überprüft. Für einen möglichst realitätsnahen Beispieldatensatz entsprechend der angenommen Prozessklasse werden folgende charakteristische Eigenschaften für $y_U[k]$ simuliert:

- Unterschiedliche Verbrauchsmuster (Tagesmuster) durch kalenderabhängige (bzw. wochentagabhängige) Standardlastprofile,
- Unterschiedliche Lastniveaus in Abhängigkeit von Typtagen (Wochenrhythmus),
- Nichtlinearer Jahrestrend (saisonale Effekte) und
- Stochastischer normalverteilter Rauschanteil.

Für die Simulation von $y_R[k]$ werden die Abhängigkeiten zum Einflussparameter Zeit (Uhrzeit, Typtag, saisonal) beachtet. Die Matrix \mathbf{Z} nach Gleichung (3.10), welche die Eigen- und die Kreuzpreiselastizität beschreibt, wird in Abhängigkeit von der Uhrzeit individuell besetzt. In Abhängigkeit von Typtagen und saisonalen Effekten (Unterscheidung in c Klassen) werden jeweils individuelle Matrizen \mathbf{Z}_c (pro Klasse c) eingesetzt. In Abbildung 5.1 ist exemplarisch die Matrix \mathbf{Z}_c für $c = 1$ (Typtag = Montag) als Heatmap abgebildet. Die dabei dargestellte Kreuzpreiselastizität ist ein Maß für die Verbraucherreaktion zu einem Zeitintervall i auf Preisänderungen im Zeitintervall

j . Die Spalte j der Matrix \mathbf{Z}_c beschreibt, wie eine Preisänderung in dem einzelnen Zeitintervall j den Verbrauch in allen andern Zeitintervallen beeinflusst.

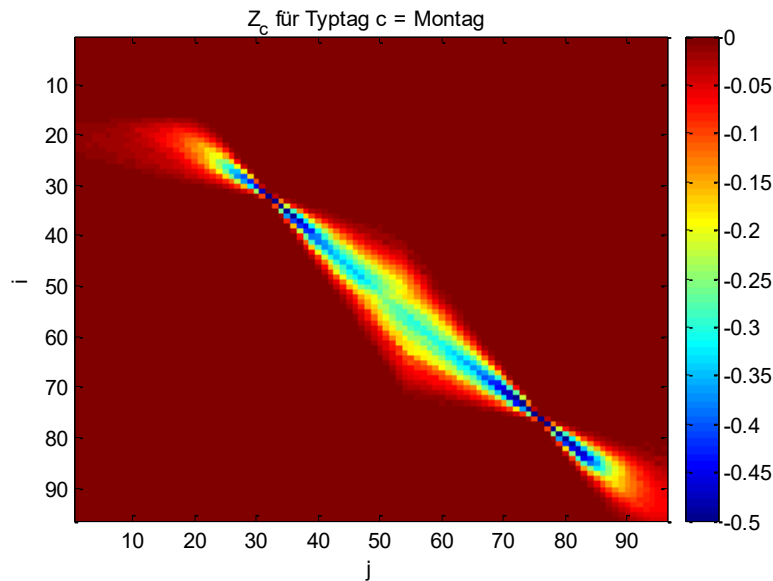


Abbildung 5.1: Beispiel-Heatmap-Darstellung der individuellen Besetzung der Matrix \mathbf{Z}_c für Typtag von $c = \text{Montag}$

Die erzeugten Zeitreihen des synthetischen Datensatzes sind im Bereich 0 und 1 normiert. Die Zeitreihen sind jeweils vollständig und plausibel. Es sind also keine irregulären Werte wie bspw. Ausreißer oder fehlende Werte vorhanden. Die genauen Parametervorgaben für die einzelnen Zeitreihenkomponenten sowie eine Abbildung dieser Parametervorgaben werden im Anhang B beschrieben. Der Nachweis der charakteristischen Eigenschaften wird im Abschnitt 5.3.1 durch eine Zeitreihenanalyse des synthetischen Datensatzes erbracht.

5.1.1.2 Zeitreihengenerator für Energiezeitreihen

Zur Generierung synthetischer Zeitreihen wurde ein Zeitreihengenerator [149] entwickelt. Ziel ist die Generierung realitätsnaher Zeitreihen mit spezifischen Eigenschaften entsprechend der zu untersuchenden Prozessklasse. Die zugrundeliegende Modellierung synthetischer Zeitreihen basiert dabei auf etablierten Modellen der Zeitreihenmodellierung. Basierend auf dem Komponentenmodell (siehe Abschnitt 3.2) werden deterministische und stochastische Zeitreihenkomponenten, eine Musterkomponente und eine exogene Komponente additiv miteinander verknüpft. Zur Identifikation spezifischer charakteristischer Eigenschaften werden die in Tabelle 5.1 aufgeführten Methoden der Zeitreihenanalyse eingesetzt. Entsprechend der zu untersuchenden Prozessklasse werden die zu setzenden Modelle und Modellparameter ausgewählt, die relevanten Eingänge bestimmt und die relevanten Effekte (z.B. Kalendereffekte, saisonale Effekte, Typtage, typische wiederkehrende Rhythmen, stochastische Zeitreiheneigenschaften usw.) bei der Modellierung berücksichtigt.

Die synthetische Gesamtzeitreihe setzt sich aus den in Tabelle 5.1 aufgeführten Elementen zusammen.

Tabelle 5.1: Bei der Modellierung verwendete Zeitreihenkomponenten und deren Ausprägungen (erweitert nach [149])

Zeitreihenkomponente	Beschreibung	Mögliche Ausprägungen
<p>Trendkomponente y_T</p> $y_T[k] = a_0 + \sum_{i=1}^m a_i \cdot [k]^i$ <p>mit: m – Ordnung des Modells a_0, a_i – Modellparameter</p>	<ul style="list-style-type: none"> Beschreibung der Trendkomponente durch Polynomansatz Realisierung durch Polynom der Ordnung m 	<ul style="list-style-type: none"> Linear ($m = 1$) Quadratisch ($m = 2$) Kubisch ($m = 3$)
<p>Periodische Komponente y_P</p> $y_P[k] = \sum_{i=1}^m \left[a_i \cos \left(\omega_i[k] + \frac{\varphi_i}{100\% \cdot 2\pi} \right) \right]$ <p>mit: ω – Kreisfrequenz pro Frequenz a_i – Amplitude pro Frequenzanteil φ – Nullphasenverschiebung pro Frequenzanteil in %</p>	<ul style="list-style-type: none"> Beschreibung der periodischen Komponente durch periodischen Ansatz Realisierung durch Überlagerung von Kosinus-Funktionen Festlegung der entsprechenden Periodendauern durch die Kreisfrequenz Nullphasenverschiebung bei Zeitreihenbeginn wird berücksichtigt 	<ul style="list-style-type: none"> Tageszyklus Wochenzyklus Jahreszyklus
<p>Stochastische Komponente y_S</p> $y_S[k] = \sum_{i=1}^p [a_i \cdot y[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \cdot \varepsilon[k-i]$ <p>mit: ε – weißes Rauschen a_i, b_i – Modellparameter</p>	<ul style="list-style-type: none"> Beschreibung der stochastischen Komponente durch stochastisches Zeitreihenmodell Realisierung mittels ARMA-Prozesses mit Ordnung p, q Realisierung des weißen Rauschens ε über gaußverteilte Pseudozufallszahlen 	<ul style="list-style-type: none"> ARMA-Modellansatz mit maximal 3. Ordnungen ($p \leq 3$ und $q \leq 3$)
<p>Musterkomponente y_M</p>	<ul style="list-style-type: none"> Beschreibung der Musterkomponente durch Standardlastprofildaten [101] Realisierung über Jahreszeitreihen und Berücksichtigung von Sommer, Winter und Übergangszeit und Typtagen 	<ul style="list-style-type: none"> Standardlastprofile (H0, G0 bis G6, L1, L2 des BDEW) Berücksichtigung bundeseinheitlicher Feiertage

Zeitreihenkomponente	Beschreibung	Mögliche Ausprägungen
<p>Exogene Komponente y_R</p> $y_R[k] = \sum_j^{96} \zeta_{i,j,c}[k] \cdot \left(\frac{\Delta p_{j,c}[k]}{p_{ref}[k]} \right) \cdot y_{ref}[k]$ <p>mit: $\zeta_{i,j,c}$ – Kreuzpreiselastizität in Abhängigkeit der Klasse c des Uhrzeitindex und y_{ref} – Referenzverbrauch p_{ref} – Referenzpreis</p>	<ul style="list-style-type: none"> Beschreibung des Einflusses der exogenen Größen Preis p Realisierung über Eigen- und Kreuzpreiselastizität in Matrix Z_c (siehe Abschnitt 3.4.4) Berücksichtigung von Typtagklassen c 	<ul style="list-style-type: none"> Skalierter Preiseinfluss Individuelle Besetzung der Matrix Z_c je Typtag c
Stauchung/ Streckung und Skalierung	<ul style="list-style-type: none"> Stauchung oder Streckung der Gesamtzeitreihe Skalierung auf Jahresenergiewert 	

Mit dem angewendeten Zeitreihengenerator werden synthetische Zeitreihen in normierter Form mit der Zeitreihenlänge $k = 1, \dots, K$ und einer Abtastzeit von 15 Minuten erzeugt. Eine Skalierung der generierten Zeitreihe auf einen entsprechenden Energiewert ist möglich. Die einzelnen Zeitreihenkomponenten gehen gewichtet in die Gesamtzeitreihe ein. Durch die Wichtung wird der Wertebereich der jeweiligen Komponente festgelegt. Mit Hilfe der Stauchung lässt sich die Gesamtzeitreihe zusätzlich in Richtung der Ordinate stauchen und strecken.

5.1.2 Real gemessener Datensatz aus dem „Olympic Peninsula Project“

Um die Praxistauglichkeit des aufgeführten Modellansatzes zu demonstrieren, wird für die Evaluierung zusätzlich ein realer Datensatz herangezogen, welcher der zu untersuchenden Prozessklasse zuzuordnen ist. Bei dem verwendeten Datensatz aus der Feldstudie „Pacific Northwest GridWise Testbed Demonstration“ des Teilprojektes „Olympic Peninsula Project“ [63] wurde das Verbrauchsverhalten von Haushaltsstromkunden bei variablen Stromtarifen von April 2006 bis März 2007 untersucht. Der Datensatz umfasst Verbrauchszeitreihen von 112 Haushalten, die zu gleichen Teilen vier Gruppen zugeordnet wurden. Die Gruppen umfassen dabei jeweils:

- Haushalte einer Kontrollgruppe (CTRL-Gruppe),
- Haushalte mit einem konstanten Stromtarif (FIXED-Gruppe),
- Haushalte, die durch einen TOU-Tarif beeinflusst wurden (TOU-Gruppe) und
- Haushalte, die durch einen RTP-Tarif beeinflusst wurden (RTP-Gruppe).

In einer Datenvorverarbeitung wurden alle Zeitreihen mit mehr als 3% fehlenden Werten identifiziert und für die Untersuchungen der vorliegenden Arbeit nicht berücksichtigt. Für die RTP-Gruppe standen somit 27 Zeitreihen für die Untersuchungen zur Verfügung. Alle Zeitreihen wurden im Rahmen einer Primärdatenaufbereitung behandelt. Es wurden fehlende und irreguläre Werte detektiert und entsprechende Ersatzwerte gebildet, sodass nach der Primärdatenaufbereitung alle Zeitreihen vollständig und plausibel vorlagen. Die 27 Zeitreihen wurden zu einer Gesamtzeitreihe aggregiert. Die aggregierte Zeitreihe wurde zusammen mit der zugehörigen Preiszeitreihe zwischen 0 und 1 normiert und im Rahmen der Evaluierung des aufgeführten Modellansatzes für die Untersuchungen der vorliegenden Arbeit verwendet. Aufgrund der Zusammenstellung der Kunden in der

zugrundeliegenden Feldstudie und der dadurch entstandenen systematischen Ungleichheit der enthaltenen Tarifgruppen liegt nur die preisbeeinflusste Lastzeitreihe $y[k]$ für die Untersuchungen vor. Die Evaluierung des aufgeführten Modellansatzes kann also mit dem realen Datensatz nur für die preisbeeinflusste Lastzeitreihe $y[k]$ vorgenommen werden, da für die Zeitreihenkomponenten $y_U[k]$ und $y_R[k]$ in der Feldstudie keine Messwerte vorliegen. Es können nur die Residuen $e[k]$ (siehe Gleichung (4.17)) ermittelt und ausgewertet werden.

5.2 Validierungsstrategie

Für die Bewertung einer Prognose wird ex post das Ausmaß der Übereinstimmung zwischen prognostizierten und realisierten Werten der betrachteten Variable untersucht. Für die Bewertung der Prognosequalität steht in der Literatur eine Vielzahl von statistischen Verfahren zur Verfügung [102] und [103]. Um die Prognosen miteinander vergleichen und bewerten zu können, werden zunächst entsprechende Kriterien für die Prognosegüte definiert. Diese sollten mindestens folgende Punkte aufgreifen und berücksichtigen:

- Es werden ein oder mehrere Fehlermaße festgelegt (siehe Abschnitt 5.2.2), mit denen die Prognosequalität bestimmt wird. Die festgelegten Fehlermaße sollen dabei den Prognosefehler bezogen auf die Istwerte und in Abhängigkeit des Vorhersagehorizontes bewertet.
- Die Prognosefehler werden auf die Eigenschaften des weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell [45] untersucht (siehe Abschnitt 2.2.1).

Mit Hilfe der verwendeten Beispieldatensätze soll die Leistungsfähigkeit des aufgeführten Modellansatzes evaluiert und demonstriert werden. Dazu werden die für die Untersuchungen verwendeten Datensätze, welche im Abschnitt 5.1 vorgestellt werden, zunächst im Verhältnis 2/3 zu 1/3 in Trainings- und Testdaten eingeteilt. Mit den Trainingsdaten werden die Modellparameter der verwendeten Modelle im Rahmen des Trainings geschätzt. Mit den Testdaten werden die trainierten Modelle für die Prognose sowie die Berechnung der Prognosefehler und die resultierenden Fehlermaße angewendet. Die im Abschnitt 5.3.2 aufgeführten Ergebnisse wurden anhand der Testdaten ermittelt. Die unter Abschnitt 5.2.2 festgelegten Fehlermaße werden jeweils pro Vorhersagehorizont für eine rollierende Prognose mit einem Vorhersagehorizont $H = 1, \dots, 96$ Abtastschritten (ein Tag) im 15 Minuten-Zyklus ermittelt (siehe Abbildung 5.2).




Abbildung 5.2: Rollierende Prognose mit einem Vorhersagehorizont $H = 1, \dots, 96$ Abtastschritten im 15-Minuten-Zyklus

Dabei wird die Prognose zyklisch alle 15 Minuten für jeden Uhrzeitindex neu berechnet. Für die sich zeitlich überschneidenden Prognoseläufe werden jeweils der Prognosefehler berechnet und die einzelnen Prognoseläufe und Fehlerzeitreihen abgespeichert. Die Prognosequalität wird in Abhängigkeit des Vorhersagehorizontes über alle Prognoseläufe mittels verschiedener Fehlermaße dargestellt und ausgewertet. Im Abschnitt 5.2.1 werden die Untersuchungsszenarien vorgestellt, um die benötigte Komplexität des vorgeschlagenen IARIMA-Modellansatzes zu verdeutlichen. Im Abschnitt 5.2.2 werden die Fehlermaße aufgeführt, die für die Ermittlung der Prognosequalität herangezogen werden. Im Abschnitt 5.3.2 wird ein Überblick über die Prognoseergebnisse gegeben, bei dem die Ergebnisse der Untersuchungsszenarien miteinander verglichen werden. In den Abschnitten 5.3.2.1 und 5.3.2.2 werden die Untersuchungen in allen Details dargestellt.

5.2.1 Untersuchungsszenarien

Für die Evaluierung werden verschiedene Untersuchungsszenarien für die Prognose aufgestellt und miteinander verglichen. Die Grundlagen bilden dabei die im Abschnitt 5.1 vorgestellten Beispieldatensätze. Die Tabelle 5.2 fasst hierzu die Untersuchungsszenarien zusammen. Die entwickelten Untersuchungsszenarien ergeben sich dabei jeweils aus verschiedenen Methoden, die auf die im Abschnitt 5.1 skizzierten Beispieldatensätze angewendet werden. Für die Referenzszenarien werden dabei etablierte Methoden der Lastprognose eingesetzt. Für die Testszenarien wurde jeweils das in der vorliegenden Arbeit entwickelte Vorhersagesystem, welches im Abschnitt 4.4 vorgestellt wurde und auf dem IARIMA-Modellansatz basiert, in unterschiedlichen Ausbaustufen bzw. Modellierungsspezifika angewendet.

Referenzszenarien

Zunächst werden Referenzprognosen erstellt, bei denen etablierte Methoden der Lastprognose verwendet werden, um die preisbeeinflusste Lastzeitreihe $y[k]$ zu prognostizieren. Dazu wurde ein ARIMAX-Modell (ARIMA mit exogener Größe) und ein KNN-Modell jeweils mit der Preiszeitreihe $p[k]$ als exogene Eingangsgröße verwendet. Die Modellparameter des ARIMAX-Modells werden mit Hilfe der Methode der kleinsten Fehlerquadrate geschätzt. Das verwendete KNN-Modell ist ein Feed-Forward-Netz mit drei Schichten, linearen Aktivierungsfunktionen in der Ein- und Ausgabeschicht, Tangens-Hyperbolicus-Aktivierungsfunktion in der verdeckten Schicht und einem Backpropagation Trainingsalgorithmus [104]. In den Referenzszenarien wird jeweils das Konzept eines Mehrschrittmodells (siehe Abschnitt 4.3.1) für die Abbildung mehrerer Vorhersagehorizonte verwendet [15]. Dabei wird für jeden Horizont der Vorhersage ein separates Modell eingesetzt, welches parametrisch auf den jeweiligen zu berechnenden Horizont abgestimmt ist.

Testszenarien

Es werden Testszenarien für die Evaluierung definiert. Dabei wird das im Abschnitt 4.4 vorgestellte Vorhersagesystem in verschiedenen Ausbaustufen verwendet, um die benötigte Komplexität des aufgeführten Ansatzes zu demonstrieren. Für die Testszenarien eins und zwei wird das uhrzeitabhängige Mehrschrittmodell als Erweiterung des bei den Referenzszenarien eingesetzten einfachen Mehrschrittmodells angewendet (siehe Abschnitt 4.3.1). Dabei wird nicht nur für jeden Vorhersagehorizont ein separates Modell verwendet, sondern auch für jeden Uhrzeitindex. Das Konzept der globalen und lokalen Prognose beinhaltet für die Testszenarien eins und zwei lokale Phänomene zu jedem Uhrzeitindex. Für Testszenario zwei wird im Vergleich zu Testszenario eins ein weiterer Eingang bei der Modellierung verwendet. Neben dem Preis wird die Preisvarianz als zusätzlicher Input verwendet. Das Testszenario drei umfasst die komplette in den vorherigen Abschnitten

beschriebene Komplexität des Modellansatzes. Das Konzept der uhrzeitabhängigen und klassenbezogenen Mehrschrittmodellierung wird umgesetzt, indem neben der horizontabhängigen Modellierung separate Modelle pro Uhrzeitindex und Klasse verwendet werden. Die Klasseneinteilung des Klassifikationsmoduls wird für das Testszenario drei pro Typtag vorgenommen. Jeder Wochentag entspricht dabei einem zu separierenden Typtag. Feiertage werden dem Sonntag zugeordnet. Die Tabelle 5.2 zeigt die Ausbaustufen der Testszenarien. Den Abbildungen in der Tabelle 5.2 sind die prinzipiellen Eingangsbelegungen der angewendeten Methoden zu entnehmen. Die genauen Modellkonfigurationen werden durch eine Zeitreihenanalyse festgelegt. Die Modellkonfigurationen umfassen jeweils die Modellstruktur bezogen auf die Modellordnung der eingesetzten Modelle sowie die Kalenderkonfiguration. Die Zeitreihenanalyse und die Modellkonfigurationen werden im Abschnitt 5.3.1 vorgestellt. Es ergibt sich die in Tabelle 5.2 zusammengefasste Übersicht.

Tabelle 5.2: In Untersuchungsszenarien angewendete Methoden und Modellierungsspezifika

Szenario	Modellansatz	Modellierungsspezifika des Klassifikationsmoduls	Berücksichtigung der Preisinformation
Referenzszenario 1 	• ARIMAX	• Mehrschrittmodellierung	Eingänge: • $p[k]$
Referenzszenario 2 	• KNN	• Mehrschrittmodellierung	Eingänge: • $p[k]$
Testszenario 1 	• IARIMAX	• Mehrschrittmodellierung • Uhrzeitabhängig	Eingänge: • $p[k]$ • $y_{R,ref}[k]$
Testszenario 2 	• IARIMAX	• Mehrschrittmodellierung • Uhrzeitabhängig	Eingänge: • $p[k]$ • $y_{R,ref}[k]$ • $\sigma_p^2[\Delta k]$
Testszenario 3 	• IARIMAX	• Mehrschrittmodellierung • Uhrzeitabhängig • Klassenbezogen	Eingänge: • $p[k]$ • $y_{R,ref}[k]$ • $\sigma_p^2[\Delta k]$

5.2.2 Fehlermaße und optimale Prognose

Für die Bewertung von Prognosen werden in der vorliegenden Arbeit verschiedene Fehlermaße berechnet, welche je Vorhersagehorizont angegeben werden. Folgende Fehlermaße werden verwendet:

- **Mittlerer Fehler**

$$ME[H] = \frac{1}{N} \cdot \sum_{k=1}^N (\hat{y}[k+H] - y[k+H]) \quad (5.1)$$

Der mittlere Fehler ME gibt die durchschnittliche Abweichung zwischen den prognostizierten Werten $\hat{y}[k]$ und den tatsächlichen Messwerten $y[k]$ an. Der ME beschreibt die globale Über- bzw. Unterschätzung der Messwerte durch die Prognose. Je näher der ME dem Wert Null ist, desto geringer ist der systematische Fehler der Prognose. Ein ME nahe Null zeigt, dass das Modell den Prozess prinzipiell erfasst und der Arbeitspunkt getroffen wurde.

- **Mittlerer quadratischer Fehler**

$$MSE[H] = \frac{1}{N} \cdot \sum_{k=1}^N (\hat{y}[k+H] - y[k+H])^2 \quad (5.2)$$

Durch das Quadrieren der Abweichung wird vermieden, dass sich positive und negative Fehler gegenseitig aufheben und es erfolgt eine überproportionale Gewichtung großer gegenüber kleiner Abweichungen.

- **Standardabweichung des Prognosefehlers**

$$STD[H] = \sqrt{\frac{1}{N-1} \cdot \left(\sum_{k=1}^N \left((\hat{y}[k+H] - y[k+H]) - \sum_{k=1}^N \frac{\hat{y}[k+H] - y[k+H]}{N} \right)^2 \right)} \quad (5.3)$$

Die Standardabweichung des Prognosefehlers ist ein Maß für die Abweichung des Prognosefehlers um seinen Mittelwert. Ein kleinerer Wert bedeutet eine höhere Vorhersagegüte. Die Standardabweichung des Prognosefehlers und der $RMSE$ (Wurzel des mittleren quadratischen Fehlers) weisen aufgrund der jeweiligen Berechnungsvorschriften im Allgemeinen ähnliche Zahlenwerte auf und haben somit eine ähnliche Aussagekraft. Nur wenn der ME deutlich von Null abweicht, dann ergeben sich größeren Änderungen zum $RMSE$.

- **Mittlerer absoluter Fehler**

$$MAE[H] = \frac{1}{N} \cdot \sum_{k=1}^N |\hat{y}[k+H] - y[k+H]| \quad (5.4)$$

Der MAE gibt die durchschnittliche Abweichung zwischen den prognostizierten und den tatsächlichen Messwerten an. Durch die Betrachtung der absoluten Abweichungen wird keine Bewertung vorgenommen, ob eine von Über- oder Unterschätzung vorliegt.

- **Optimale Prognose**

Die Prognosefehler werden auf die Eigenschaften des weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell untersucht [45]. Zur Untersuchung der Prognosefehler auf weißes Rauschen werden die partielle Autokorrelationsfunktion (PAKF) sowie der Periodogrammtest verwendet. Die partielle Autokorrelationsfunktion setzt einen normalverteilten Fehler voraus. Der Periodogrammtest ist ein verteilungsunabhängiger Nullhypothesentest, bei dem eine zweiseitige Prüfung des kumulierten Periodogramms s_r gegenüber einem $(1-\alpha)$ -Quantil vorgenommen wird [45]. Das kumulierte Periodogramm der Länge N ist laut [45] definiert als:

$$s_r = \frac{\sum_{k=1}^r f(\varphi)}{\sum_{k=1}^M f(\varphi)} \quad (5.5)$$

mit: s_r - kumuliertes Periodogramm

$f(\varphi)$ - Funktion der Frequenz φ ,

$M = N/2$ und

$r = 1, 2, \dots, M$.

Ein Periodogramm $f(\varphi)$ ist eine Funktion der Frequenz und beschreibt die Stärke, mit der harmonische Schwingungen der Frequenz φ in einer Zeitreihe vorhanden sind. Die Beschreibung der Funktion $f(\varphi)$ wird in [45] detailliert aufgeführt. Bei einem Prozess, welches weißem Rauschen entspricht, stellt das kumulierte Periodogramm eine Gerade als Winkelhalbierende dar. Bei einer zu prüfenden Zeitreihe wird das kumulierte Periodogramm gegen r/M aufgetragen und schwankt um die Winkelhalbierende. Die Hypothese wird abgelehnt, wenn die Schwankung um die Winkelhalbierende zu groß wird. Die maximale Abweichung wird durch das Toleranzband um die Winkelhalbierende festgelegt, welche durch ein $(1-\alpha)$ -Quantil definiert ist. Das $(1-\alpha)$ -Quantil wird in Abhängigkeit der Irrtumswahrscheinlichkeit α bestimmt. Die Abbildung 5.3 zeigt einen Periodogrammtest am Beispiel eines weißen Rauschens als Prüfgröße. Der Periodogrammtest wird zusätzlich angewendet, da eine Normalverteilung der Prognosefehler nicht nachgewiesen werden kann. Die Überprüfung der optimalen Prognose wird in Abhängigkeit des Vorhersagehorizontes vorgenommen.




Abbildung 5.3: Beispiel für Periodogrammtest für die Realisierung eines weißen Rauschens als Prüfgröße

5.3 Anwendung des Vorhersagesystems für beeinflusste Zeitreihen

5.3.1 Zeitreihenanalyse und Modellkonfiguration

Um die Modellkonfiguration der Methoden der Untersuchungsszenarien durchführen zu können, wird eine Zeitreihenanalyse der in der Datengrundlage aus Abschnitt 5.1 beschriebenen Zeitreihen vorgenommen. Das Ziel der Zeitreihenanalyse ist die Identifikation der charakteristischen Eigenschaften der zugrundeliegenden Zeitreihen. Aus den gewonnenen Erkenntnissen der Zeitreihenanalyse können die Eignung eines Modellansatzes sowie die Modellstruktur als Modellkonfiguration abgeleitet werden. Ein Großteil der eingesetzten Methoden der Zeitreihenanalyse zur Identifikation relevanter Informationen für die Modellbildung wurde im Abschnitt 3.5 detaillierter beschrieben. Es wird der Verarbeitungsworkflow für die Analyse von Lastzeitreihen aus Abbildung 3.4 angewendet. Für die Zeitreihenanalyse wird jeweils der komplette Datensatz herangezogen.

5.3.1.1 Zeitreihenanalyse des synthetischen Datensatzes und Modellkonfiguration

Zeitreihenanalyse

Für einen ersten Eindruck wird die beeinflusste Lastzeitreihe visualisiert. In der Abbildung 5.4 ist der Verlauf von $y[k]$ über zwei Wochen dargestellt. In der Darstellung sind Verbrauchsmuster in Abhängigkeit des Wochentages zu erkennen. Das erste abgebildete Tagesmuster vom 06.10.2014 ist ein Montag. Die Werkzeuge weisen eine ausgeprägte Morgenspitze und eine weniger ausgeprägte Abendspitze auf. Die Samstage und Sonntage unterscheiden sich im Lastniveau und im Verbrauchsmuster signifikant von den Werktagen.




Abbildung 5.4: Verlauf der normierten Lastzeitreihen $y[k]$ des synthetischen Datensatzes über 2 Wochen

Die Abbildung 5.5 zeigt die Autokorrelationsfunktion von $y[k]$ für eine Verschiebung bis zu 700 Tastpunkten. Es sind lokale Maxima bei Vielfachen von 96 zu erkennen. Durch die Abtastzeit von 15 Minuten erklären sich diese Maxima durch einen ausgeprägten Tagesrhythmus. Das Maximum bei einer Verschiebung von 672 (eine Woche), welches höher als das Maximum mit einer Verschiebung von 96 Tastschritten ist, wird auf einen ausgeprägten Wochenrhythmus zurückgeführt. Durch signifikante Korrelation von ca. 0,85 (Verschiebung von 96 Tastpunkten) bzw. 0,96 (Verschiebung von 672 Tastpunkten) ist eine Berücksichtigung von Referenzwerten des Vortages bzw. der Vorwoche als Eingangswerte der Prognosemethode gerechtfertigt.




Abbildung 5.5: Autokorrelationsfunktion der Lastzeitreihen $y[k]$ des synthetischen Datensatzes

Die Abbildung 5.6 zeigt die PAKF für $y[k]$. Die PAKF wird bis zu einer Verschiebung von 10 Tastpunkten dargestellt. Die Korrelation ist bei einer Verschiebung von 1 mit einem Wert von 0,98 sehr hoch und fällt bei Verschiebungen > 1 stark ab. Die Korrelation zu den letzten sieben Vergangenheitswerten liegt bei einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ über der Signifikanzgrenzen.




Abbildung 5.6: Partielle Autokorrelationsfunktion der Lastzeitreihe $y[k]$ des synthetischen Datensatzes

Die Hauptkomponentenanalyse, wie in Abbildung 5.7 abgebildet, ist ein Verfahren zur Merkmalsreduktion, welches die wesentlichen trennenden Eigenschaften der Beobachtungen (Varianz) größtenteils beibehält. Sie dient der Analyse der Abhängigkeitsstruktur, die zwischen den Komponenten eines Zufallsvektors besteht. Es wird eine Merkmalsreduktion des datumsbezogenen Tagesbedarfs als zu untersuchendes Objekt auf zwei Hauptmerkmale als typische und dominierende Tagesbedarfseigenschaften vorgenommen. Im Ergebnis können z.B. unterschiedliche Tagestypen bezüglich des Bedarfs aufgedeckt werden. Die Hauptkomponentenanalyse wird dabei so angewendet, dass eine Ziffer in der Abbildung ein Tagesmuster des Datensatzes repräsentiert. Die schwarzen Ziffern 1 bis 5 stellen jeweils die Werktage (Montag bis Freitag) dar. Die blauen Ziffern 6 bilden Samstage und die roten Ziffern 0 Sonntage ab. Durch die Anordnung der Tagesmuster entsprechend der aufgespannten Hauptachsen lassen sich zusammengehörige Tagesmuster erkennen. Die Werktage separieren sich in ihrer Charakteristik deutlich von den Wochenenden. Auch Samstage und Sonntage lassen sich voneinander separieren. Mit den beiden ersten Hauptkomponenten wird eine Gesamtvarianz von ca. 85% erfasst.




Abbildung 5.7: Hauptkomponentenanalyse der Lastzeitreihe $y[k]$ des synthetischen Datensatzes

Die Abbildung 5.8 zeigt die x-y-Darstellung der Wertepaare von $p[k]$ und $y[k]$. Dadurch, dass die Werte für $p[k]$ in Preisstufen vorkommen, ergeben sich in der Darstellung „Streifen“ parallel zur y-

Achse. Ein funktionaler Zusammenhang zwischen den Wertepaaren ist nicht eindeutig auszumachen. Die Streuung der Wertepaare ist allerdings hoch.




Abbildung 5.8: Punktwolke/x-y-Darstellung von Preis $p[k]$ (x-Achse) der Lastzeitreihe $y[k]$ (y-Achse) des synthetischen Datensatzes

Die Abbildung 5.9 zeigt die Kreuzkorrelationsfunktion zwischen $y[k]$ und $p[k]$. Das globale Maximum der Korrelation liegt mit ca. 0,71 bei einer Verschiebung von 0. Der hohe Korrelationswert lässt sich dadurch erklären, dass hohe Preise vorwiegend zu Hochlastzeiten vorkommen und niedrige Preise eher zu Schwachlastzeiten.




Abbildung 5.9: Kreuzkorrelationsfunktion von Preis $p[k]$ und Lastzeitreihe $y[k]$ des synthetischen Datensatzes

Ein Konfigurationsparameter, der bei der Modellbildung noch bestimmt und vorgegeben werden muss, ist die Fenstergröße Δk bei der Berechnung der Preisvarianz σ_p^2 . Dieser Konfigurationsparameter gibt an, wie viele Werte bei der Berechnung der Varianz in einem gleitenden Fenster einbezogen werden und damit Einfluss auf die beeinflusste Zeitreihenkomponente $y_R[k]$ haben. Dafür zeigt die Abbildung 5.10 auf der y-Achse den Korrelationswert zwischen $\sigma_p^2[\Delta k]$ und $y[k]$. Auf der x-Achse wird die Größe des gleitenden Fensters für die Berechnung der Preisvarianz abgebildet. Das Maximum der Kurve zeigt die optimale Fenstergröße, welche bei der Modellbildung Berücksichtigung findet.




Abbildung 5.10: Bestimmung der optimalen Fenstergröße zur Berechnung der Preisvarianz.

Mit der Verfolgung des Konzeptes der globalen und lokalen Prognose (siehe Abschnitt 4.3) gilt es, im Rahmen der Analysephase eine Klassenkonfiguration zu ermitteln, mit der die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung angewendet wird. Dazu sind lokale Abschnitte der Lastzeitreihe zu identifizieren, die verschiedene Arbeitspunkte mit unterschiedlichen Werteverteilungen aufweisen. Mit der im Abschnitt 3.3 beschriebenen Charakteristik des Verbrauchsverhaltens und der damit resultierenden typischen Charakteristik von Lastzeitreihen ist mit dem Auftreten von Tagesmustern zu rechnen, die in voneinander abweichenden Typtagen unterschieden werden können. Im Rahmen der bisherigen Analysephase konnte dies bestätigt werden. Darüber hinaus ist zu analysieren, welche unterschiedlichen Typtage in der Lastzeitreihe vorkommen. Außerdem ist die vorzugebene Klassenkonfiguration zu bestimmen.

Die Klassenkonfiguration wird mittels eines Kreuzvergleiches der Werteverteilung von Datenbeispielen lokaler Abschnitte der Zeitreihe vorgenommen. Die Abbildung 5.11 fasst die Ergebnisse dieses Kreuzvergleiches zusammen und basiert auf der Analyse, die im Anhang C aufgeführt ist. Dazu wurde die Lastzeitreihe in Datenbeispiele lokaler Abschnitte bezüglich der Typtage und des Uhrzeitindex zerlegt. Es werden die sieben Wochentage als $c = 1 \dots 7$ Typtagklassen unterschieden. Feiertage werden dabei der Klasse Sonntag zugeordnet. Bei der Abtastzeit von 15 Minuten werden jeweils $h = 1 \dots 96$ Uhrzeitindizes unterschieden. Mit der Zerlegung der Verbrauchszeitreihe resultieren $y[k|c = 1 \dots 7, h = 1 \dots 96]$ Datenbeispiele (672 Datenbeispiele mit 96 Uhrzeitindizes je sieben Typtagklassen) als lokale Abschnitte. Mit der Durchführung eines Kreuzvergleiches wird die Verteilung jedes Datenbeispiels mit der Verteilung jedes anderen Datenbeispiels mit Hilfe des KS-Tests verglichen. Die Methode zur Identifikation der Klassenkonfiguration im Rahmen der Analyse wird im Abschnitt 4.3.2 detailliert beschrieben.

Aus der Abbildung 5.11 ist die Klassenkonfiguration zu entnehmen. Weisen beim Vergleich zweier Typtagklassen jeweils alle Datenbeispiele mit jeweils dem gleichen Uhrzeitindex $y_1 = y[k|c = c_1, h = h_1 = h_2]$ und $y_2 = y[k|c = c_2, h = h_1 = h_2]$ eine identische Verteilung auf (Nullhypothese trifft für alle Uhrzeitindizes zu), dann können diese folglich einer Klasse zugeordnet werden und sind in der Abbildung 5.11 durch ein grünes Feld markiert. Sind beim Vergleich zweier Typtagklassen Datenbeispiele mit sich unterscheidender Verteilung für den gleichen Uhrzeitindex auszumachen (Nullhypothese trifft für ein oder mehrere Uhrzeitindizes nicht zu), dann sind diese Typtagklassen zu unterscheiden und werden in der Abbildung 5.11 grau gekennzeichnet. Die Ergebnisse aus Abbildung 5.11 zeigen die Zusammenfassung der Ergebnisse mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$. Für die Abbildung ergibt sich ein an der Hauptdiagonalen

gespiegeltes symmetrisches Bild. Bei genauerer Betrachtung des Kreuzvergleichs der einzelnen Uhrzeitindizes untereinander (siehe Anhang C) sind nicht bei allen Vergleichen der Werktage untereinander durchgängig identische Verteilungen je Uhrzeitindex auszumachen. Ein Zusammenfassen aller Werktage in eine Klasse ist daher nicht uneingeschränkt sinnvoll. Beim Vergleich der Werktage untereinander haben nur die Typtage Dienstag und Mittwoch durchgehend für alle Uhrzeitindizes eine identische Verteilung. Beim Vergleich der anderen Werktage untereinander kommen mehrfach Uhrzeitindizes vor, die keine identische Verteilung aufweisen. Beim Vergleich der Samstags- und Sonntagklasse mit den Werktagen und auch beim Vergleich von Samstagen und Sonntagen sind kaum Uhrzeitindizes mit identischer Verteilung auszumachen. Nur wenn die Nullhypothese für alle Uhrzeitindizes zutrifft, ist in Abbildung 5.11 ein entsprechendes grünes Kästchen beim Kreuzvergleich aufgeführt. Die Ergebnisse des Kreuzvergleiches aus Abbildung 5.11 lassen sich auf die Musterkomponente der beeinflussten Zeitreihe des synthetischen Datensatzes zurückführen. Die Musterkomponente basiert auf einem Mix verschiedener Standardlastprofile (siehe Anhang B). Die resultierende Musterkomponente weist für jeden Typtag ein unterschiedliches Lastprofil auf. Die größten Unterschiede sind zwischen den Werktagen und den Wochenenden auszumachen. Mit Ausnahme der Profile der Typtage Dienstag und Mittwoch sind auch leichte Unterschiede unter den Werktagen zu erkennen. Die Profile der Typtage Dienstag und Mittwoch sind allerdings nahezu identisch. Die mit dem Kreuzvergleich aus Abbildung 5.11 ermittelten Ergebnisse passen also zu der beeinflussten Zeitreihe des synthetischen Datensatzes.

Zusätzlich kommen bei der detaillierteren Untersuchung (siehe Anhang C) auch Konstellationen beim Kreuzvergleich vor, bei denen die Nullhypothese für unterschiedlichen Klassen und unterschiedliche Uhrzeitindizes zutrifft ($c_1 \neq c_2$ und/oder $h_1 \neq h_2$). Es ist also denkbar, Datenbeispiele unterschiedlicher Typtagklassen mit unterschiedlichen Uhrzeitindizes einer Klasse zuzuordnen, was eine Reduzierung der Parameteranzahl bei der Modellierung zur Folge hätte. Die Zulässigkeit dieser Zuordnung ist allerdings zu prüfen und wird im Rahmen der vorliegenden Arbeit nicht weiter untersucht.

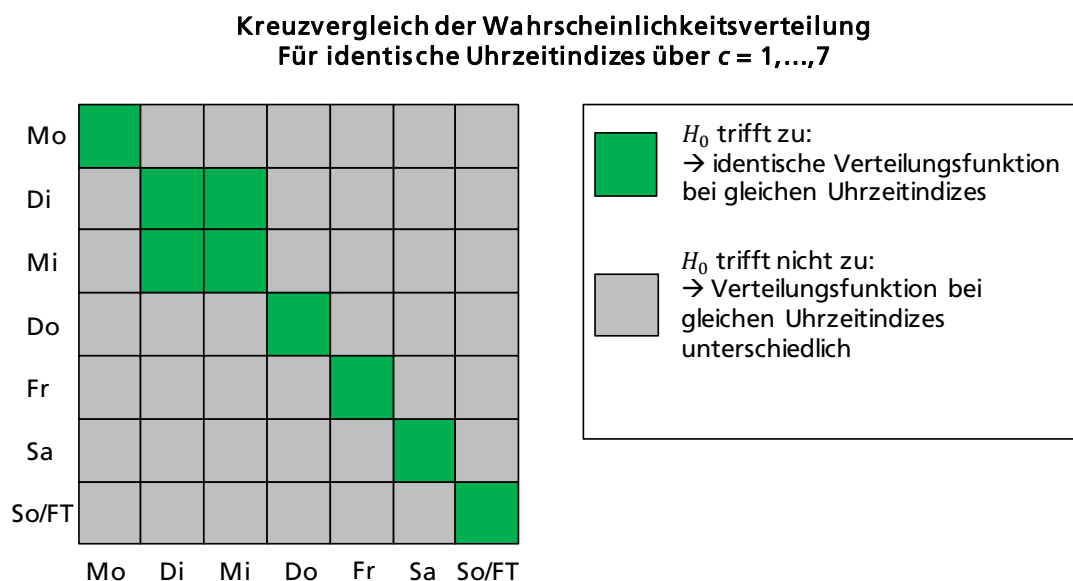


Abbildung 5.11: Zusammenfassung des Kreuzvergleichs der Verteilungen aus Anhang C für die Ermittlung der Klassenzuordnung

Um die Parameteranzahl bei der Modellierung zu reduzieren, wird zusätzlich die Möglichkeit in Betracht gezogen, Datenbeispiele mit benachbarten Uhrzeitindizes in Blöcken zusammenzufassen. Dazu werden die Datenbeispiele derselben Stunde zusammengefasst, was die Parameteranzahl bei der Modellierung um den Faktor 4 verringern würde. Allerdings geht aus der Analyse aus Anhang C hervor, dass in den meisten Fällen nicht alle Datenbeispiele benachbarter Uhrzeitindizes eine identische Verteilung besitzen. Bei einer Zusammenfassung in Stundenblöcke würden somit Datenbeispiele mit unterschiedlicher Verteilung durch ein Modell repräsentiert werden. Folglich ist mit einer Verschlechterung der Prognosequalität zu rechnen. Eine Zusammenfassung von Datenbeispielen benachbarter Uhrzeitindizes wird daher verworfen.

Modellkonfiguration

Aus den gewonnenen Erkenntnissen wird die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung folgendermaßen angewendet:

Aufgrund der nicht durchgängig identischen Werteverteilungen beim Vergleich der Werktage untereinander von Datenbeispielen mit dem gleichen Uhrzeitindex wird jeder Wochentag einer separaten Klasse zugeordnet. Es entstehen somit sieben Typtagklassen. Eine Zusammenfassung von Datenbeispielen mit verschiedenen Uhrzeitindizes wird ausgeschlossen. Grundsätzlich besteht damit die Möglichkeit, die Parameteranzahl bei der Modellierung zu verringern. Erkauft würde sich dieser Vorteil aber mit einem erhöhten Aufwand bei der Datenvorverarbeitung, um die zusammengehörigen Datenbeispiele in einer Klasse bei der Modellierung automatisiert zusammenzufassen, wobei eine Verbesserung der Prognosequalität mit dieser Maßnahme nicht zu erwarten ist. Außerdem wäre ein erheblich größerer Aufwand bei der Fehleranalyse die Folge. Eine Zusammenfassung von Datenbeispielen in Blöcken (z.B. Stundenblöcke) wird ebenfalls ausgeschlossen. Die Verringerung der Parameteranzahl bei der Modellierung würde mit einer Verschlechterung der Prognosequalität einhergehen.

Für den Entwurf des Prognosemodells sind die Ergebnisse der durchgeführten Zeitreihenanalyse auszuwerten und die Erkenntnisse bei der Modellierung zu berücksichtigen. Der verwendete IARIMA-Modellansatz beinhaltet musterbasierte Differenzenfilter, der zur Filterung musterbasierter Zeitreihenanteile dient. Mit der Erweiterung der Differenzenbildung um den Backshift-Operator τ wird eine Beschreibung periodischer Zeitreihenanteile möglich. Als zusätzliche Eingangsgröße wird der Referenzwert als Repräsentant des identifizierten Referenzverbrauchs als Teil des Vorhersagesystems mit Linearisierungskomponente (siehe Abbildung 4.11) eingesetzt. Zur Identifikation der nötigen Konfigurationsparameter des Backshift-Operators τ und des verwendeten Referenzwertes sind die Ergebnisse der Autokorrelationsfunktion und der Hauptkomponentenanalyse zu berücksichtigen. Die Autokorrelationsfunktion ergab den größten mittleren linearen Zusammenhang mit einer Korrelation von 0,96 zum Vorwochenwert. Die Korrelation ist wesentlich größer und damit signifikant gegenüber dem kritischen Korrelationskoeffizienten, der für einen Freiheitsgrad größer 1000 und eine Irrtumswahrscheinlichkeit von 0,1% einen Wert von 0,104 annimmt. Die Verwendung des Referenzwertes für die Vorwoche ist damit gerechtfertigt. Die Hauptkomponentenanalyse zeigt eine Unterteilung in Werktage, Samstage und Sonntage. Durch die Erkenntnisse der Autokorrelationsfunktion und der Hauptkomponentenanalyse wird ein datumsbasiertes Regelwerk für die Kalenderkonfiguration zur Ermittlung der Referenzwerte und den Backshift-Operators τ eingeführt. Die mathematische Umsetzung bei der Modellbildung erfolgt mit dem Differenzenfilter 1. Ordnung (Konfigurationsparameter $p = 1$) zur Eliminierung eines linearen Trends und dessen Erweiterung mittels eines datumsbasierten Regelwerks laut [15] aus Gleichung (5.6).

Die Ermittlung des Referenzwertes erfolgt analog mittels Gleichung (5.7). Die in Gleichung (5.7) aufgeführten typtagabhängigen und datumsbasierten Regeln für die Verschiebung des Backshift-Operators τ beschreiben die Kalenderkonfiguration des Gesamtmodells, die sich im Rahmen der Analyse des synthetischen Datensatzes folgendermaßen ergibt:

$$\nabla_{\tau} y[k] = y[k] - y[k - \tau] \quad (5.6)$$

$$y[k - \tau] = y_{ref}[k] \quad (5.7)$$

$$\text{mit: } \tau = \begin{cases} 96 \text{ für } Typtag = \text{Dienstag, Mittwoch, Donnerstag, Freitag} \\ 672 \text{ für } Typtag = \text{Montag, Samstag, Sonntag} \\ 96 \cdot k_d \text{ für } Typtag = \text{Feiertag und nicht Sonntag} \end{cases},$$

k_d - Tagesindex beginnend mit Sonntag = 0,

$y_{ref}[k]$ - Referenzwert von $y[k]$.

Die Ordnung des Konfigurationsparameters für den AR-Anteil p ergibt sich mit der Auswertung der partiellen Autokorrelationsfunktion. Für Vorhersagehorizonte $H \leq 4$ wird der Konfigurationsparameter $p = 4$ und für $H > 4$ mit $p = 1$ festgelegt. Zur Minimierung des Modellfehlers wird ein MA-Anteil bei der Modellbildung berücksichtigt. Der Konfigurationsparameter für die Ordnung des MA-Anteils wird auf $q = 1$ festgelegt.

Der Konfigurationsparameter Δk für die Fenstergröße für die Berechnung der Preisvarianz wird mit der Auswertung der Abbildung 5.10 ermittelt. Der optimale Wert für die Fenstergröße Δk ergibt sich durch das Maximum der abgebildeten Kurve mit einem Wert von 22, was einem Fenster von 5,5 Stunden entspricht.

5.3.1.2 Zeitreihenanalyse des real gemessenen Datensatzes aus dem „Olympic Peninsula Project“ und Modellkonfiguration

Zeitreihenanalyse

Für einen ersten Eindruck wird die beeinflusste Lastzeitreihe visualisiert. Die Abbildung 5.12 zeigt den Verlauf von $y[k]$ über zwei Wochen. In der Darstellung sind Verbrauchsmuster in Tageslänge zu erkennen. Allerdings sind konkrete Typtage wie beispielsweise Werktage oder Wochenenden auf den ersten Blick nicht zu unterscheiden. Die Tagesprofile weisen ausgeprägte Muster auf. Es sind jeweils eine Morgenspitze und eine ausgeprägte Abendspitze zu erkennen. Die Ausprägungen der Morgen- und Abendspitze und damit die Verbrauchsmuster variieren allerdings stark im abgebildeten Zeitraum. Unterschiedliche Lastniveaus in Abhängigkeit des Typtages sind nicht zu erkennen.




Abbildung 5.12: Verlauf der normierten Lastzeitreihe $y[k]$ des real gemessenen Datensatzes über 2 Wochen

Die Abbildung 5.13 zeigt die Autokorrelationsfunktion von $y[k]$ für eine Verschiebung bis zu 700 Tastpunkten. Es sind lokale Maxima bei Vielfachen von 96 zu erkennen. Durch die Abtastzeit von 15 Minuten erklären sich diese Maxima durch einen ausgeprägten Tagesrhythmus. Die Autokorrelationsfunktion fällt mit ansteigender Verschiebung kontinuierlich ab. Ein ausgeprägter Wochenrhythmus kann nicht identifiziert werden. Durch signifikante Korrelation von ca. 0,88 (Verschiebung von 96 Tastpunkten) ist eine Berücksichtigung von Referenzwerten des Vortages gerechtfertigt.




Abbildung 5.13: Autokorrelationsfunktion der Lastzeitreihe $y[k]$ des real gemessenen Datensatzes

Die Abbildung 5.14 zeigt die PAKF von $y[k]$. Die PAKF wird bis zu einer Verschiebung von 10 Tastpunkten dargestellt und hat den größten Wert mit einer Korrelation von 0,96 bei einer Verschiebung von 1. Bei einer Verschiebung > 1 fällt die PAKF stark ab. Die Korrelation zu den letzten drei Vergangenheitswerten liegt bei einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ über der Signifikanzgrenze.




Abbildung 5.14: Partielle Autokorrelationsfunktion der Lastzeitreihe $y[k]$ des real gemessenen Datensatzes

In der Hauptkomponentenanalyse aus Abbildung 5.15 werden Werktage durch die schwarzen Ziffern 1 bis 5, Samstage durch die blauen Ziffern 6 und Sonntage durch die roten Ziffern 0 repräsentiert. Durch die Anordnung der Tagesmuster entsprechend der aufgespannten Hauptachsen lassen sich keine Tagestypen voneinander separieren. Es kann angenommen werden, dass Typtage nicht anhand ihrer Verbrauchscharakteristik unterschieden werden können. Die durch die 1. und 2. Hauptachse erfasste Gesamtvarianz beträgt ca. 87%.




Abbildung 5.15: Hauptkomponentenanalyse der Lastzeitreihe $y[k]$ des real gemessenen Datensatzes

Die Abbildung 5.16 zeigt die x-y-Darstellung der Wertepaare von $p[k]$ und $y[k]$. Ein funktionaler Zusammenhang zwischen den Wertepaaren ist anhand der x-y-Darstellung nicht eindeutig auszumachen. Die Streuung der Wertepaare ist hoch.




Abbildung 5.16: Punktwolke/x-y-Darstellung von Preis $p[k]$ (x-Achse) der Lastzeitreihe $y[k]$ (y-Achse) des real gemessenen Datensatzes

Die Abbildung 5.17 zeigt die Kreuzkorrelationsfunktion zwischen $y[k]$ und $p[k]$. Das globale Maximum der Korrelation liegt bei einer Verschiebung von drei Tastpunkten. Mit einem Korrelationswert von ca. 0,375 liegt ein mittlerer bis niedriger linearer Zusammenhang vor.




Abbildung 5.17: Kreuzkorrelationsfunktion von Preis $p[k]$ und Lastzeitreihe $y[k]$ des real gemessenen Datensatzes

Die optimale Fenstergröße Δk für die Berechnung der Preisvarianz ergibt sich durch das Maximum der aufgeführten Kurve in Abbildung 5.18 und hat einen Wert von 18, was einem Fenster von 4,5 Stunden entspricht.




Abbildung 5.18: Bestimmung der optimalen Fenstergröße zur Berechnung der Preisvarianz.

Zur Ermittlung einer geeigneten Klassenkonfiguration für die Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung bei der Prognose wird auf die detaillierte Analyse aus Anhang C zurückgegriffen. In dieser Analyse wurde die Lastzeitreihe analog zur Analyse des synthetischen Datensatzes (siehe Abbildung 5.11 und deren Erläuterungen) in Datenbeispiele lokaler Abschnitte bezüglich der Typtage und des Uhrzeitindex zerlegt, bei denen die sieben Wochentage als Typtagklassen unterschieden werden. Analog zu den Untersuchungen des synthetischen Datensatzes resultieren 672 Datenbeispiele ($96 \text{ Uhrzeitindizes} \times 7 \text{ Typtagklassen}$) als lokale Abschnitte, bei denen die Verteilung untereinander mit Hilfe des KS-Tests verglichen wird. Der Test wird beim jeweiligen Kreuzvergleich der Werteverteilungen der Datenbeispiele jeweils mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ und $\alpha = 1\%$ angewendet. Die Abbildung 5.19 zeigt die Zusammenfassung der Ergebnisse der Analyse aus Anhang C mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$, aus der die Klassenkonfiguration entnommen werden kann. Weisen beim Kreuzvergleich zweier Typtagklassen jeweils alle Datenbeispiele mit dem gleichen Uhrzeitindex $y_1 = y[k|c = c_1, h = h_1 = h_2]$ und $y_2 = y[k|c = c_2, h = h_1 = h_2]$ eine identische Verteilung auf, dann trifft die Nullhypothese für alle Uhrzeitindizes zu (siehe Abschnitt 4.3.2). Folglich können diese einer Klasse zugeordnet werden, und in Abbildung 5.19 wird das entsprechenden Feld grün markiert. Bei einer grauen Kennzeichnung sind beim Vergleich zweier Typtagklassen Datenbeispiele mit sich unterscheidender Verteilung für den gleichen Uhrzeitindex auszumachen und die Nullhypothese trifft für ein oder mehrere Uhrzeitindizes nicht zu. In Abbildung 5.19 ergibt sich ein an der Hauptdiagonalen gespiegeltes symmetrisches Bild. Für den Vergleich der Werktage untereinander ergibt die Analyse, dass die Datenbeispiele jeweils mit dem gleichen Uhrzeitindex für alle Werktage eine identische Verteilung aufweisen. Eine Unterscheidung verschiedener Werktage in separate Typtagklassen wird daher ausgeschlossen und alle Werktage einer Klasse zugeordnet. Beim Vergleich der Werktage mit den Wochenenden sind allerdings bei allen Vergleichen Uhrzeitindizes zu finden, die Datenbeispiele mit verschiedener Verteilung besitzen. Auch beim Vergleich zwischen den Klassen Samstag und Sonntag sind Datenbeispiele mit verschiedener Verteilung zu finden.




Abbildung 5.19: Ermittlung der Klassenzuordnung für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung in Abhängigkeit von Typtagen und Uhrzeitindex $h = 1 \dots 96$ (15 Minutenwerte)

Analog zum synthetischen Datensatz werden bei der detaillierteren Untersuchung (siehe Anhang C) Stundenblöcke für eine mögliche Parameterreduktion zusammengefasst. Es ist allerdings zu erkennen, dass in den meisten Fällen nicht alle Datenbeispiele benachbarter Uhrzeitindizes eine identische Verteilung besitzen. Analog zur Argumentation beim synthetischen Datensatz aus Abschnitt 5.3.1.1 wird die Zusammenfassung in Stundenblöcke verworfen.

Modellkonfiguration

Die klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung wird aufgrund der gewonnenen Erkenntnisse folgendermaßen angewendet:

Aufgrund der durchgängig identischen Werteverteilungen in Bezug auf gleiche Uhrzeitindizes beim Vergleich der Werktage untereinander werden alle Werktage einer Klasse zugeordnet. Eine Zusammenfassung von Datenbeispielen mit verschiedenen Uhrzeitindizes ist prinzipiell möglich, wird aber aufgrund des nötigen Aufwandes für die individuelle Datenvorverarbeitung und Fehleranalyse im Rahmen der Modellierung verworfen, da auch eine Verbesserung der Prognosegüte nicht erwartet werden kann. Samstage und Sonntage werden jeweils einer separaten Klasse zugeordnet, sodass insgesamt drei Typtagklassen unterschieden werden. Eine Zusammenfassung von Datenbeispielen in Blöcken (z.B. Stundenblöcke) wird ausgeschlossen.

Die Auswertung der Ergebnisse der durchgeführten Zeitreihenanalyse werden bei der Modellierung berücksichtigt. Aus den Erkenntnissen der Autokorrelationsfunktion und der Hauptkomponentenanalyse lässt sich die Kalenderkonfiguration für die Ermittlung der Referenzwerte und des Backshift-Operators τ ableiten. Die Autokorrelationsfunktion ergibt den größten mittleren linearen Zusammenhang mit einer Korrelation von 0,96 zum Vortageswert. Die Korrelation ist gegenüber dem kritischen Korrelationskoeffizienten, der für einen Freiheitsgrad größer 1000 und eine Irrtumswahrscheinlichkeit von 0,1% einen Wert von 0,104 annimmt, signifikant und rechtfertigt die Verwendung des Referenzwertes für den Vortageswert. Die mathematische Umsetzung bei der Modellbildung erfolgt mit dem Differenzenfilter 1. Ordnung (Konfigurationsparameter $p = 1$) und

dessen Erweiterung mittels eines datumsbasierten Regelwerks aus Gleichung (5.6). Die Ermittlung des Referenzwertes erfolgt mittels Gleichung (5.8). Die in Gleichung (5.8) aufgeführten typtagabhängigen und datumsbasierten Regeln für die Verschiebung des Backshift-Operators τ beschreibt die Kalenderkonfiguration des Gesamtmodells, die im Rahmen der Analyse des real gemessenen Datensatzes ermittelt wurde:

$$y[k - \tau] = y_{ref}[k] \quad (5.8)$$

mit: $\tau = 96$

für *Typtag* = Montag, Dienstag, Mittwoch, Donnerstag, Freitag, Samstag, Sonntag und Feiertag und

$y_{ref}[k]$ - Referenzwert von $y[k]$.

Mit der Auswertung der partiellen Autokorrelationsfunktion, wird die Ordnung des Konfigurationsparameters für den AR-Anteil für Vorhersagehorizonte $H \geq 4$ mit $p = 3$ und $H < 4$ mit $p = 1$ festgelegt. Zur Minimierung des Modellfehlers wird ein MA-Anteil bei der Modellbildung berücksichtigt. Der Konfigurationsparameter für die Ordnung des MA-Anteils wird mit $q = 1$ vorgegeben. Mit der Auswertung der Abbildung 5.18 ergibt sich der Konfigurationsparameter mit einem Wert von $\Delta k = 18$.

5.3.2 Ergebnisse

Die Bewertung des aufgeführten Modellansatzes für preisbeeinflusste Zeitreihen erfolgt anhand simulativer Untersuchungen für die in Tabelle 5.2 festgelegten Szenarien. Dabei wird die im Abschnitt 5.2 beschriebene Validierungsstrategie angewendet, bei der eine rollierende Day-ahead-Prognose im 15-Minuten-Zyklus berechnet wird. Die für die simulativen Untersuchungen verwendeten Daten werden im Abschnitt 5.1 beschrieben. Eine detaillierte Auswertung der simulativen Untersuchungen wird in den Abschnitten 5.3.2.1 und 5.3.2.2 aufgeführt. Für die Auswertungen werden die im Abschnitt 5.2.2 beschriebenen Fehlermaße berechnet. Die aufgeführten Ergebnisse wurden auf Grundlage der Testdaten ermittelt.

5.3.2.1 Synthetischer Datensatz

Referenzszenarien

Für eine objektive Bewertung der Prognoseergebnisse werden für die Referenzszenarien die gleichen Auswertungen durchgeführt wie für die Testszenarien. Die berechneten Fehlermaße werden in Tabelle 5.3 aufgeführt. Die Abbildung 5.20 zeigt exemplarisch die mittleren Tageskurven für die Prognosewerte (blaue Kurve) und Istwerte (schwarze Kurve) für $y[k]$ für die Referenzszenarien 1 und 2. Dabei ist zu erkennen, dass bei der Approximation des Verlaufs von $y[k]$ jeweils durch das ARIMA- und KNN-Modell (Referenzszenario 1 und 2) eine hohe Übereinstimmung vorliegt.




Abbildung 5.20: Vergleich der mittleren Tageskurven von $y[k]$, $\hat{y}[k]$ sowie $p[k]$ für Referenzszenarien über Testdaten.

Für eine genauere Fehlerdarstellung und -interpretation wird die $STD[H]$ der Fehlerzeitreihe in Abbildung 5.21 in Abhängigkeit des Vorhersagehorizontes $H = 1, \dots, 96$ dargestellt. Durch den ermittelten $ME[H]$ ist zu erkennen, dass das ARIMA- und das KNN-Modell die tatsächlichen Istwerte im Mittel leicht überschätzen. Die ersten Horizonte weisen aufgrund der Relevanz der AR-Anteile eine höhere Prognosegüte auf. Die Standardabweichung des Prognosefehlers für den ersten Horizont $H = 1$ liegt beim ARIMA-Modell bei 0,036 und beim KNN-Modell bei 0,0357. Abbildung 5.22 zeigt die Verteilung der Prognosefehler für das ARIMA- und das KNN-Modell für verschiedene Vorhersagehorizonte in Form von Histogrammen. Zusätzlich zu dem jeweils abgebildeten Vorhersagehorizont ist die Standardabweichung des Prognosefehlers aufgeführt. Bei kleineren Vorhersagehorizonten ist die Verteilung deutlich schmäler und die Standardabweichung somit geringer. Bei größeren Vorhersagehorizonten ab ca. $H = 8$ ist die Breite der Verteilung (und somit auch die Standardabweichung) nahezu konstant.




Abbildung 5.21: Standardabweichung von $e[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für Referenzszenarien über Testdaten

Für eine weitere Auswertung der Prognoseergebnisse werden im Rahmen des Verarbeitungsworkflows aus Abbildung 3.5 die Prognosefehler auf die Eigenschaften des weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell untersucht (siehe Abschnitt 5.2.2 – Optimale Prognose). Dabei kommen PAKF sowie der Periodogrammtest mit einer Irrtumswahrschein-

lichkeit $\alpha = 5\%$ zur Anwendung. Die Abbildung 5.23 zeigt für die Referenzszenarien jeweils die PAKF und den Periodogrammtest für den Vorhersagehorizont $H = 1$. Es ist zu erkennen, dass das Konfidenzintervall in beiden Tests verletzt wird. Das Kriterium für ein optimales Vorhersagemodell ist daher nicht erfüllt.

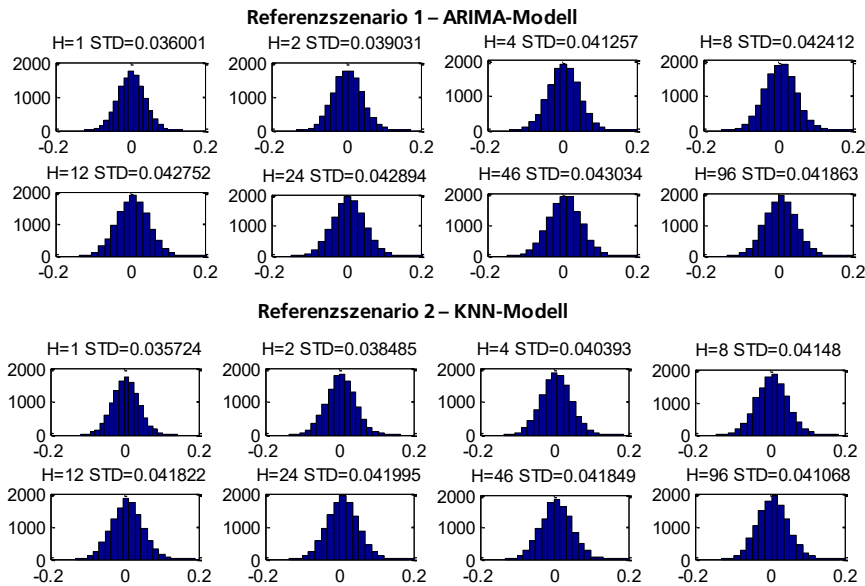


Abbildung 5.22: Histogramm von $e[k]$ für verschiedene Vorhersagehorizonte H für Referenzszenarien über Testdaten

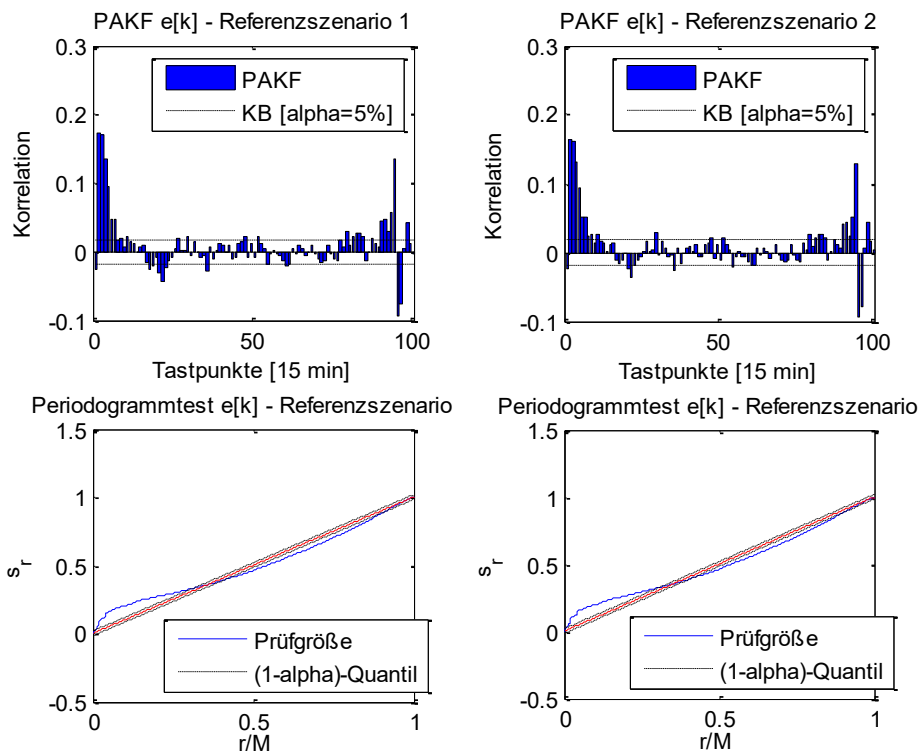


Abbildung 5.23: Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest von $e[k]$ für $H = 1$ für Referenzszenarien über Testdaten

Für die Referenzszenarien 1 und 2 sind die Prognoseergebnisse sehr ähnlich. Der Verlauf der Istwerte kann durch das jeweils verwendete Modell gut approximiert werden. Die Prognosegüte des KNN-Modells ist allerdings etwas größer als die des ARIMA-Modells. Die Eigenschaften des Prognosefehlers sind nahezu identisch. Die Istwerte werden durch das jeweilige Prognosemodell leicht überschätzt. Bei den Untersuchungen des Prognosefehlers auf die Eigenschaften des weißen Rauschens wurde festgestellt, dass für beide Referenzprognosen durch eine geringfügige Verletzung des Kriteriums der optimalen Prognose kein optimales Vorhersagesystem vorliegt.

Testszzenarien

Mit den Testszenarien 1 bis 3 wird mit Hilfe synthetischer Zeitreihen (siehe Abschnitt 5.1) das neue im Abschnitt 4.4 vorgestellte Vorhersagesystem evaluiert. Es werden jeweils Fehlermaße für $y[k]$ und die beiden Zeitreihenkomponenten $y_U[k]$ und $y_R[k]$ berechnet und in Tabelle 5.3 und Tabelle 5.4 aufgeführt. In Abbildung 5.24 werden der mittlere Tagesverlauf der unbeeinflussten Zeitreihenkomponente $y_U[k]$ sowie deren Prognose $\hat{y}_U[k]$ im Vergleich zur beeinflussten Lastzeitreihe $y[k]$ und der Preiszeitreihe $p[k]$ dargestellt. Dabei sind die Lastverschiebungen der beeinflussten Lastzeitreihe (schwarze Kurve) im Vergleich zur unbeeinflussten Komponente (rote Kurve) in Abhängigkeit des Preises zu erkennen. Zwischen dem Verlauf von $y_U[k]$ und der mit Hilfe des Modells erstellten Prognose $\hat{y}_U[k]$ liegt für alle drei Testszenarien eine hohe Übereinstimmung vor. Die geringsten Abweichungen sind augenscheinlich beim Testszenario 3 zu erkennen.

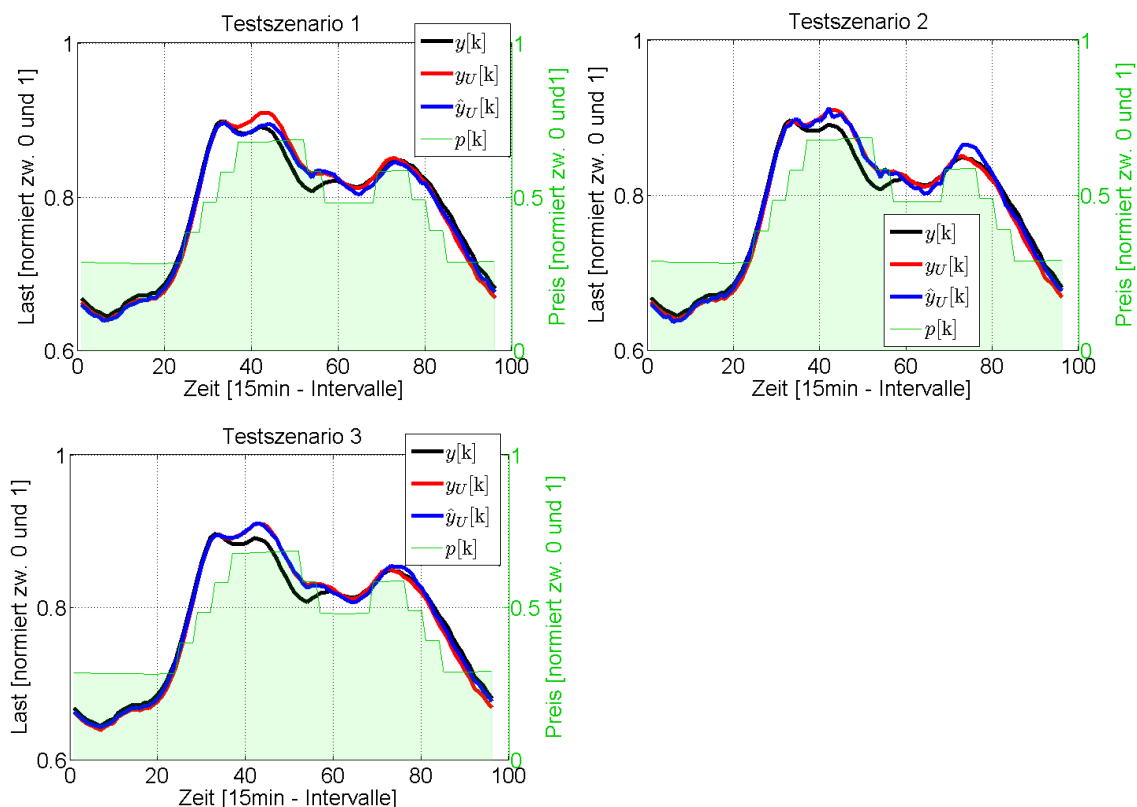


Abbildung 5.24: Vergleich der mittleren Tageskurven von $y_U[k]$, $\hat{y}_U[k]$, und $y[k]$ sowie $p[k]$ für Testszenarien über Testdaten

Die Abbildung 5.25 zeigt den mittleren Tagesverlauf der unbeeinflussten Zeitreihenkomponente $y_R[k]$ sowie deren Prognose $\hat{y}_R[k]$ und der Preiszeitreihe $p[k]$. Zwischen dem Verlauf von $y_R[k]$ und der Prognose $\hat{y}_R[k]$ liegt für alle drei Testszenarien ebenfalls eine hohe Übereinstimmung vor. Der Verlauf von $y_R[k]$ wird im Testszenario 3 erkennbar am besten approximiert. Zu den Niedrigpreiszeiten zwischen $h = 0, \dots, 24$ und $h = 85, \dots, 96$ sind generell positive Werte für $y_R[k]$ (Lastanstieg in $y[k]$) zu erkennen und in den Hochpreiszeiten vorwiegend negative Werte (Lastabsenkung in $y[k]$).

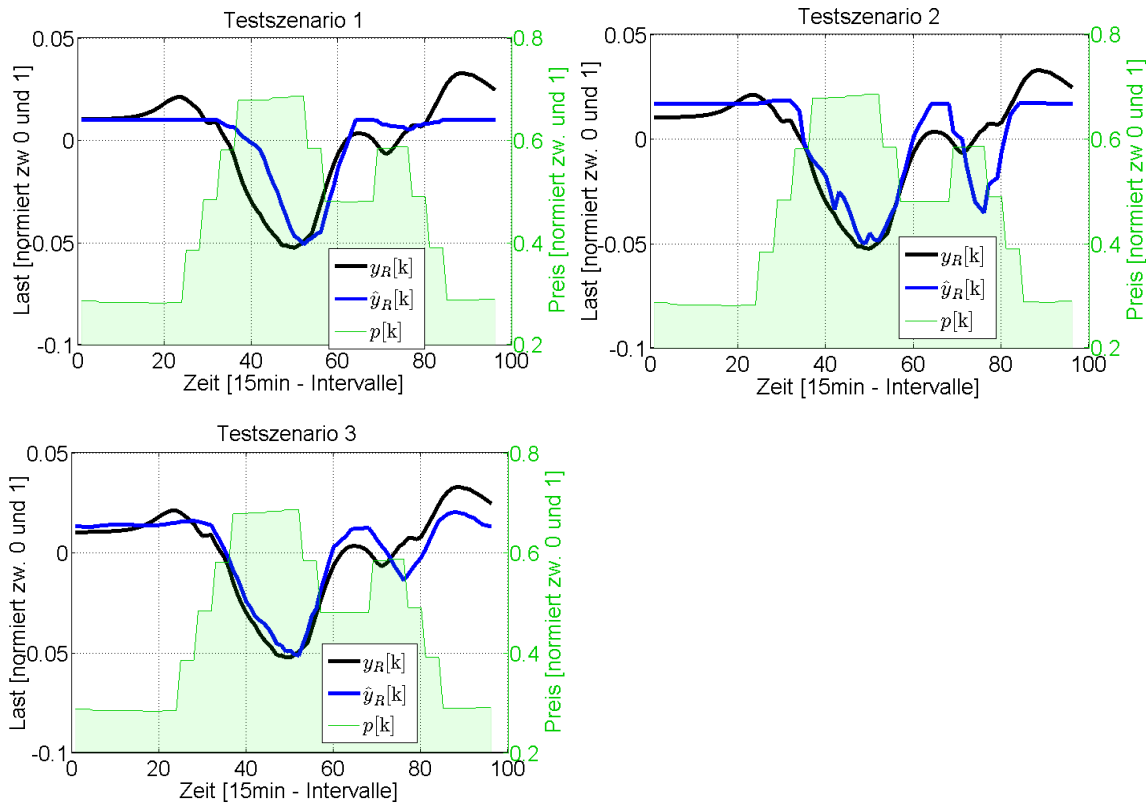


Abbildung 5.25: Vergleich der mittleren Tageskurven von $y_R[k]$, $\hat{y}_R[k]$ sowie $p[k]$ für Testszenarien über Testdaten

Die Abbildung 5.26 zeigt die Standardabweichung des Prognosefehlers $e[k]$ in Abhängigkeit des Vorhersagehorizontes für die Testszenarien 1 bis 3. Im Mittel über alle Vorhersagehorizonte ist die Standardabweichung für Testszenario 3 am geringsten. Für Testszenario 3 liegt dementsprechend die höchste Prognosegüte vor. Für kleinere Vorhersagehorizonte liegen für die Testszenarien 2 und 3 die Ergebnisse sehr nahe beieinander. Erst ab einem Vorhersagehorizont von ca. $H = 6$ wird der Vorteil der Modellierung im Testszenario 3 deutlich. Die Abbildung 5.27 zeigt dazu die Verteilung des Prognosefehlers $e[k]$ für verschiedene Vorhersagehorizonte in Form von Histogrammen für die drei Testszenarien. Zusätzlich zu dem jeweils abgebildeten Vorhersagehorizont ist die Standardabweichung des Prognosefehlers aufgeführt.




Abbildung 5.26: Standardabweichung von $e[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für die Testszenarien über Testdaten

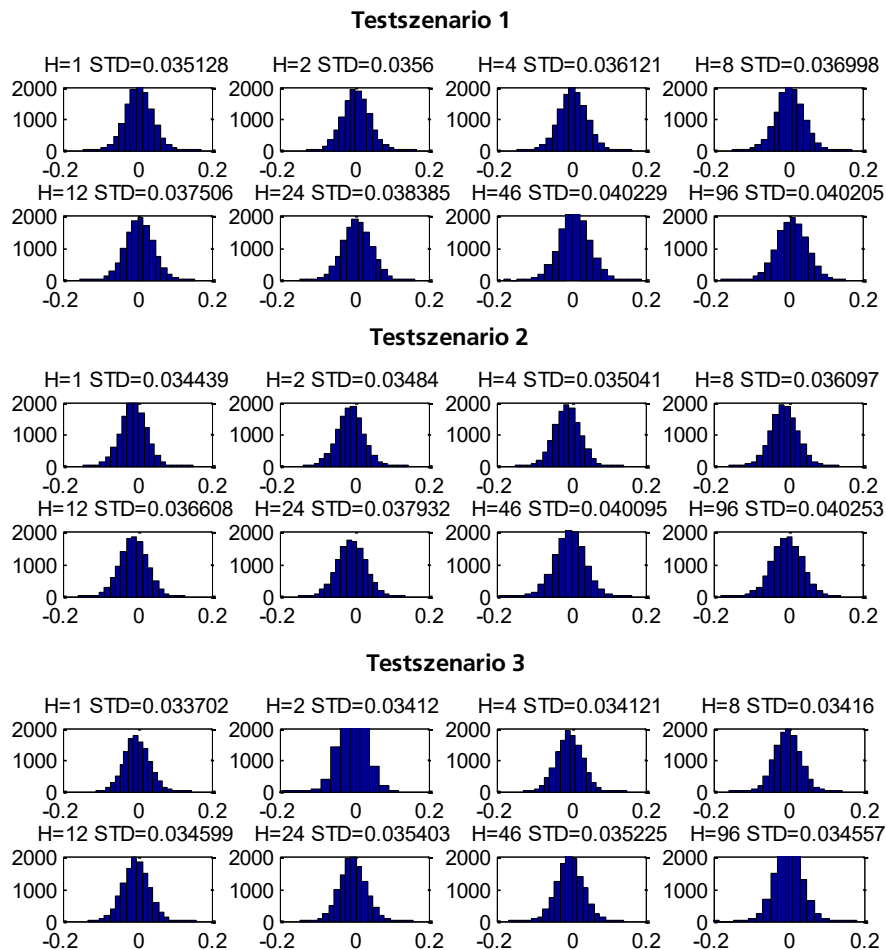


Abbildung 5.27: Histogramme von $e[k]$ für verschiedene Vorhersagehorizonte H für die Testszenarien über Testdaten

In Abbildung 5.28 und Abbildung 5.29 ist die Standardabweichung der Prognosefehler $e_U[k]$ und $e_R[k]$ für die Testszenarien in Abhängigkeit des Vorhersagehorizontes abgebildet. Die besten Er-

gebnisse sind im Mittel für das Testszenario 3 auszumachen. Jedoch variieren die Werte des aufgeführten Fehlermaßes und damit die Verteilung des Fehlers jeweils für $e_U[k]$ und $e_R[k]$ stark. Im Mittel kann aber ein moderater Anstieg des Prognosefehlers mit ansteigendem Vorhersagehorizont angenommen werden.




Abbildung 5.28: Standardabweichung von $e_U[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für die Testszenarien über Testdaten




Abbildung 5.29: Standardabweichung von $e_R[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für die Testszenarien über Testdaten

Für eine weitere Auswertung der Prognoseergebnisse werden die Prognosefehler $e[k]$ auf die Eigenschaften des weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell untersucht. Die Abbildung 5.30 zeigt die PAKF sowie den Periodogrammtest zur Überprüfung der Prognosefehler auf die Eigenschaften von weißem Rauschen für die Testszenarien 1 bis 3. Bei der Darstellung der PAKF von $e[k]$ ist zusätzlich das Konfidenzintervall des kritischen Korrelationskoeffizienten in Abhängigkeit des Freiheitsgrads und einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ abgebildet. Für den Periodogrammtest, der als verteilungsunabhängiger Nullhypothesentest eine zweiseitige Prüfung des kumulierten Periodogramms gegenüber einem $(1-\alpha)$ -Quantil vornimmt, wird der Bereich für das $(1-\alpha)$ -Quantil für eine Irrtumswahrscheinlichkeit von $\alpha = 5\%$ dar-

gestellt. In der Abbildung 5.30 wird dabei den Nachweis für eine optimale Prognose für den Vorhersagehorizont $H = 1$ vorgestellt.

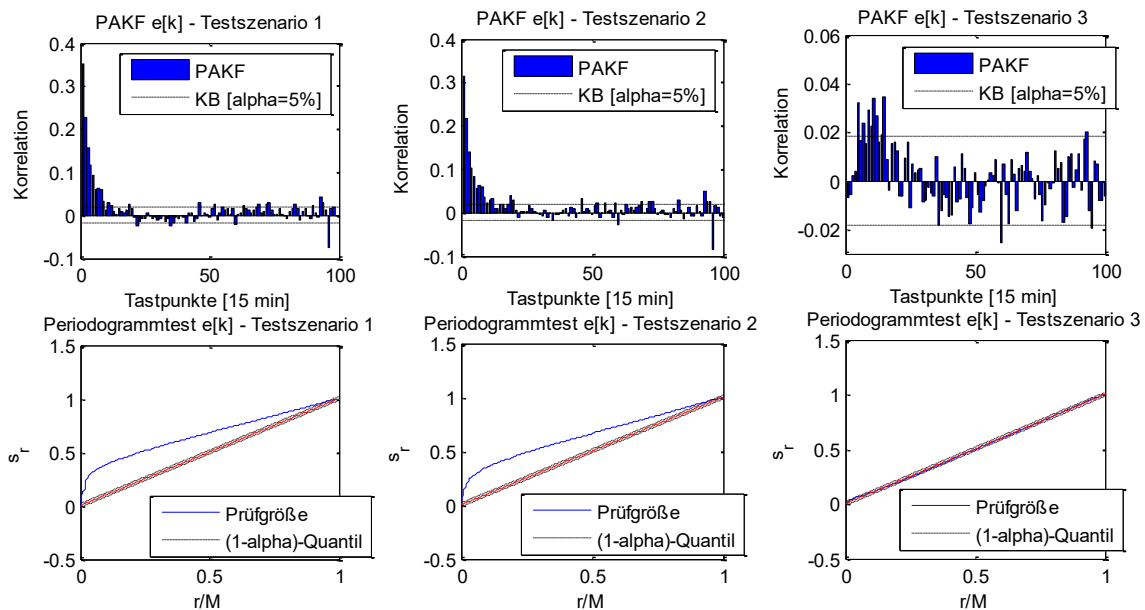


Abbildung 5.30: Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest von $e[k]$ für Vorhersagehorizont $H = 1$ für Testszenarien über Testdaten

Für die Testszenarien 1 und 2 sind deutliche Verletzungen des Konfidenzintervalls bei der PAKF und dem Periodogrammtest zu erkennen. Die Hypothese auf weißes Rauschen für die Testszenarien 1 und 2 wird somit abgelehnt. Für das Testszenario 3 lässt die PAKF vermuten, dass die Residuen dem weißen Rauschen entsprechen. Es sind nur geringfügige Verletzungen des Konfidenzintervalls zu erkennen. Die Überprüfung mittels Periodogrammtest lässt keine signifikanten Verletzungen des $(1-\alpha)$ -Quantils erkennen. Folglich kann für Testszenario 3 die Hypothese auf weißes Rauschen und damit auf eine optimale Prognose für den Vorhersagehorizont $H = 1$ angenommen werden.

Vergleich von Referenz und Testszenarien

Die Tabelle 5.3 zeigt die berechneten Fehlermaße im Mittel über alle rollierenden Prognoseläufe und alle Vorhersagehorizonte pro Berechnungsszenario für $e[k]$ für den synthetischen Datensatz. Dabei werden die Fehlermaße für jeden Prognoselauf über die kompletten Testdaten berechnet und über alle Prognoseläufe gemittelt. Der *ME* zeigt durchgängig mit niedrigen Werten nahe Null für alle Berechnungsszenarien, dass die eingesetzten Modelle jeweils den Prozess erfasst haben und der Arbeitspunkt prinzipiell getroffen wurde. Systematische Fehler sind sehr klein und können als zufällig für alle Berechnungsszenarien angenommen werden. Für den synthetischen Datensatz zeigt das Testszenario 3 den kleinsten Absolutwert des *ME*. Die Fehlermaße *STD*, *MAE* und *MSE* zeigen für die Auswertung ein ähnliches Verhalten. Die Testszenarien weisen alle eine bessere Prognosequalität als die Referenzszenarien auf. Beim Vergleich der Referenzszenarien sind bei den Künstlichen Neuronalen Netz Vorteile gegenüber dem ARIMA Modellansatz zu erkennen. Die verschiedenen Ausbaustufen des IARIMA-Modells aus den Testszenarien 1 bis 3 weisen beim synthetischen Datensatz signifikante Vorteile im Hinblick auf die Prognosequalität auf. Schon bei der Ausbaustufe von Testszenario 1 ist ein deutlicher Gewinn der Prognosequalität gegenüber den Referenzszenarien zu erkennen.

renzszenarien zu erkennen. Die höchste Prognosequalität wurde bei der Ausbaustufe aus Testszenario 3 erzielt und rechtfertigt damit die vorgeschlagenen Erweiterungen des Modellansatzes.

Tabelle 5.3: Fehlermaße für $e[k]$ des synthetischen Datensatzes für Untersuchungsszenarien über Testdaten

Datensatz	Methode	<i>ME</i>	<i>STD</i>	<i>MAE</i>	<i>MSE</i>
Synthetischer Datensatz	Referenzszenario 1 – ARIMA	0,0074	0,0427	0,0345	0,0019
	Referenzszenario 2 – KNN	0,0076	0,0419	0,0338	0,0018
	Testszenario 1 – IARIMA	0,0082	0,0397	0,0321	0,0016
	Testszenario 2 – IARIMA	-0,0053	0,0394	0,0316	0,0016
	Testszenario 3 – IARIMA	-0,0027	0,0351	0,0279	0,0012

Die Ergebnisse werden für den synthetischen Datensatz in Abbildung 5.31 visualisiert und zeigen die durchschnittlichen Fehlermaße *STD*, *MAE* und *MSE* des Prognosefehlers $e[k]$ je Untersuchungsszenario.




Abbildung 5.31: Durchschnittliche Fehlermaße für $e[k]$ des synthetischen Datensatzes für Untersuchungsszenarien über Testdaten

Die Tabelle 5.4 fasst die Ergebnisse für den synthetischen Datensatz in Form der berechneten Fehlermaße im Mittel über alle rollierenden Prognoseläufe und alle Vorhersagehorizonte pro Berechnungsszenario für $e_U[k]$ und $e_R[k]$ zusammen. Dabei können aufgrund der Aufgabenstellung und der Funktionsweise der in den Referenzszenarien zum Einsatz kommenden Methoden nur die Testszenarien ausgewertet werden. Der *ME* mit niedrigen Werten nahe Null demonstriert, dass der Arbeitspunkt prinzipiell jeweils getroffen wird. Die beiden Teilprozesse für die unbeeinflusste und beeinflusste Verbrauchskomponente werden durch das angewendete Modell erfasst. Die systematischen Fehler sind klein und können als zufällig für alle Berechnungsszenarien angenommen werden. Die Auswertung der Fehlermaße *STD*, *MAE* und *MSE* zeigen einen deutlichen Qualitätsge-

winn der Prognose entsprechend der höheren Ausbaustufe. Die beste Prognosequalität wird mit der Ausbaustufe von Testszenario 3 erzielt.

Tabelle 5.4: Fehlermaße für Untersuchungsszenarien für $e_U[k]$ und $e_R[k]$ über Testdaten

Methode	Zeitreihenkomponente	ME	STD	MAE	MSE
Testszenario 1 – IARI-MA	$y_U[k]$	0,0082	0,0432	0,0347	0,0020
	$y_R[k]$	0,0000	0,0408	0,0316	0,0018
Testszenario 2 – IARI-MA	$y_U[k]$	-0,0053	0,0419	0,0335	0,0018
	$y_R[k]$	0,0000	0,0374	0,0298	0,0016
Testszenario 3 – IARI-MA	$y_U[k]$	-0,0027	0,0376	0,0299	0,0014
	$y_R[k]$	0,0000	0,0329	0,0258	0,0011

Die Abbildung 5.32 zeigt die Auswertung der Fehlermaße *STD*, *MAE* und *MSE* der Prognosefehler $e_U[k]$ und $e_R[k]$ für die Untersuchungsszenarien und visualisiert die Ergebnisse der Tabelle 5.4 für den synthetischen Datensatz.




Abbildung 5.32: Durchschnittliche Fehlermaße für $e_U[k]$ und $e_R[k]$ für die Testszenarien (synthetischer Datensatz) über Testdaten

Für eine detaillierte Auswertung wird in der Abbildung 5.33 die Prognosequalität mittels Standardabweichung des Prognosefehlers $e[k]$ (*STD*) für jeden Vorhersagehorizont abgebildet. Die Standardabweichung des Prognosefehlers *STD* als statistische Kenngröße eignet sich prinzipiell als Aussage über die Prognosequalität und sollte im Sinne einer hohen Prognosequalität möglichst klein sein. Die Abbildung 5.33 enthält die Ergebnisse für die Referenz- und Testszenarien für den synthetischen Datensatz. Für die Referenzszenarien fällt die Prognosegüte mit dem Anstieg der *STD* nach wenigen Vorhersagehorizonten stark ab. Für kleinere Vorhersagehorizonte sind die Modelle der Referenzszenarien wesentlich genauer als für größere Vorhersagehorizonte. Mit Hilfe der partiellen Autokorrelationsfunktion wurde eine hohe Korrelation benachbarter Zeitreihenwerte der

Zeitreihen $y[k]$ identifiziert. Die Modellierung als autoregressives Modell nutzt diesen Zusammenhang aus. Für kleine Vorhersagehorizonte, bei denen die Korrelation zu den verfügbaren Vorwerten hoch ist, spiegelt sich dieses Verhalten in der Prognosegüte wider. Mit zunehmendem Vorhersagehorizont sinkt der funktionale Zusammenhang zu den letzten verfügbaren Istwerten. Gleichzeitig steigt der Prognosefehler an und strebt letztlich gegen die Prozessvarianz [45].

Für die Testszenarien ergibt sich eine andere Entwicklung der Prognosequalität in Abhängigkeit des Vorhersagehorizontes. Es ist zu erkennen, dass für den synthetischen Datensatz für die drei Testszenarien die Werte für STD für alle Vorhersagehorizonte deutlich unterhalb der Referenzszenarien liegen. Das Verhalten der Referenzszenarien mit deutlich besserer Prognosegüte bei kleinen Vorhersagehorizonten ist bei den Testszenarien nicht in so ausgeprägtem Maße zu erkennen. Im Testszenario 3 ist nur ein moderater Anstieg der STD mit steigendem Vorhersagehorizont auszumachen. Die Erklärung liegt in der Struktur des IARIMA-Modellansatzes. Der IARIMA-Modellansatz verwendet im Gegensatz zu den autoregressiven Modellierungsansätzen der Referenzszenarien nicht die AR-Anteile der durch das Gesamtmodell vorherzusagenden Größe $y[k]$ sondern die AR-Anteile der abgeleiteten Zeitreihenkomponente $y_v[k]$. Der Vorteil für kleine Vorhersagehorizonte, die sich durch den autoregressiven Modellansatz ergeben, ist beim IARIMA-Modellansatz nicht direkt gegeben. Testszenario 2 weist im Vergleich zu Testszenario 3 leichte Vorteile bezüglich der Prognosequalität auf. Für Testszenario 3 erweist sich die Modellierung als vorteilhaft und erzielt die beste Prognosegüte.




Abbildung 5.33: Standardabweichung für $e[k]$ in Abhängigkeit von $H = 1, \dots, 96$ für Referenz- und Testszenarien (synthetischer Datensatz) über Testdaten

5.3.2.2 Real gemessener Datensatz aus “Olympic Peninsula Project”

Für die Bewertung der Prognoseergebnisse für den real gemessenen Datensatz werden für die Referenzprognosen die gleichen Auswertungen durchgeführt wie für das Testszenario. Für den real gemessenen Datensatz wird im Gegensatz zum synthetischen Datensatz nur das Testszenario 3 mit der höchsten Ausbaustufe zur Evaluierung eingesetzt. Die berechneten Fehlermaße werden in Tabelle 5.5 aufgeführt. Die Abbildung 5.34 zeigt exemplarisch die mittleren Tageskurven der Referenz-

renzszenarien und des Testszenarios für $y[k]$. Die Verläufe der Prognosewerte (blaue Kurve) und der Istwerte (schwarze Kurve) zeigen dabei, dass $y[k]$ durch das ARIMA-, das KNN- und das IA-RIMA-Modell jeweils mit einer hohen Übereinstimmung approximiert wird.

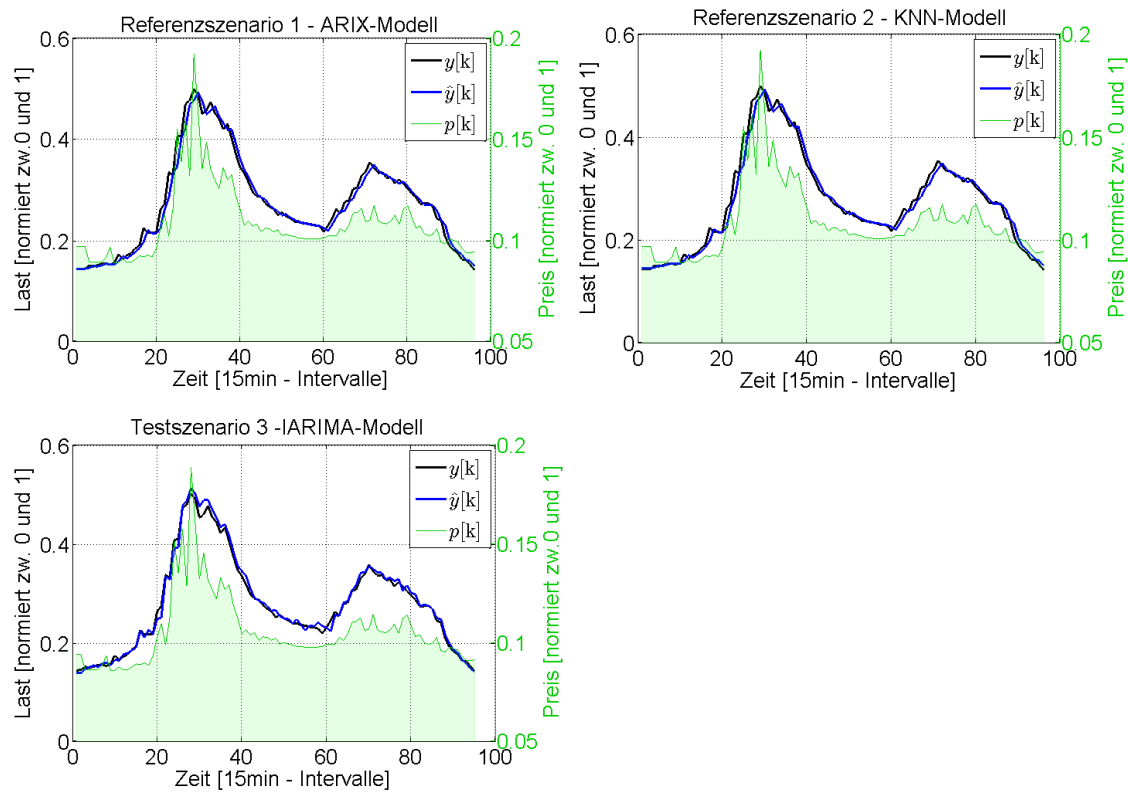


Abbildung 5.34: Vergleich der mittleren Tageskurven von $y[k]$, $\hat{y}[k]$ sowie $p[k]$ für Referenzszenarien und das Testszenario über Testdaten

Die Abbildung 5.35 zeigt den mittleren Tagesverlauf der Prognose der unbeflussten Zeitreihenkomponente $\hat{y}_R[k]$ und der Preiszeitreihe $p[k]$. Istwerte für $y_R[k]$ sind aufgrund der Nichtverfügbarkeit nicht aufgeführt. Dementsprechend kann keine Aussage über die Qualität der Funktionsapproximation für unbeflusste oder beeinflusste Zeitreihenkomponente vorgenommen werden.




Abbildung 5.35: Verlauf der mittleren Tageskurve von $\hat{y}_R[k]$ sowie $p[k]$ für das Testszenario über Testdaten

Die Abbildung 5.36 bildet die Verteilung der Prognosefehler für das ARIMA-, das KNN- und das IARIMA Modell für verschiedene Vorhersagehorizonte in Form von Histogrammen ab. Zusätzlich zu dem jeweils abgebildeten Vorhersagehorizont ist die Standardabweichung des Prognosefehlers aufgeführt. Bei kleineren Vorhersagehorizonten zeigen die Verteilungen bei allen Szenarien eine deutlich kleinere Standardabweichung. Bei größeren Vorhersagehorizonten ab ca. $H = 12$ steigt die Standardabweichung nur noch marginal an. Zwischen den Referenzszenarien sind die Verteilungen des Prognosefehlers je Horizont sehr ähnlich. Ein deutlicher Vorteil einer der beiden Methoden der Referenzszenarien ist bezüglich der Prognosegenauigkeit nicht auszumachen. Beim Testszenario verzeichnet die Verteilung durchweg kleinere Standardabweichungen des Prognosefehlers je Vorhersagehorizont. Das Testszenario zeigt bezüglich der Prognosegenauigkeit demnach einen deutlichen Vorteil gegenüber den Referenzszenarien.

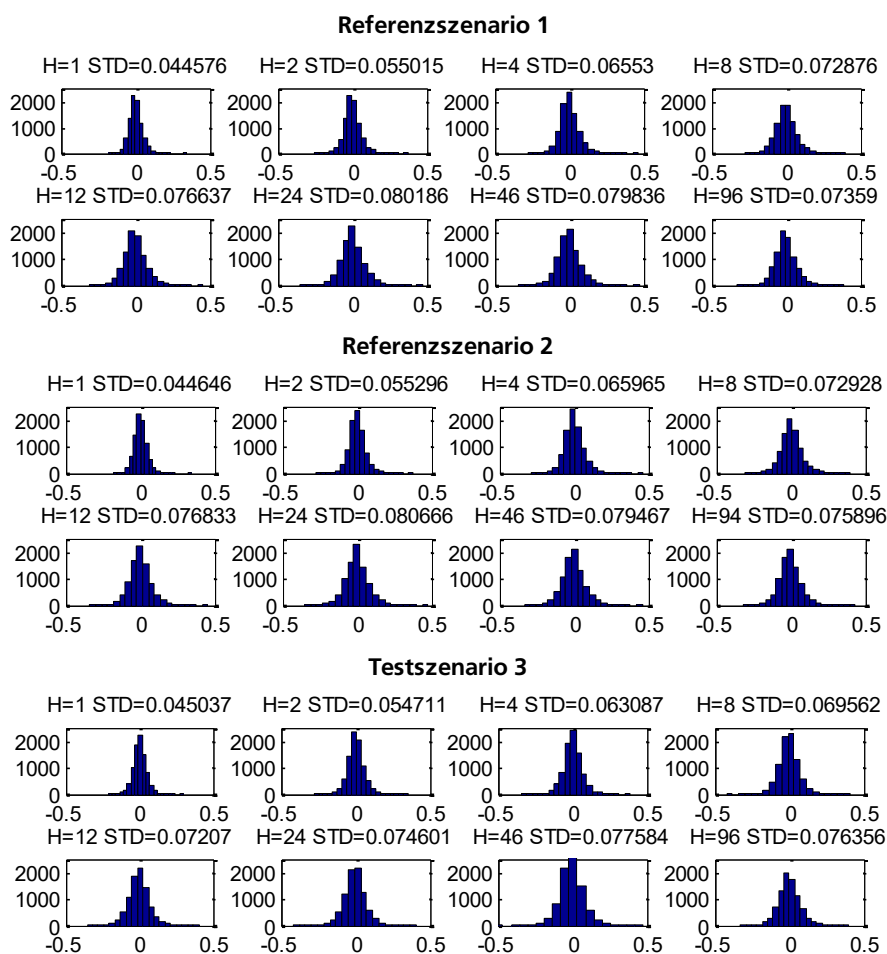


Abbildung 5.36: Histogramme von $e[k]$ für verschiedene Vorhersagehorizonte H für Referenzszenarien und das Testszenario über Testdaten

Für eine weitere Auswertung der Prognoseergebnisse werden die Prognosefehler auf die Eigenschaften des weißen Rauschens als hinreichendes Kriterium für ein optimales Vorhersagemodell untersucht. Dabei kommen PAKF sowie der Periodogrammtest mit einer Irrtumswahrscheinlichkeit $\alpha = 5\%$ zur Anwendung. Die Abbildung 5.37 zeigt für die Untersuchungsszenarien jeweils die PAKF und den Periodogrammtest für den Vorhersagehorizont $H = 1$. Es ist zu erkennen, dass das Konfidenzintervall für beide Referenzszenarien verletzt wird, und das Kriterium für ein optimales

Vorhersagemodell daher nicht erfüllt ist. Für die beiden Referenzszenarien sind die Verletzungen des Konfidenzintervalls allerdings sehr gering, was auf eine bereits sehr gute Erfassung des Verbrauchsverhaltens durch die angewendeten Modelle schließen lässt. Beim Testszenario 3 sind bei der PAKF nur geringe Verletzungen des Konfidenzintervalls zu beobachten. Der Periodogrammtest zeigt allerdings keine signifikanten Verletzungen des $(1-\alpha)$ -Quantils. Für das Testszenario 3 kann die Hypothese auf weißes Rauschen und damit auf eine optimale Prognose folglich für den Vorhersagehorizont $H = 1$ angenommen werden.

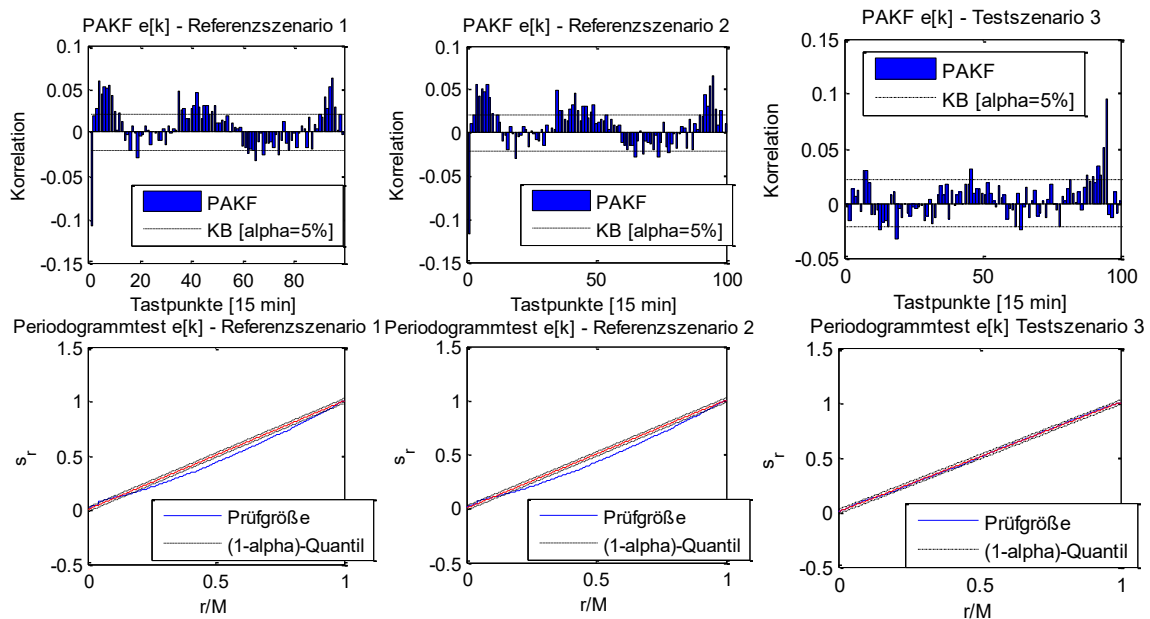



Abbildung 5.37: Partielle Autokorrelationsfunktion (PAKF) und Periodogrammtest für $e[k]$ für Vorhersagehorizont $H = 1$ für Testszenarien über Testdaten

Die Tabelle 5.5 zeigt die berechneten Fehlermaße im Mittel über alle rollierenden Prognoseläufe und alle Vorhersagehorizonte pro Berechnungsszenario für $e[k]$ für den real gemessenen Datensatz. Dabei werden die Fehlermaße für jeden Prognoselauf über die kompletten Testdaten berechnet und über alle Prognoseläufe gemittelt. Der ME zeigt durchgängig mit niedrigen Werten nahe Null für alle Berechnungsszenarien, dass die eingesetzten Modelle jeweils den Prozess erfassen und der Arbeitspunkt prinzipiell getroffen wurde. Systematische Fehler sind sehr klein und können als zufällig für alle Berechnungsszenarien angenommen werden. Für den real gemessenen Datensatz zeigt das Referenzszenario 1 den kleinsten Absolutwert des ME . Die Fehlermaße STD , MAE und MSE belegen für die Auswertung ein ähnliches Verhalten. Das Testszenario 3 weist eine bessere Prognosequalität als die Referenzszenarien auf. Beim Vergleich der Referenzszenarien lässt der Modellansatz der Künstlichen Neuronen Netze keine Vorteile bezüglich der Prognosegenauigkeit gegenüber dem ARIMA Modellansatz erkennen. Die Ausbaustufe des IARIMA-Modells aus Testszenario 3 weist signifikante Vorteile bei der Prognosequalität auf und rechtfertigt damit den vorgeschlagenen Modellansatz und dessen Ausbaustufe.

Tabelle 5.5: Fehlermaße für Untersuchungsszenarien für $e[k]$ für den real gemessenen Datensatz über Testdaten

Datensatz	Methode	ME	STD	MAE	MSE
Real gemessener Datensatz	Referenzszenario 1 – ARIMA	-0,0013	0,0786	0,0589	0,0062
	Referenzszenario 2 – KNN	-0,0024	0,0792	0,0594	0,0063
	Testszenario 3 – IARIMA	-0,0033	0,0751	0,0561	0,0057

Die Ergebnisse werden in Abbildung 5.38 für den real gemessenen Datensatz visualisiert und zeigen die durchschnittlichen Fehlermaße STD , MAE und MSE des Prognosefehlers $e[k]$ je Untersuchungsszenario.

**Abbildung 5.38:** Durchschnittliche Fehlermaße für $e[k]$ für Referenzszenarien und Testszenario für den real gemessenen Datensatz über Testdaten

Für eine detaillierte Auswertung wird in Abbildung 5.39 die Prognosequalität mittels Standardabweichung des Prognosefehlers $e[k]$ für jeden Vorhersagehorizont abgebildet. Die Standardabweichung des Prognosefehlers STD sollte analog zu Abbildung 5.33 im Sinne einer hohen Prognosequalität möglichst klein sein. Die Abbildung 5.39 enthält die Ergebnisse für die Referenz- und das Testszenario für den real gemessenen Datensatz. Für alle Untersuchungsszenarien steigt die STD nach wenigen Vorhersagehorizonten stark an. Für kleinere Vorhersagehorizonte ist demnach die Prognosegenauigkeit deutlich höher. Wie bei den Untersuchungen des synthetischen Datensatzes aus Abschnitt 5.3.2.1 ist der Grund bei der Ausnutzung der autoregressiven Anteile der Zeitreihen zu finden. Es gelten die gleichen Aussagen und Erläuterungen wie zu Abbildung 5.33. Die Unterschiede zwischen den beiden Referenzszenarien sind nur gering. Das IARIMA-Modell des Testszenarios 3 zeigt im Durchschnitt über alle Vorhersagehorizonte deutlich niedrigere Werte für die Standardabweichung des Prognosefehlers und damit bessere Prognosequalität im Vergleich zu den Referenzszenarien. Für die Vorhersagehorizonte 1 bis 3 sind allerdings kaum Unterschiede bei der

Prognosequalität auszumachen. Die Stärke des angewendeten IARIMA-Modellansatzes kommt erst bei der Betrachtung aller Vorhersagehorizonte zum Tragen.




Abbildung 5.39: Standardabweichung für $e[k]$ in Abhängigkeit des Vorhersagehorizontes $H = 1, \dots, 96$ für Referenzszenarien und Testszenario (real gemessener Datensatz) über Testdaten

5.4 Zusammenfassung und wichtigste Erkenntnisse

Im Abschnitt 5 wird das im Abschnitt 4.4 vorgeschlagene neuartige Vorhersagesystem evaluiert. Dazu wird im Abschnitt 5.1 die zur Evaluierung verwendete Datengrundlage vorgestellt, die aus einem synthetischen und einem realen Smart-Meter-Beispieldatensatz besteht. Der synthetische Beispieldatensatz wird mit Hilfe eines im Rahmen der Arbeit entwickelten Zeitreihengenerators erzeugt. Der Vorteil bei der Verwendung des synthetischen Datensatzes besteht darin, dass die einzelnen Zeitreihenkomponenten bekannt sind und die erwarteten Phänomene der zu untersuchenden Prozessklasse explizit in den synthetischen Zeitreihen erzeugt und in verschiedenen Ausprägungen vorgegeben werden können. Der entwickelte Zeitreihengenerator und dessen Möglichkeiten wurde im Abschnitt 5.1.1.2 vorgestellt. Die abschließende Evaluierung basiert auf einem realen Smart-Meter-Datensatz aus einer Feldstudie namens „Olympic Peninsula Project“. Aufgrund der Zusammenstellung der Verbraucher in der zugrundeliegenden Feldstudie und der dadurch entstandenen systematischen Ungleichheit der enthaltenen Tarifgruppen steht nur die preisbeeinflusste Lastzeitreihe $y[k]$ für die Untersuchungen zur Verfügung. Die Evaluierung des aufgeführten Modellansatzes kann mit dem real gemessenen Datensatz demnach nicht für die einzelnen Zeitreihenkomponenten $y_U[k]$ und $y_R[k]$ durchgeführt werden.

Der Abschnitt 5.2 beschreibt die angewendete Strategie zur Validierung des Vorhersagesystems. Im Abschnitt 5.2.1 werden die Untersuchungsszenarien aufgeführt, die aus zwei Referenzszenarien und drei Testszenarien bestehen. Die beiden Referenzszenarien basieren auf etablierten Methoden der Lastprognose, bei denen ARIMAX und Künstliche Neuronale Netze als Modellansatz angewendet wurden. Die Referenzszenarien dienen als Vergleich zum aktuellen Stand des Wissens. Die Testszenarien basieren auf dem in Abschnitt 4.4 vorgeschlagenen Vorhersagesystem. Die drei

Testsszenarien unterscheiden sich in der Ausbaustufe des neuartigen Vorhersagesystems bezüglich der Spezifikation der klassenbezogenen und uhrzeitabhängigen Modellierung sowie der Eingangsbelegung. Weiterhin werden im Abschnitt 5.2.2 die zur Validierung verwendeten Fehlermaße vorgestellt. Die Bewertung wird dabei je Vorhersagehorizont vorgenommen. Beim abschließenden Bewertungskriterium wird geprüft, ob ein optimales Prognosemodell vorliegt.

Im Abschnitt 5.3 wird das neuartige Vorhersagesystem im Rahmen der im Abschnitt 5.2 vorgeschlagenen Validierungsstrategie auf die im Abschnitt 5.1 vorgestellten Daten angewendet. Zunächst wird für beide Datensätze eine Zeitreihenanalyse auf Grundlage des in Abbildung 3.4 vorgeschlagenen Verarbeitungsworkflows für die Analyse von Lastzeitreihen vorgenommen. Aus den gewonnenen Erkenntnissen der Zeitreihenanalyse wurden Modellstruktur und Modellkonfiguration abgeleitet. Zwischen den Beispieldatensätzen gibt es bezüglich der charakteristischen Eigenschaften entscheidende Unterschiede, die sich folglich auch auf die Modellstruktur und -konfiguration auswirken. Für den synthetischen Datensatz wurde im Rahmen der Analyse für die optimale Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung die Berücksichtigung von sieben Typtagklassen identifiziert. Die ermittelte Kalenderkonfiguration umfasst ein Regelwerk, welche für die verschiedenen Typtage unterschiedliche Regeln der Referenzwertermittlung anwendet. Für Werktag, Wochenenden und Feiertage werden jeweils unterschiedliche Regeln eingesetzt. Für den real gemessenen Datensatz wurde nur drei Typtagklassen (Werktag, Samstag, Sonntag) als optimale Konfiguration der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung identifiziert. Das Regelwerk der ermittelten Kalenderkonfiguration setzt hingegen nur eine Regel ein, die für alle Typtage gleich ist.

Im Abschnitt 5.3.2 werden die Ergebnisse der Untersuchungen auf der Grundlage beider Datensätze aufgeführt. Für den synthetischen Datensatz werden die zwei Referenzszenarien mit den drei Testsszenarien verglichen. Die Ergebnisse zeigen, dass mit den Referenzszenarien bereits Prognosen mit hoher Güte vorliegen. Eine optimale Prognose konnte für die Referenzszenarien zwar nicht nachgewiesen werden. Dennoch sind nur geringe Verletzungen des Optimalitätskriteriums für $H = 1$ zu erkennen. Beim Vergleich mit den Testsszenarien sind die Vorteile des neuartigen Vorhersagesystems bezüglich der Prognosequalität dennoch deutlich zu erkennen. Beim Vergleich der Standardabweichung des Prognosefehlers konnte mit dem Testsszenario 3 die Prognosequalität gegenüber dem Referenzszenario 2 um ca. 16,2 % gesteigert werden. Die Ausbaustufe aus Testsszenario 3 erzielt die höchste Prognosequalität und erfüllt für $H = 1$ das Kriterium der optimalen Prognose. Für den real gemessenen Datensatz wurde daher nur das Testsszenario 3 für die Validierung herangezogen. Im Vergleich zu den Referenzszenarien zeigt Testsszenario 3 die höchste Prognosequalität und erfüllt für $H = 1$ das Kriterium der optimalen Prognose. Die Untersuchungen beider Datensätze haben gezeigt, dass die Ausbaustufe aus Testsszenario 3 jeweils die Prognose mit der höchsten Genauigkeit erstellt. Diese rechtfertigt damit die vorgeschlagenen Erweiterungen des Modellansatzes.

6 Zusammenfassung und Ausblick

6.1 Erkenntnisse der vorliegenden Arbeit

Das Demand Side Management kann einen Beitrag bei der Integration erneuerbarer Energien und dem Erschließen neuer Flexibilitätpotenziale leisten. Beim Demand Response werden Verbraucher indirekt über variable Strompreise beeinflusst, um diese Flexibilitätpotenziale in Form einer gezielten Anpassung des Verbrauchsverhaltens auszunutzen. Die Anpassung des Verbrauchsverhaltens spiegelt sich in einer geänderten Lastkurve wider, die im Hinblick auf eine ausgeglichene Leistungsbilanz zwischen Erzeugung und Verbrauch durch ihren angepassten Verlauf besser zur gegebenen Erzeugung aus erneuerbaren Energien passt. Mit der Ausnutzung verbrauchsseitiger Lastverschiebepotenziale im Rahmen von Demand Response verändern sich allerdings auch typische Verbrauchsmuster von bisher unbeeinflussten Verbrauchern, wodurch sich wiederum die Unsicherheit bei der Verbrauchsprognose und darauf aufbauenden energiewirtschaftlichen Folgeprozessen erhöht.

Beim Demand Response wird der den Verbrauchern vorzugebene Preisanreiz mit Hilfe bestimmter Tarifmodelle vorab in einem vorgelagerten Planungsprozess bestimmt. Ausgangspunkt dieser Planung ist die zu erwartende Verbrauchskurve, wenn diese nicht durch einen Preis beeinflusst ist. Denn nur auf der Grundlage des zu erwartenden Verbrauchs ohne einen Preiseinfluss kann abgeschätzt werden, zu welchem Zeitpunkt und in welchem Ausmaß die Verbraucher mit Hilfe eines zu setzenden Preises zu beeinflussen sind. Die Entscheidungsfindung zur Lastbeeinflussung und die zugehörige Vorschrift zur Preisbildung basieren auf einer Vorhersage des unbeeinflussten Verbrauchs. Bei der Planung und der dafür notwendigen Prognose kann dabei im Rahmen eines kontinuierlich ablaufenden Demand Response Programms nur auf historische Werte zurückgegriffen werden, die bereits durch Preise beeinflusst sind.

Vor diesem Hintergrund war es die Zielsetzung der vorliegenden Arbeit, einen Beitrag zur Analyse und zur Vorhersage von preisbeeinflusstem Verbrauchsverhalten in Energiesystemen zu leisten. Dabei sollte die zusätzliche Unsicherheit, die durch die Beeinflussung im Rahmen von Demand Response bei der Lastprognose zu erwarten ist, minimiert werden. Die entworfene Prognosemethode sollte die komplexen Zusammenhänge und die spezielle Charakteristik des beeinflussten Verbrauchsverhaltens wiedergeben und neben dem beeinflussten auch das unbeeinflusste Verbrauchsverhalten für zukünftige Zeitpunkte beschreiben.

Der Ausgangspunkt für die in der vorliegenden Arbeit durchgeführten Untersuchungen war die Aufarbeitung des aktuellen Standes des Wissens im Abschnitt 2. Es wurde ein Überblick über das Thema Demand Side Management sowie die damit einhergehenden Herausforderungen, Potenziale sowie Beschreibungsansätze gegeben. Der Fokus der vorliegenden Arbeit wurde dabei auf die Prozessklasse von Verbraucherprozessen mit indirekter Beeinflussung mittels Preiszeitreihen gelegt, was als Demand Response bezeichnet wird. Die fokussierte Prozessklasse stellt dabei einen erweiterten und zukünftig erwarteten Anwendungsfall der heutigen Lastprognose dar, welche bisher noch nicht ausreichend in der Literatur untersucht wurde. Zur der Beantwortung der im Abschnitt 1.4 gestellten Forschungsfragen richtete sich die Zielstellung der vorliegenden Arbeit auf den Entwurf eines optimalen Prognosemodells. Dazu wurden die Kriterien für ein optimales Prognosemodell vorgestellt. Der Entwurf eines optimalen Prognosemodells im Rahmen einer Modellbildung basiert auf einer Zeitreihenanalyse. Es besteht eine Wechselwirkung zwischen der Analyse und der

Modellbildung. Die Entscheidungen bei der Modellbildung für die Auswahl eines geeigneten Modellansatzes, die Festlegung der Modellstruktur und die Wahl der Eingangsbelegung stützten sich auf die Ergebnisse der Analyse und somit auf die charakteristischen Eigenschaften der zugrundeliegenden Zeitreihen. Dazu wurde ein Überblick über eingesetzte Analysemethoden aufgezeigt und welche davon im Rahmen der vorliegenden Arbeit relevant waren. Weiterhin wurde ein Überblick über Ansätze zur Zeitreihenmodellierung aufgeführt und als Grundlage der Zeitreihenprognose diskutiert. Der Untersuchungsschwerpunkt wurde dabei auf den linearen stochastischen Zeitreihenmodellen festgelegt.

Der Schwerpunkt im Abschnitt 3 lag auf der Untersuchung von preisbeeinflusstem Verbrauchsverhalten. Zunächst wurden potenzielle Einsatzszenarien für flexible Lasten und damit für die Beeinflussung des Verbrauchsverhaltens diskutiert, in denen jeweils eine Prognose benötigt wird und die somit die gestellte Forschungsaufgabe rechtfertigte. Anschließend erfolgte eine systemtechnische Aufarbeitung der Problemstellung, in der das Zusammenspiel von preisbeeinflusstem Verbraucherverhalten, dessen Vorhersage sowie die zugrundeliegende Betriebsplanung inklusive der Preisbildung in einem Gesamtkonzept aufgearbeitet und diskutiert wurden. Dabei wurde eine Dekomposition der beeinflussten Zeitreihe in die beeinflusste und die unbeeinflusste Zeitreihenkomponente durch das Prognosesystem vorgeschlagen. Für die Zeitreihenmodellierung wurde eine Erweiterung des Komponentenmodells um die beeinflusste Zeitreihenkomponente als neuartiger Ansatz zur Beschreibung von Zeitreihen vorgestellt. Danach folgte eine Untersuchung und Bewertung der Charakteristik der beeinflussten und der unbeeinflussten Zeitreihenkomponente. Bei der unbeeinflussten Zeitreihenkomponente handelt es sich dabei um bekannte Phänomene, wie unterschiedliche Lastniveaus in Abhängigkeit von Uhrzeit und Typtagen und damit typische Rhythmen und Verbrauchsmuster sowie Kalendereffekte. Die beeinflusste Zeitreihenkomponente ist vor allem durch die Preiselastizität charakterisiert, die ein Maß dafür ist, wie stark eine Laständerung als Reaktion auf eine Preisänderung ausfällt. Dabei sind die Auswirkungen des Planungshorizontes von Interesse, da sich die Vorlaufzeit, in der Preise im Vorfeld bekannt sind, auf die Planbarkeit der Verbraucher, sich auf Preisänderungen einzustellen, auswirkt. Preise, die im Vorfeld bekannt sind, bewirken dabei eine dynamisch a priori oder a posteriori zeitversetzte Reaktion der Verbraucher. Die Verbraucherreaktion kann also auch schon vor dem eigentlichen Preisevent vorkommen. Weiterhin wurden im Abschnitt 3 Analysemethoden vorgestellt, die zur Analyse der Verbrauchscharakteristik zur Anwendung kamen, sowie deren Relevanz in Bezug auf die Analyse. Es wurden ein Verarbeitungsworkflow für die Analyse von Lastzeitreihen sowie ein Verarbeitungsworkflow für die Auswertung der Residuen vorgeschlagen. Abschließend wurden im Abschnitt 3 die Anforderungen an die Prognose von preisbeeinflusstem Verbrauchsverhalten noch einmal zusammengefasst, die sich aus der speziellen Verbrauchscharakteristik, der systemtechnischen Aufarbeitung und der übergeordneten Aufgabenstellung ergeben.

Der Abschnitt 4 beschäftigte sich mit der Konzeption und dem Entwurf der neuen Prognosemethode. Zunächst wurde ein Vorgehenskonzept vorgestellt, welches den Handlungsstrang von der Datenanalyse bis zum Modellentwurf vorgibt. Im Rahmen der Entwurfsphase wurden Modellansätze jeweils zur Modellierung der unbeeinflussten und beeinflussten Zeitreihenkomponente als Teilmodelle vorgeschlagen, die anschließend im Vorhersagesystem für beeinflusste Zeitreihen zu einem Gesamtmodell zusammengeführt wurden. Dabei wird auf Grundlage des erweiterten Komponentenmodells die beeinflusste Zeitreihe in beeinflusste und unbeeinflusste Zeitreihenkomponente zerlegt. Die Vorteile dieser Herangehensweise liegen einerseits in der Möglichkeit, die beiden Zeitreihenanteile in separaten Teilmodellen zu beschreiben, welche jeweils die spezifische Charakteristik der unbeeinflussten und der beeinflussten Zeitreihenkomponente berücksichtigen. Ein weiterer

Vorteil besteht in der Dekomposition der beeinflussten Lastzeitreihe in die beeinflusste und die unbeeinflusste Zeitreihenkomponente. Der neuartige Modellansatz wurde als IARIMA (Influenced Autoregressive Integrated Moving Average) vorgestellt und basiert auf einem abgewandelten ARIMAX-Modellansatz mit spezieller Berücksichtigung der Preisinformationen. Für die Prognose wird dabei das Konzept klassenbezogener und uhrzeitabhängiger Mehrschrittmodellierung eingeführt, bei dem lokale Phänomene der Zeitreihen durch separate Einzelmodelle beschrieben wurden, um die Qualität der Gesamtprognose zu verbessern. Abschließend wurden der Aufbau des Prognosesystems und der Ablauf bei der Anwendung des IARIMA-Modells im Rahmen des Vorhersagesystems vorgestellt.

Der Abschnitt 5 umfasst die Erprobung und Evaluation der neuartigen Prognosemethode. Zunächst wurde die Datengrundlage vorgestellt, die einen synthetischen und eine real gemessenen Datensatz umfasst. Bei dem synthetisch erzeugten Datensatz wurden die erwarteten Phänomene der zu untersuchenden Prozessklasse explizit in synthetischen Zeitreihen vorgegeben. Dafür wurde ein Zeitreihengenerator entwickelt der alle Zeitreihenkomponenten in verschiedenen Ausprägungen erzeugen und somit realitätsnahe Zeitreihen generieren kann. Der real gemessene Datensatz ist der zu untersuchenden Prozessklasse zuzuordnen und stammt aus einer Feldstudie. Anhand einer vorgestellten Validierungsstrategie wurde die neuartige Prognosemethode mit Hilfe der vorliegenden Daten erprobt und evaluiert. Die Zeitreihen wurden mit den relevanten Analysemethoden untersucht und auf der Grundlage der gewonnenen Erkenntnisse erfolgten jeweils die Modellkonfiguration und Modelldimensionierung. Abschließend wurden die Ergebnisse aufgeführt und ausgewertet. Im Ergebnis der Untersuchung konnte gezeigt werden, dass die neuartige Prognosemethode für preisbeeinflusstes Verbrauchsverhalten signifikante Vorteile gegenüber etablierten Methoden der Lastprognose aufweist. Einerseits konnte eine erhebliche Verbesserung der Prognosequalität beobachtet werden, was bei der Untersuchung der Modellresiduen im Nachweis der optimalen Prognose (Horizont $H = 1$) mündete. Andererseits ist es mit der neuartigen Prognosemethode möglich, die einzelnen Zeitreihenkomponenten der unbeeinflussten und beeinflussten Zeitreihenkomponente mittels Dekomposition separat vorherzusagen. Dies erfüllt die Voraussetzung der Preisplanung beim Demand Response.

6.2 Ausblick auf weiteren Forschungsbedarf

Die Anknüpfungspunkte an die vorliegende Arbeit bestehen vorrangig in der Untersuchung des dynamischen Zusammenwirkens von Verbrauchern, Prognoseverfahren und Preisoptimierung in rückgekoppelten Systemen. Die Auswirkungen von Preisanreizen auf Energieverbraucher, auf deren Verbrauchsverhalten, Energiebedarfsprognosen und die einhergehenden Phänomene im Energiesystem sind dabei in einem Gesamtzusammenhang zu betrachten und zu untersuchen. Dabei ist insbesondere zu klären, welche Güte Demand-Response-Strategien inkl. der neuen Prognosemethode in komplexen Szenarien erreichen können. In diesem Zusammenhang ergeben sich offene Fragestellungen bezüglich des Aufhaltens unerwünschter Phänomene sowie deren Beschreibung und Quantifizierung wie bspw. die Stabilität eines preisbeeinflussten Energiesystems. Außerdem stellen sich Fragen nach Maßnahmen zur Steigerung der Robustheit. Ordnet man die in der vorliegenden Arbeit untersuchte Problemstellung in einen größeren Kontext ein, dann ergeben sich weitere Forschungsfragen im Zusammenwirken mit anderen Technologien zur Erschließung von Flexibilitätspotenzialen im Energiesystem.

Für eine methodische Weiterentwicklung der Modellierung von preisbeeinflusstem Verbrauchsverhalten und dessen Prognose schließen in verschiedenen Details weiterführende Forschungsfragen

an. Es ist beispielsweise zu untersuchen, ob bei der Beeinflussung von Verbrauchern Konditionierungseffekte beim Verbrauchsverhalten entstehen. Diese müssten ggfls. bei der Modellierung Berücksichtigung finden. Weitere methodische Anknüpfungspunkte liegen in einer detaillierteren Modellierung der Speichereigenschaft von Verbrauchern im Rahmen von DR. Eine Kombination von DSM-Maßnahmen mit Wärmeumwandlung werden vor dem Hintergrund des Smart-Grid-Konzeptes als vielversprechende Technologie angesehen. Vor diesem Hintergrund sind die zwei Fälle P-DSM (reine Lastverschiebung) und PE-DSM (Lastverschiebung und Änderung des Energiebedarfs) für die Prognose von preisbeeinflussten Verbrauchern explizit zu unterscheiden. Zur Ermittlung und Quantifizierung eines Parameters für eine „DR-Speicherkapazität“ aus einem entsprechenden Smart-Meter-Datensatz können weiterführende Forschungsfragen bezüglich der Datenanalyse abgeleitet werden.

Die vorgestellte Prognosemethode wurde im Rahmen der vorliegenden Arbeit für einen Anwendungsfall verwendet und evaluiert. Es ergeben sich allerdings auch Parallelen zu anderen Anwendungsfeldern, bei denen die neuartige Prognosemethode zu Einsatz kommen könnte. Beispielsweise gibt es Ähnlichkeiten bei der Vorhersage des Wärmebedarfs in Fernwärmenetzen. Dabei ist der Speichereffekt der Netze zu beachten und bei der Prognose mit zu berücksichtigen. Für eine Anpassung der Methoden an den Anwendungsfall Wärmebedarfsprognose in Fernwärmenetzen ergibt sich weiterführender Forschungsbedarf.

Weiterhin gibt es prinzipiell Anknüpfungspunkte im Hinblick auf Alternativen und Vereinfachungen für die Modellierung der Eigen- und Kreuzpreiselastizitäten der Matrix \mathbf{Z} . Vereinfachte bzw. reduzierte Strukturen wie die Annahme, dass alle Elemente auf der Hauptdiagonalen gleich sind oder eine nur punktuelle Besetzung von \mathbf{Z} , ergeben Forschungsbedarf für weiterführende Arbeiten.

Andere interessante Fragestellungen resultieren aus dem Einsatz komplexerer Modellansätze wie nichtlinearer stochastischer Zeitreihenmodelle, KNN oder hybride Modellansätze und wie diese auf die vorliegende Problemstellung adaptiert werden können. Insbesondere die Möglichkeiten von Deep Learning Ansätzen und die hierzu zur Verfügung stehenden Werkzeuge bieten umfangreiche Möglichkeiten zur Beantwortung weiterführender Forschungsfragen zum Thema Prognose. Im Hinblick auf eine geeignete Modellierung preisbeeinflusster Verbraucher und die resultierende Prognosequalität ergibt sich somit weiterer Forschungsbedarf.

Der im Rahmen der vorliegenden Arbeit entwickelte Zeitreihengenerator bietet ebenfalls Anknüpfungspunkte. Betrachtet man den Zeitreihengenerator als Werkzeug zur Beschreibung typischer Verbrauchszeitreihen, dann können die darin enthaltenen Modelle als Modellbibliothek zur automatischen Klassifikation von Zeitreiheneigenschaften ausgebaut werden. Eine automatische Dekomposition von Zeitreihen entsprechend des Komponentenmodells und somit eine automatische Zuordnung der charakteristischen Eigenschaften münden in weiterem Forschungsbedarf.

7 Literaturverzeichnis

- [1] Netzentwicklungsplan Strom: *Szenario Rahmen für den Netzentwicklungsplan Strom 2030* (Version 2019). Entwurf der Übertragungsnetzbetreiber, Stand Januar 2018
- [2] acatech – Deutsche Akademie der Technikwissenschaften, Nationale Akademie der Wissenschaften Leopoldina und Union der deutschen Akademien der Wissenschaften: »Sektorkopplung« – *Optionen für die nächste Phase der Energiewende*. Schriftenreihe zur wissenschaftsbasierten Politikberatung, Berlin, 2017
- [3] Sonnenschein, M.; Rapp, B.; Bremer, J.: *Demand Side Management und Demand Response, Handbuch Energiemanagement*. 2010
- [4] Deutsche Energie-Agentur GmbH (dena): *dena-Verteilnetzstudie. Ausbau- und Innovationbedarf der Stromverteilnetze in Deutschland 2030*. Endbericht 2012
- [5] Hinterberger, R.; Polak, S.: *Lastverschiebung in Industrie und Gewerbe in Österreich Chancen und Potentiale in zukünftigen Smart Grids*. 7. Internationale Energiewirtschaftstagung an der TU Wien, 2011
- [6] Unterländer, M.: *Dynamische Stromtarife aus Kundensicht – Akzeptanzstudie auf Basis einer Conjointanalyse*. Master Thesis, Fraunhofer ISI, 2010
- [7] Paetz, A.; Kaschub, T.; Jochem, P.; Fichtner, W.: *Demand Response with Smart Homes and Electric Scooters: An Experimental Study on User Acceptance*. Karlsruhe Institute of Technology, 2012
- [8] Albadi, M.H.; El-Saadany, E.F.: *A summary of demand response in electricity markets*. Electric Power Systems Research, 2008
- [9] Aghaei, J.; Alizadeh, M.-I.: *Demand response in smart electricity grids equipped with renewable energy sources: A review*. Renewable and Sustainable Energy Reviews Vol. 18, 2013, pp. 64–72, 2013
- [10] Roscoe, A.; Ault G.: *Supporting high penetrations of renewable generation via implementation of real-time electricity pricing and demand response*. IET Renew. Power Gen., Vol. 4, Iss. 4, pp. 369–382, 2010
- [11] Corradi, O.; Ochsenfeld, H.; Madsen, H.; Pinson, P.: *Controlling Electricity Consumption by Forecasting its Response to Varying Prices*. IEEE Transactions on Power Systems, Vol. 28, Iss. 1, pp 421 – 429, 2013
- [12] EEG 2017 (2017): *Erneuerbare-Energien-Gesetz*. 2017
- [13] Bronstein, N; Mühling, H.; Musiol, G.; Semendjajew, K.A.: *Taschenbuch der Mathematik*, Europa-Lehrmittel, 10. Auflage, 2016
- [14] Wernstedt, J. : *Experimentelle Prozessanalyse*, VEB Verlag Technik, Berlin 1989
- [15] Bretschneider, P.: *Ein Beitrag zur Vorhersage musterbasierter nichtlinearer stochastischer Signale*. Dissertation, Verlag ISLE, Ilmenau 2002
- [16] Bernstein M.A.; Griffin J.: *Regional Differences in the Price-Elasticity of Demand for Energy*. National Renewable Energy Laboratory 2006
- [17] Hayn, M.; Ringler P.; Ruppert, M.; Schmid, J.; Bertsch, V.; Keles, D.; Fichtner, W.: *A residential price elasticity model for agent-based simulation of decentralized energy systems*. E-World energy & water 2014
- [18] Waczowicz, S.; Mikut, R.; Klaiber, S.; Bretschneider, P.; Konotop, I.; Westermann, D.: *Virtuelle Speicher als adaptierbare Verbrauchermmodelle zur Lastprognose und Betriebsführung in Verteilnetzen*. 23. Workshop Computational Intelligence, Dortmund, 2013

- [19] Holtschneider, T.; Erlich, I.: *Modeling demand response of consumers to incentives using fuzzy systems*. IEEE power and energy society general meeting – conversion and delivery of electrical energy in the 21st century, 2012
- [20] Pflugradt, S.; Arnoldt, A.; Warweg, O.; Bretschneider, P.: *Customer behavior model for load adjustment and tariff forming*. International Workshop on Integration of Solar Power into Power Systems, 2013
- [21] Wang, Q.; Wang, J.; Guan, Y.: *Stochastic Unit Commitment With Uncertain Demand Response*. IEEE Transaction on Power Systems, Vol. 28 No. 1, pp. 562 – 563, 2013
- [22] Goia, A.; May, C.; Fusai, G.: *Functional clustering and linear regression for peak load forecasting*. International Journal of Forecasting 26, 2010
- [23] Chen, J.-F.; Wang, W.-M.; Huang, C.-M.: *Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting*. Electric Power Systems Research 34. 1995
- [24] Hufendiek, K.: *Systemtechnische Entwicklung von Lastprognosesystemen auf Basis neuronaler Netze*. Fortschr.-Ber. VDI Reihe 6 Nr. 455, VDI Verlag, Düsseldorf, 2001
- [25] Hahn, H.; Meyer-Nieberg, S.; Pickl, S.: *Electric load forecasting methods: Tools for decision making*. European Journal of Operational Research, Vol. 199, No. 3, pp. 902-907, 2009.
- [26] Kollman, A.; Amann, C.; Elbe, C.; Heinisch, V.; Kraussler, A.; Moser, S.; Schmautzer, E.; Schmidthaler, M.: *Lastverschiebung in Haushalt, Industrie, Gewerbe und kommunaler Infrastruktur – Potenzialanalyse für Smart Grids – LOADSHIFT*. Internationale Energiewirtschaftstagung an der TU Wien (IEWT) 2013
- [27] Palensky P.; Dietrich D.: *Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads*. IEEE Transactions on Industrial Informatics Vol. 7, No. 3, 2011
- [28] Saffre, F.; Gedge, R.: *Demand-Side Management for the Smart Grid*. Network Operations and Management Symposium Workshops (NOMS Wksp), IEEE/IFIP, pp. 300-303, 2010
- [29] Abdollahi, A.; Moghaddam, M. P.; Rashidinejad, M.; Sheikh-El-Eslami, M. K.: *Investigation of Economic and Environmental-Driven Demand Response Measures Incorporating UC*. IEEE Transactions on Smart Grid, Vol. 3 No. 1, pp.12-25, 2012
- [30] Backhaus, K.; Erichson, B.; Plinke, W.; Weiber, R.: *Multivariate Analysemethoden*. 11. Auflage, Springer Verlag, Berlin Heidelberg 2006
- [31] Guan, C.; Luh, P.B.; Michel, L. D.; Wang, Y.; Friedland, P. B.: *Very Short-Term Load Forecasting: Wavelet Neural Networks With Data Pre-Filtering*. IEEE Transactions on Power Systems, Vol. 28, Iss. 1, p. 30-41, 2012
- [32] Hanmandlu, M.; Chauhan, B. K.: *Load Forecasting Using Hybrid Models*. IEEE Transactions on Power Systems, Vol. 26, No. 1, pp. 20-29, 2011
- [33] Fan, S.; Hyndman, R. J.: *Short-Term Load Forecasting Based on a Semi-Parametric Additive Model*. IEEE Transactions on Power Systems Vol. 27, No. 1, p. 134–141, 2012
- [34] Al-Hamadi, H.; Soliman, S.: *Long-term/mid-term electric load forecasting based on short-term correlation and annual growth*. Electric Power Systems Research, Vol. 74, No. 3, pp. 353-361, 2005
- [35] Taylor, J.; McSharry, P.: *Short-term load forecasting methods: An evaluation based on European data*. IEEE Transactions on Power Systems., Vol. 22, No. 4, pp. 2213–2219, Nov. 2007
- [36] Amjady, N.; Daraeepour, A.: *Midterm Demand Prediction of Electrical Power Systems Using a New Hybrid Forecast Technique*. IEEE Transactions on Power Systems, Vol.26, No. 2, pp. 755-765, 2011
- [37] Hamid, M. A.; Rahman, T. A.: *Short Term Load Forecasting Using an Artificial Neural Network Trained by Artificial Immune System Learning Algorithm*. IEEE 12th International Conference on Computer Modelling and Simulation, pp. 408-413, 2010

- [38] Khosravi, A.; Nahavandi, S.; Creighton, D.; Srinivasan, D.: *Interval Type-2 Fuzzy Logic Systems for Load Forecasting: A Comparative Study*. IEEE Transactions on Power Systems, Vol. 27, No. 3, pp. 1274-1282, 2012
- [39] Wang, Y.; Xia, Q; Kang, C.: *Secondary Forecasting Based on Deviation Analysis for Short-Term Load Forecasting*. IEEE Transactions on Power Systems, Vol. 26, No. 2, pp. 500-507, 2011
- [40] Gu, Y.; Hu, F.: *An intelligent forecasting method for short term electric power load based on partitioned support vector regression*. IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems, pp. 721-725, 2012
- [41] Suganthi, L.; Samuel, A.A.: *Energy models for demand forecasting-A review*. Renewable and Sustainable Energy Reviews, Vol. 16, pp. 1223-1240, 2012
- [42] Mertens, P.; Rässler, S.: *Prognoserechnung*. 7. Auflage, Springer-Verlag Berlin Heidelberg, 2012
- [43] Singh, A.K; Ibraheem, I.; Khatoon, S.; Muazzam, M.; Chaturvedi, D. K.: *Load Forecasting Techniques and Methodologies: A Review*. Power, Control and Embedded Systems (ICPCES), 2nd International Conference on, 2012
- [44] Vapnik V.: *The nature of statistic learning theory*. New York: Springer-Verlag; 1995
- [45] Schlittgen, R.; Streitberg, B.: *Zeitreihenanalyse*. 9. Auflage: Oldenburg Wissenschaftsverlag München Wien, 2001
- [46] Jang, J.-S.R.: *ANFIS: adaptive-network-based fuzzy inference system*. Systems, Man and Cybernetics, IEEE Transactions, Vol. 23, Iss. 3, pp. 665–685, 1993
- [47] Raza, M.Q., Baharudin, Z.: *A Review on Short Term Load Forecasting Using Hybrid Neural Network Techniques*. IEEE International Conference on Power and Energy (PECon), 2012
- [48] Aladag, C. H.; Yolcu, U.; Egrioglu, E.; Dalar, A. Z.: *A new time invariant fuzzy time series forecasting method based on particle swarm optimization*. Applied Soft Computing, Vol. 12, No. 10, pp. 3291-3299, 2012
- [49] Che, J.; Wang, J.; Wang, G.: *An adaptive fuzzy combination model based on self-organizing map and support vector regression for electric load forecasting*. Energy, Vol. 37, No. 1, pp. 657-664, 2012
- [50] Almeshaieci, E.; Soltan, H.: *A methodology for Electric Power Load Forecasting*. Alexandria Engineering Journal, Vol. 50, No. 2, pp. 137-144, 2011
- [51] Carlson, C. S.: *Fuzzy logic load forecasting with genetic algorithm parameter adjustment*. Dissertation, 2012
- [52] Cárdenas, J. J.; Romeral, L.; Garcia, A.; Andrade, F.: *Load forecasting framework of electricity consumptions for an Intelligent Energy Management System in the user-side*. Expert Systems with Applications, Vol. 39, No. 5, pp. 5557-5565, 2012
- [53] Nie, H.; Liu, G.; Liu, X.; Wang, Y.: *Hybrid of ARIMA and SVMs for Short-Term Load Forecasting*. Energy Procedia, Vol. 16, pp. 1455-1460, 2012
- [54] Ye, S.: *Long Term Load Forecasting and Recommendations for China Based on Support Vector Regression*. Energy and Power Engineering, Vol. 04, No. 05, pp. 380-385, 2012
- [55] Wang, J.; Li, L.; Niu, D.; Tan, Z.: *An annual load forecasting model based on support vector regression with differential evolution algorithm*. Applied Energy, Vol. 94, pp. 65-70, 2012
- [56] Bunnoon, P.; Chalermyanont, K.; Limsakul, C.: *Multi-substation control central load area forecasting by using HP-filter and double neural networks (HP-DNNs)*. International Journal of Electrical Power & Energy Systems, Vol. 44, No. 1, pp. 561-570, 2013

- [57] Sousa, J.; Neves, L.; Jorge, H.: *Assessing the relevance of load profiling information in electrical load forecasting based on neural network models*. International Journal of Electrical Power & Energy Systems, Vol. 40, No. 1, pp. 85-93, 2012
- [58] Sigauke, C.; Chikobvu, D.: *Prediction of daily peak electricity demand in South Africa using volatility forecasting models*. Energy Economics, Vol. 33, No. 5, pp. 882-888, 2011
- [59] Wang, J.; Zhu, S.; Zhang, W.; Lu, H.: *Combined modeling for electric load forecasting with adaptive particle swarm optimization*. Energy, Vol. 35, No. 4, pp. 1671-1678, 2010
- [60] Chen, Y.; Luh, P.; Guan, C.; Zhao, Y.; Michel, L.; Coolbeth, M.; Friedland, P.; Rourke, S.: *Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks*. IEEE Transactions on Power Systems, Vol. 25, No. 1, pp. 322-330, 2010
- [61] Klaiber, S., Bretschneider, P., Waczowicz, S., Mikut, R., Konotop, I., Westermann, D.: *A contribution to the load forecast of price elastic consumption behavior*. IEEE PowerTech, Eindhoven, 2015
- [62] Warweg, O.; Arnoldt, A.; Troitzsch, C.; Frenzel, S.; Werner, M.; Bretschneider, P.: *Analysis of the Effects of Demand Response to the Integration of Renewable Energy into the Distribution Grid*. International Workshop on Integration of Solar Power into Power Systems, Langen, Energynautics, pp.181-186, 2011
- [63] Hammerstrom, D.; Ambrosio, R.; Brous, J.; Carlon, T.; Chassin, D.; DeSteese, J.; Guttromson, R.; Horst, G.; Jarvegren, O.; Kajfasz, R.; et al: *Pacific Northwest GridWise Testbed Demonstration Projects. Part I. Olympic Peninsula Project*. Tech. Rep. Pacific Northwest National Laboratory, 2007
- [64] Klobasa M. : *Dynamische Simulation eines Lastmanagements und Integration von Windenergie in ein Elektrizitätsnetz auf Landesebene unter regelungstechnischen und Kostengesichtspunkten*. Dissertation, ETH Zürich, 2007
- [65] Faruqui, A.; Sergici, S.: *Household Response to Dynamic Pricing of Electricity: A Survey of 15 Experiments*. Journal of Regulatory Economics, Springer, Vol. 38, Iss.2, pp. 193-225, 2010
- [66] Stromback, J.; Dromacque, C.; Yassin, M.: *The potential of smart meter enabled programs to increase energy and systems efficiency: a mass pilot comparison*. VaasaETT, Global Energy Think Tank, 2011 Available at: <http://www.esmig.eu/press/filestor/empower-demand-report.pdf> [Online: accessed 29.04.15]
- [67] Ehrhardt-Martinez, K.; Donnelly, K.A.; Laitner, J.A.: *Advanced Metering Initiatives and Residential Feedback Programs: A Meta-Review for Household Electricity-Saving Opportunities*. Report No. E105. American Council for an Energy-Efficient Economy, Washington, 2010
- [68] Klaiber, S.; Bretschneider, P.; Waczowicz, S.; Mikut, R.; Konotop, I.; Westermann, D.: *Intelligente Prognoseverfahren für beeinflusstes Verbrauchsverhalten in Energiesystemen*. 23. Workshop Computational Intelligence, Dortmund, 2013
- [69] Andersen, F.M.; Larsen, H.V.; Boomsma, T.K.: *Long-term forecasting of hourly electricity load: Identification of consumption profiles and segmentation of customers*. Energy Conversion and Management, No. 68, pp. 244-252, 2013
- [70] Gobmaier, T. H.: *Entwicklung und Anwendung einer Methodik zur Synthese zukünftiger Verbraucherlastgänge*. Dissertation, Technische Universität München, Lehrstuhl für Energiewirtschaft und Anwendungstechnik, 2014
- [71] VDEW, Repräsentative VDEW Lastprofile (M-32/99), Frankfurt (Main), 1999
- [72] Fan, S.; Hyndman, R. J.: *The price elasticity of electricity demand in South Australia*. Energy Policy Vol. 39, pp. 3709-3719, 2011
- [73] Mardavij Roozbehani, M.; Faghieh, A.; Ohannessian, M. I.; Dahleh, M. A.: *The Intertemporal Utility of Demand and Price Elasticity of Consumption in Power Grids with Shiftable Loads*. 50th IEEE Conference on Decision and Control and European Control Conference (CDC-ECC), 2011

- [74] Goel, L.; Wu, Q.; Wang, P.: *Reliability Enhancement and Nodal Price Volatility Reduction of Restructured Power Systems with Stochastic Demand Side Load Shift*. IEEE Power Engineering Society General Meeting, 2007
- [75] Yu, N.; Yu, J.-L.: *Optimal TOU Decision Considering Demand Response Model*, IEEE International Conference on Power System Technology, 2006
- [76] Aalami, H.A.; Moghaddam, M. P.; Yousefi, G.R.: *Modeling and prioritizing demand response programs in power markets*. Electric Power Systems Research No. 80, pp. 426-435, 2009
- [77] Kirschen, D. S.; Strbac, G.; Cumperayot, P.; Paiva Mendes, D. de: *Factoring the Elasticity of Demand in Electricity Prices*. IEEE Transactions on Power Systems, Vol. 15, No. 2, pp. 612-617, 2000
- [78] VDE-Studie: *Demand Side Integration – Lastverschiebungspotentiale in Deutschland*. Studie der Energietechnischen Gesellschaft im VDE (ETG), 2012
- [79] Siano, P.: *Demand Response and Smart Grids – a Survey*. Renewable and Sustainable Energy Reviews, Vol. 30, pp. 461-478, 2014
- [80] Richtlinie 2012/27/EU (Energieeffizienz-Richtlinie), Richtlinie des Europäischen Parlaments und des Rates der Europäischen Union, 2012
- [81] Bruyn, K. de; Kollmann, A.; Moser, S.; Schmidthaler, M.; Amann, C.; Elbe, C.; Schmutzter, E.; Kraussler, A.; Reinhofer-Gubisch, M.; Pucker, J.; Frantes, B.: *LoadShift: Lastverschiebung in Haushalt, Industrie, Gewerbe und kommunaler Infrastruktur Potenzialanalyse für Smart Grids – Loadshift-Rahmenbedingungen*. Berichte aus Energie- und Umweltforschung 7b/2015 – Österreichische Begleitforschung zu Smart Grids, Bundesministerium für Verkehr, Innovation und Technologie, 2014
- [82] Bankhofer, U. P.-D.; Vogel, J. D.: *Datenanalyse und Statistik*. 1. Auflage Hrsg., Ilmenau, Thüringen: Gabler Verlag, 2008
- [83] Härdle, W.; Simar, L.: *Applied Multivariate Statistical Analysis*. MD TECH Method & Data Technologies, 2003
- [84] Dormann, C.F.D.; Kühn, I. D.: *Angewandte Statistik für die biologischen Wissenschaften*. 2 Hrsg., Helmholtz Zentrum für Umweltforschung-UFZ, 2011
- [85] Holtmann, D.: *Grundlegende multivariate Modelle der sozialwissenschaftlichen Datenanalyse*. 3 Hrsg., Universität Potsdam: Universitätsverlag Potsdam, 2010
- [86] Mikut, R.: *Data Mining in der Medizin und Medizintechnik*. Bd. 22, Institut für Angewandte Informatik / Automatisierungstechnik Universität Karlsruhe: Universitätsverlag Karlsruhe, 2008
- [87] R. M. Sakia, R.M.: *The Box-Cox Transformation technique: a review*. The Statistician, No. 41, pp. 169-178, 1992
- [88] Teusch, A.: *Einführung in die Spektral- und Zeitreihenanalyse mit Beispielen aus der Geodäsie*. Heft Nr. 120 Hrsg., Bd. Reihe A, München: Verlag der Bayerischen Akademie der Wissenschaften in Kommission bei der C. H. Beck'schen Verlagsbuchhandlung München, 2006
- [89] Kroschel, K.; Rigoll, G.; Schuller, B.: *Statistische Informationstechnik*. 5. Auflage, Springer Verlag, Berlin Heidelberg, 2011
- [90] Mertins, A.: *Signaltheorie*. 2. Auflage, Vieweg+Teubner | GWV Fachverlage GmbH, Wiesbaden, 2010
- [91] Handl, A.: *Multivariate Analysemethoden*, 2. Auflage, Springer-Verlag Berlin Heidelberg 2010
- [92] Sachs, L.; Hedderich, J.: *Angewandte Statistik*. Berlin Heidelberg: Springer-Verlag, 2009
- [93] Kohonen, T.: *Self-Organizing Maps*. 3. Edition, Springer-Verlag Berlin Heidelberg, 2001

- [94] Rauschenbach, T.: *Modellierung und Vorhersage nichtlinearer Zeitreihen*, Habilitationsschrift, Ilmenau 2004
- [95] Hillemacher, L.; Nolden, C.; Bertsch, V.; Fichtner, W.: *Lastverlagerungspotenziale durch variable Stromtarife – Ergebnisse eines Feldtests*. 8. Internationale Energiewirtschaftstagung an der TU Wien, 2013
- [96] Klobasa, M.; Erge, T.; Bukvic-Schäfer, A. S.; Hollmann, M.: *Demand Side Management in dezentral geführten Verteilnetzen (Erfahrungen und Perspektiven)*. 11. Kasseler Symposium Energy Systems Technology, 2006
- [97] Arnoldt, A.; Warweg, O.; Frenzel, S.; Werner, M.; Bretschneider, P.: *Analyse des Einflusses vom Demand Response RESIDENS Feldversuch auf das Kundenlastverhalten*. VDE-Kongress, 2012.
- [98] Warweg, O.; Schmelzer, K.; Ifland, M.; Bretschneider, P.; Westermann, D.: *Auswirkungen zeitvariabler Stromtarife in der Bilanzkreisabrechnung von Haushaltskunden*. VDE-Kongress, 2012
- [99] Waczowicz, S.; Reischl, M.; Hagenmeyer, V.; Mikut, R.; Klaiber, S.; Bretschneider, P.; Konotop, I.; Westermann, D.: *Demand Response Clustering – How do Dynamic Prices affect Household Electricity Consumption?*. IEEE PowerTech, Eindhoven, 2015
- [100] Klaiber, S.; Waczowicz, S.; Konotop, I.; Westermann, D.; Mikut, R.; Bretschneider, P.: *Prognose für preisbeeinflusstes Verbrauchsverhalten*. at – Automatisierungstechnik, Bd. 65, Nr.3, Seiten 179–188, 2017
- [101] Link: <http://www.ewe-netz.de/strom/1988.php> (Verwendung des Referenzjahres 2014) [Abruf am: Oktober 2015]
- [102] Andres, P.; Spiwoks, M.: *Prognosegütemasse: State of the Art der statistischen Ex-post-Beurteilung von Prognosen*. Sofia-Studien zur Institutionenanalyse, Bd. 00-1, Darmstadt. 2000
- [103] Feindt, M.; Kerzel, U.: *Prognosen bewerten*. Springer-Verlag Berlin Heidelberg, 2015
- [104] Pham, D.; Liu, X.: *Neural Networks for Identification*. Prediction and Control. Springer-Verlag London, 1995
- [105] Koch, M.; Kuhn, T.; Wernstedt, J.: *Fuzzy Control: Optimale Nachbildung und Entwurf optimaler Entscheidungen; mit 46 Tabellen*. Oldenbourg, München, 1996
- [106] Borgelt C.: *Neuro-Fuzzy-Systeme: Von den Grundlagen künstlicher Neuronaler Netze zur Kopplung mit Fuzzy-Systemen*. Computational intelligence. Vieweg, Wiesbaden, 3. Auflage, 2003
- [107] Nauck, D.; Klawonn, F.; Kruse, R.: *Neuronale Netze und Fuzzy-Systeme: Grundlagen des Konnektivismus, neuronaler Fuzzy Systeme und der Kopplung mit wissensbasierten Methoden*. 2. Auflage, Computational Intelligence, Vieweg, Braunschweig und Wiesbaden, 1996
- [108] Minku, F.; Ludermir, T.: *EfuNNs Ensembles Construction Using a Clustering Method and a Coevolutionary Genetic Algorithm*. IEEE Congress on Evolutionary Computation, pp. 1399-1406, 2006
- [109] Kasabov, N.K.; Song, Q.: *DENFIS: dynamic evolving neural-fuzzy inference system and its application for time-series prediction*. IEEE Transactions on Fuzzy Systems, Vol.10 No.2, pp.144-154, 2002
- [110] Ye, R.; Suganthan, P. N.; Srikanth, N.; Sarkar, S.: *A hybrid ARIMA-DENFIS method for wind speed forecasting*. IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), 2013
- [111] Mellit, A.: *Development of an expert configuration of stand-alone power PV system based on adaptive Neuro-Fuzzy inference system (ANFIS)*. IEEE MELECON 2006, pp.893-896, 2006
- [112] Box, G.; Jenkins, G.: *Time Series Analysis: Forecasting and Control*. 4. Auflage, John Wiley & Sons, Hoboken, 1970
- [113] Connect Energy Economics: *Aktionsplan Lastmanagement*. Endbericht einer Studie von Connect Energy Economics. Studie im Auftrag von Agora Energiewende, 2015

- [114] Waczowicz, S.; Klaiber, S.; Bretschneider, P.; Konotop, I.; Westermann, D.; Reischl, M.; Mikut, R.: *Data Mining zur Analyse der Auswirkungen von Preissignalen auf Haushaltsstromkunden*. at – Automatisierungstechnik, Bd. 62 Nr. 10, Seiten 740–752, 2014
- [115] Waczowicz, S.; Reischl, M.; Klaiber, S.; Bretschneider, P.; Konotop, I.; Westermann, D.; Hagenmeyer, V.; Mikut, R.: *Virtual Storages as Theoretically Motivated Demand Response Models for Enhanced Smart Grid Operations*. In: Energy Technology, WILEY-VCH Verlag, Vol. 4, pp. 163–176, 2016
- [116] Fahrmeir, L.; Kneib, T.; Lang, S.: *Regression – Modelle, Methoden und Anwendungen*. 2. Auflage, Springer-Verlag Berlin Heidelberg, 2009
- [117] Shariatzadeh, F.; Mandal, P.; Srivastava, A. K.: *Demand response for sustainable energy systems: A review, application and implementation strategy*. Renewable and Sustainable Energy Reviews, Vol. 45, pp. 343–350, 2015
- [118] O’Connell, N.; Pinson, P.; Madsen, H.; O’Malley, M.: *Benefits and challenges of electrical demand response: A critical review*. Renewable and Sustainable Energy Reviews, Vol. 39, pp. 686–699, 2014
- [119] Dietrich, K.; Latorre, J.M.; Olmos, L.; Ramos, A.: *Demand Response in an Isolated System With High Wind Integration*. IEEE Transactions on Power Systems, Vol. 27, Iss.1, pp.20–29, 2012
- [120] Deng, R.; Yang, Z.; Chow, M.-Y.; Chen, J.: *A Survey on Demand Response in Smart Grids: Mathematical Models and Approaches*. IEEE Transactions on Industrial Informatics, Vol. 11, No. 3, pp. 570 – 582, 2015
- [121] Baboli, P. T.; Eghbal, M.; Moghaddam, M. P.; Aalami, H.: *Customer Behavior Based Demand Response Model*. IEEE Power Energy Society General Meeting, 2012
- [122] Eghbal, M.; Saha, T. K.; Mahmoudi-Kohan, N.: *Utilizing Demand Response Programs in Day Ahead Generation Scheduling for Micro-Grids with Renewable Sources*. IEEE PES Innovative Smart Grid Technologies Asia (ISGT), 2011
- [123] Dorini, G.; Pinson, P.; Madsen, H.: *Chance-Constrained Optimization of Demand Response to Price Signals*. IEEE Transactions on Smart Grid, Vol.4, No.4, pp. 2072–2080, 2013
- [124] Chen, Z.; Wu, L.; Fu, Y.: *Real-Time Price-Based Demand Response Management for Residential Appliances via Stochastic Optimization and Robust Optimization*. IEEE Transactions on Smart Grid, Vol.3, No.4, pp. 1822–1831, 2012
- [125] Maharjan, S.; Zhu, Q.; Zhang, Y.; Gjessing, S.; Basar, T.: *Dependable Demand Response Management in the Smart Grid: A Stackelberg Game Approach*. IEEE Transactions on Smart Grid, Vol. 4, No. 1, pp. 120–132, 2013
- [126] Li, S.; Zhang, D.; Roget, A. B.; O’Neill, Z.: *Integrating Home Energy Simulation and Dynamic Electricity Price for Demand Response Study*. IEEE Transactions on Smart Grid, Vol. 5, No. 2, pp. 779–788, 2014
- [127] Esther, B. P.; Kumar, K. S.: *A survey on residential Demand Side Management architecture, approaches, optimization models and methods*. Renewable and Sustainable Energy Reviews, Vol. 59, pp. 342–351, 2016
- [128] Vardakas, J. S.; Zorba, N.; Verikoukis, C. V.: *A Survey on Demand Response Programs in Smart Grids: Pricing Methods and Optimization Algorithms*. IEEE Communication Surveys and Tutorials Vol. 17, No. 1, pp. 152 – 178, 2015
- [129] Gomes, A.; Antunes, C. H.; Martins, A. G.: *Physically-based load demand models for assessing electric load control actions*. IEEE PowerTech, Bucharest, 2009
- [130] Molina-García, A.; Kessler, M.; Fuentes, J. A.; GómezLázaro, E.: *Probabilistic Characterization of Thermostatically Controlled Loads to Model the Impact of Demand Response Programs*. IEEE Transactions on Power Systems, Vol. 26, No. 1, pp. 241 – 251, 2011

- [131] Shao, S.; Pipattanasomporn, M.; Rahman, S.: *Development of physical-based demand response-enabled residential load models*. IEEE Transactions on Power Systems, Vol. 28, No.2, pp. 607–614, 2012
- [132] Kumar Nunna, H. S. V. S.; Doolla, S.: *Energy management in microgrids using demand response and distributed storage-A multi-agent approach*. IEEE Transactions on Power Delivery, Vol. 28, No. 2, pp. 939–947, 2013
- [133] Wang, Z.; Paranjape, R.: *Optimal Residential Demand Response for Multiple Heterogeneous Homes With Real-Time Price Prediction in a Multiagent Framework*. IEEE Transactions on Smart Grid, Vol. 8, No. 3, pp. 1173–1184, 2017
- [134] Li H. A.; Nair, N.-K. C.: *Multi-Agent Systems and Demand Response: A Systematic Review*. Power Engineering Conference (AUPEC), Wollongong, Australia, 2015
- [135] Benítez, I.; Quijano, A.; Díez, J.-L.; Delgado, I.: *Dynamic clustering segmentation applied to load profiles of energy consumption from Spanish customers*. International Journal of Electrical Power & Energy Systems Vol.55, pp. 437–448, 2014
- [136] Wijaya, T. K.; Vasirani, M.; Aberer, K.: *When Bias Matters: An Economic Assessment of Demand Response Baselines for Residential Customers*. IEEE Transactions on Smart Grid, Vol. 5, No.4, pp. 1755–1763, 2014
- [137] Claessens, B. J.; Vandael, S.; Ruelens, F.; Hommelberg, M.: *Self-learning Demand Side Management for a Heterogeneous Cluster of Devices with Binary Control Actions*. IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), Berlin, 2012
- [138] Arteconi, A.; Hewitt, N.J.; Polonara, F.: *Domestic demand-side management (DSM): Role of heat pumps and thermal energy storage (TES) systems*. Applied Thermal Engineering, Vol. 51, No. 1–2, pp. 155–165, 2013
- [139] Waczowicz, S.: *Konzept zur datengetriebenen Analyse und Modellierung des preisbeeinflussten Verbrauchsverhaltens*. Dissertation, Karlsruher Institut für Technologie (KIT), Fakultät für Maschinenbau, 2018
- [140] Konotop, I.; Waczowicz, S.; Klaiber, S.; Bretschneider, P.; Mikut, R.; Westermann, D.: *Investigation and Mathematical Modelling of the Impact of Incentive Signals to Consumers on their Consumption, Load Forecast and Network Operation*. IET Generation, Transmission & Distribution, Vol.10, pp. 2138–2146, 2016
- [141] Shi, H.; Xu, M.; Li, R.: *Deep learning for household load forecasting—a novel pooling deep RNN*. IEEE Transactions on Smart Grid, in press. DOI: 10.1109/TSG.2017.2686012, 2017
- [142] Almalag, A.; Edwards, G.: *A Review of Deep Learning Methods Applied on Load Forecasting*. IEEE International Conference on Machine Learning and Applications (ICMLA) 2017, 2017
- [143] Khosravi, A.; Nahavandi, S.: *Load Forecasting Using Interval Type-2 Fuzzy Logic Systems: Optimal Type Reduction*. IEEE Transactions on Industrial Informatics, Vol.10, Iss.2, pp.1055 – 1063, 2014
- [144] Coelho, V. N.; Coelho, I. M.; Coelho, B. N.; Reis, A. J. R.; Enayatifar, R.; Souza, M. J. F.; Guimarães, F. G.: *A self-adaptive evolutionary fuzzy model for load forecasting problems on smart grid environment*. Applied Energy, Vol. 169, pp. 567–584, 2016
- [145] Steurer, M.: *Analyse von Demand Side Integration im Hinblick auf eine effiziente und umweltfreundliche Energieversorgung*. Dissertation, Institut für Energiewirtschaft und Rationelle Energieanwendung der Universität Stuttgart, 2017
- [146] Deutsche Energie-Agentur GmbH (dena): *dena-Netzflexstudie - Optimierter Einsatz von Speichern für Netz- und Marktanwendungen in der Stromversorgung*. Teil 1: Ergebniszusammenfassung der Projektsteuergruppe, Stand: 03/2017

- [147] Agora – Energiewende: *Stromspeicher in der Energiewende - Untersuchung zum Bedarf an neuen Stromspeichern in Deutschland für den Erzeugungsausgleich, Systemdienstleistungen und im Verteilnetz*. Studie im Auftrag von Agora Energiewende, 2014
- [148] Pape, C.; Gerhardt, N.; Härtel, P.; Scholz, A; Schwinn, R.; Drees, T. et al. *Roadmap Speicher. Bestimmung des Speicherbedarfs in Deutschland im europäischen Kontext und Ableitung von technisch-ökonomischen sowie rechtlichen Handlungsempfehlungen für die Speicherförderung*. Endbericht, Fraunhofer IWES; IAEW; Stiftung Umweltenergierecht, 2014
- [149] Naumann, S.; Klaiber, S.; Kummerow, A.; Bretschneider, P.: *Simulation of Coordinated Market Grid Operations considering Uncertainties*, Innovative Smart Grid Technologies Conference (ISGT) Europe, Sarajevo, Bosnia and Herzegovina, 2018
- [150] Klaiber, S.; Bretschneider, P.; Waczowicz, S.; Mikut, R.; Konotop, I and Westermann, D.: *Extended Method to Forecast Price Elastic Consumption Behaviour*, Energy Science Technology Kongress, Karlsruhe, 2015
- [151] González Ordiano, J. Á.; Waczowicz, S.; Hagenmeyer, V. & Mikut, R.: *Energy Forecasting Tools and Services*, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery 2018, Vol.8, Iss.2, e1235, 2018
- [152] Heuck, K.; Dettmann, K.-D.; Schulz, D.: *Elektrische Energieversorgung*, 8. Auflage, Springer Fachmedien Wiesbaden GmbH, 2010
- [153] Richtlinie (EU) 2018/2002 des Europäischen Parlaments und des Rates vom 11. Dezember 2018 zur Änderung der Richtlinie 2012/27/EU zur Energieeffizienz, 2018

Anhang

Anhang A: Methoden der Datenanalyse

Beschreibung	Quelle
Visualisierung <p>Bei der Zeitreihenanalyse ist die Visualisierung von Daten ein etabliertes Werkzeug, um einen ersten Eindruck zu gewinnen und erste Eigenschaften zu identifizieren. Das Ziel der Visualisierung ist häufig eine Abbildung (Projektion) eines Datensatzes A auf einen Datensatz B, sodass die wesentlichen Eigenschaften von A besser zu erkennen sind. Die Visualisierung dient häufig als Grundlage weiter Untersuchungen.</p>	
<u>Histogramm (Häufigkeitsverteilung)</u> <ul style="list-style-type: none"> Beschreibung von absoluter oder relativer Häufigkeitsverteilung von Merkmalen in definierten Klassenbreiten 	[82], [83], [84], [92]
<u>Torten- und Balkendiagramme</u>	[92]
<u>Punktwolke/ x-y-Kennlinie</u> <ul style="list-style-type: none"> Darstellung von Wertepaaren in ein Koordinatensystem Aufschluss über Wertebereich, funktionalen Zusammenhang und Streuung in den Wertepaaren <u>Scatter-Plot (Streudiagramm)</u> <ul style="list-style-type: none"> Graphische Gegenüberstellung mehrerer Variablen 	[83], [92]
<u>Box-Plot/ Box-Whisker-Plot</u> <ul style="list-style-type: none"> Kompakte Häufigkeitsdarstellung von Merkmalen über die Parameter Median (50% aller Werte), unteres/oberes Quartil ($\pm\sigma$), Minimalwert und Maximalwert 	[82], [83], [92]
<u>Q-Q-Plot (Quantil-Quantil Plot)</u> <ul style="list-style-type: none"> Grafischer Vergleich, ob zwei Variablen aus einer Grundgesamtheit mit der gleichen Verteilung stammen 	[92]
Parameterauswertung	
<u>Lage- und Streuungsparameter</u> <ul style="list-style-type: none"> Beschreibung wesentlicher Informationen über die Häufigkeitsverteilung von Merkmalen über mathematische Kennwerte Beispiele: Mittelwert, Median, Modus bzw. Modalwert, Varianz, Standardabweichung, Maximum, Minimum, Spannweite, Quantile etc. 	[82], [84], [92]

<u>Konzentrationsmaße</u> <ul style="list-style-type: none">Konzentration von Merkmalsbeiträgen auf Merkmalsträger (Gleichverteilung = keine Konzentration)Beispiele: Gini-Koeffizient, Lorenzkurve	[82], [92]
<u>Rangkorrelationskoeffizient</u> <ul style="list-style-type: none">Beschreibung der Stärke des Zusammenhangs zwischen rangtransformierten Werten (Positionen der nach ihrer Größe geordneten, metrischen Daten) bzw. ordinalskalierten DatenBeispiele: Spearmans Rangkorrelationskoeffizient, Korrelationskoeffizient nach Kendalls	[82], [92]
<u>Kontingenzkoeffizient</u> <ul style="list-style-type: none">Beschreibung der Stärke des Zusammenhangs zwischen metrischen oder ordinalen VariablenVergleich zwischen den Häufigkeiten der Merkmale und den Häufigkeiten der Merkmale, die bei vollständiger Unabhängigkeit zu erwarten sind	[30], [82], [92]
Varianzanalyse	
<u>Einfaktorielle Varianzanalyse</u> <ul style="list-style-type: none">Erklärung der Varianz metrischer Merkmale durch eine unabhängige Variable	[30], [82], [84], [85]
<u>Multifaktorielle Varianzanalyse</u> <ul style="list-style-type: none">Erklärung der Varianz metrischer Merkmale durch mehrere unabhängige Variablen sowie kombinierten Einflüssen	
Regressionsanalyse	
<u>Lineare Regression</u> <ul style="list-style-type: none">Modellbasierte Schätzung des linearen Zusammenhangs zwischen einer abhängigen und ein oder mehreren (voneinander) unabhängigen VariablenÜblicherweise Schätzung der Modellparameter über Kleinste-Quadrate-Methode oder Maximum-Likelihood-Methode	[30], [42], [45], [82], [84], [91], [92]
<u>Nichtlineare Regression</u> <ul style="list-style-type: none">Modellbasierte Schätzung des nichtlinearen Zusammenhangs zwischen einer abhängigen und ein oder mehreren (voneinander) unabhängigen VariablenLinearisierung des gesuchten Zusammenhangs mittels geeigneter Merkmalstransformation	[42], [82], [84], [86], [92]

Korrelationsanalyse (statisch)	
<u>Empirischer-Korrelationskoeffizient</u> <ul style="list-style-type: none"> • Maßzahl für die Stärke des linearen Zusammenhangs zwischen zwei Variablen 	[45], [82], [84], [92]
<u>Multipler Korrelationskoeffizient</u> <ul style="list-style-type: none"> • Beschreibung der Stärke des linearen Zusammenhangs zwischen mehreren Variablen 	[45], [92]
Korrelationsanalyse dynamisch	
<u>Autokorrelationsfunktion (AKF)</u> <ul style="list-style-type: none"> • Beschreibung des linearen Zusammenhangs zwischen den Beobachtungswerten einer Variable unter Verschiebung des zeitlichen Abstands zwischen den Werten 	[14], [45]
<u>partielle Autokorrelationsfunktion (PAKF)</u> <ul style="list-style-type: none"> • Beschreibung des linearen Zusammenhangs zwischen den Beobachtungswerten einer Variable unter Verschiebung des zeitlichen Abstands zwischen den Werten und unter Ausschaltung des Einflusses der dazwischenliegenden Werten 	[14], [45]
<u>Kreuzkorrelationsfunktion (KKF)</u> <ul style="list-style-type: none"> • Beschreibung des linearen Zusammenhangs zwischen den Beobachtungswerten zweier Variablen unter Verschiebung des zeitlichen Abstands zwischen den Werten 	[14], [45]
<u>Inverse Autokorrelationsfunktion</u> <ul style="list-style-type: none"> • Exakte Dualität zur Autokorrelationsfunktion • IAKF eines ARMA[p,q]-Prozesses entspricht der AKF eines ARMA[p,q]-Prozesses 	[45]

Transformation durch Filterverfahren

Ein häufiges Interesse bei der Analyse ist die Glättung von Zeitreihenwerten. Dabei werden irreguläre Schwankungen durch lokale Approximationen eliminiert. Beispielsweise können bei der Beseitigung von fehlerhaften Werten (Ausreißern) oder der Beschreibung grundlegender Signalanteile (Polynome niedrigen Grades) Filterverfahren zur Anwendung kommen.

Gleitende Durchschnitte

[42], [45]

- Identifikation langzeitlicher oder periodischer Signalkomponenten durch Mittelung der Daten (Signalglättung) über verschiedene Fensterbreiten
- Unterscheidung nach der Art der Fensterbildung
 - zentral gleitend
 - vorwärts gleitend
 - rückwärts gleitend
- Unterscheidung nach der Anzahl der zu mittelnden Datenpunkte
- zusätzliche Gewichtung der Datenpunkte durch Bildung gewichteter, gleitender Durchschnitte

Differenzenfilter

[45]

- Identifikation polynomialer Signalkomponenten (Trendanteil) durch Bildung der Differenz zwischen jeweils zwei aufeinanderfolgenden Datenpunkten
- Ordnung des Differenzenfilters entspricht dem Grad des Trendpolynoms

Exponentielle Glättung

[42], [45]

- Entspricht exponentiell gewichteter Summe der vergangenen Werte
- Vergangenheitswerte werden mit abnehmender Aktualität abnehmend gewichtet

Box-Cox-Transformation

[45], [84], [87]

- Varianzstabilisierende Transformation
- Potenztransformation der Daten, sodass eine Monotonisierung des Verlaufs erreicht wird

Spektralanalyse

Eine häufige und typische Eigenschaft von empirischen Zeitreihen ist ein mehr oder minder ausgeprägtes zyklisches Verhalten. Bei zyklisch wiederkehrenden Ereignissen lassen sich Perioden oder Frequenzen identifizieren, welche die Länge von Zyklen angeben. Mit den Methoden der Spektralanalyse soll die periodische Charakteristik identifiziert sichtbar gemacht werden.

Periodogramm

[90], [45]

- Funktion der Frequenz
- Maß für Stärke bzw. Intensität harmonischer Wellen von Frequenzen in einer Zeitreihe

<u>Fourier-Transformation</u> <ul style="list-style-type: none"> • Zerlegung von Signalen in Spektrum • Überführung von Signalen im Zeitbereich (Zeitbereich mit Zuordnung von Zeitpunkt und Wert) in Signal im Frequenzbereich (Frequenzbereich mit Zuordnung Frequenzanteil und Amplitude/Phase) 	[89], [90], [45]
<u>Leistungsdichtespektrum</u> <ul style="list-style-type: none"> • Verteilung der Signalleistung im Frequenzbereich <u>Autoleistungsdichtespektrum</u> <ul style="list-style-type: none"> • Identifikation der dominierenden Frequenzanteile über Fourier-Transformation des Signals und Berechnung der spektralen Leistungsdichte <u>Kreuzleistungsdichtespektrum</u> <ul style="list-style-type: none"> • Identifikation der gemeinsamen, dominierenden Frequenzanteile zweier Signale über Fourier-Transformation 	[15], [88], [90]
<u>Wavelet-Analyse</u> <ul style="list-style-type: none"> • Im Gegensatz zur Fourier-Transformation lokale Frequenzanalyse des Signals durch Bildung von Wavelets • Identifikation der dominierenden Frequenzanteile in Abhängigkeit von der jeweiligen Zeitdauer der Frequenzkomponente 	[88], [89], [90]
Klassifikation Bei der Klassifikation findet mit Hilfe einer Vorschrift bzw. eines Algorithmus eine Einteilung von Objekte anhand bestimmter Merkmale statt.	
<u>Hauptkomponentenanalyse (Principle Component Analysis)</u> <ul style="list-style-type: none"> • Überführung des Signals auf Basis eines mehrdimensionalen Merkmalsraums mittels der Hauptachsentransformation in mehrere Hauptkomponenten • Hauptkomponenten sind Linearkombinationen der Daten und entsprechend den Eigenvektoren der Kovarianzmatrix des Datensatzes • Dekorrelation des Datensatzes • Projektierung der Daten in Form von Linearkombinationen in einen niederdimensionalen Merkmalsraum aufgespannt durch die Hauptachsen 	[82], [83], [84], [86], [91]
<u>Diskriminanzanalyse</u> <ul style="list-style-type: none"> • Klassifizierung metrischer Daten auf Basis einer a priori bekannten Klassenzugehörigkeit festgelegt durch die Distanz zwischen den Verteilungen der einzelnen Klassen 	[30], [42], [83], [86], [91]
<u>Unabhängigkeitsanalyse (Independent Component Analysis)</u> <ul style="list-style-type: none"> • Berechnung bzw. Extraktion (statistisch) unabhängiger Komponenten eines nicht-normalverteilten Datensatzes • Im Gegensatz zur Hauptkomponentenanalyse Dekorrelierung des Datensatzes und Erzeugung statistischer Unabhängigkeit 	[86]

<u>Faktorenanalyse</u> <ul style="list-style-type: none"> • Identifikation von voneinander statistisch unabhängigen Einflussfaktoren aus einer Vielzahl möglicher Variablen • Modellbasierte Repräsentation der Korrelationszusammenhänge eines mehrdimensionalen Merkmalraums durch Faktoren • Zusammenfassung korrelierter Merkmale zu Merkmalskomplexen 	[30], [82], [83], [86], [91]
<u>Bayes-Klassifikation</u> <ul style="list-style-type: none"> • Statistische Klassifizierung metrischer Daten auf Basis einer a priori bekannten Klassenzugehörigkeit in Form von Wahrscheinlichkeiten • Bayes Klassifikator wählt diejenige Klasse mit der maximalen Wahrscheinlichkeit aus unter Berücksichtigung der geschätzten Verteilung der Merkmale 	[84], [86], [89]
<u>k-nearest-neighbor-Klassifikation</u> <ul style="list-style-type: none"> • Klassifizierung metrischer Daten nach der Anzahl seiner k nächstgelegener Nachbarn, sodass eine Klasse durch mehrere Repräsentanten vertreten ist • Klassenzuordnung erfolgt auf Basis des am häufigsten anzutreffenden Repräsentanten • Verwendungen eines geeigneten Abstandsmaßes 	[86], [89]
<u>Support-Vektor-Maschinen (SVM)</u> <ul style="list-style-type: none"> • Klassifizierung metrischer Daten durch Bestimmung einer optimalen Trennebene, insbesondere zur Separation nicht linear-trennbarer Daten • Transformation der Daten in einen höherdimensionalen Merkmalsraum mittels Kernel-Funktionen (z.B. hyperbolischer Funktionen, Radiale Basisfunktion etc.) • Anlernen der SVM über Lerndatensätze nötig 	[86], [89]
<u>Entscheidungsbäume</u> <ul style="list-style-type: none"> • Klassifikator mit hierarchischer Struktur • Darstellung entspricht Graph mit Knoten und Zweigen mit Funktion zur Bestimmung der Ausgangsfunktion und Merkmal zur weiteren Auftrennung. • Mehrstufiger Anwendungsprozess zur Berechnung einer Ausgangsgröße anhand seiner Merkmale (Prüfung der einzelnen Merkmale in der Reihenfolge ihrer Wichtigkeit) 	[86], [89]

Clusterverfahren (Allgemein)

Im Gegensatz zur Klassifikation liegen bei Clusterverfahren in der Entwurfsphase keine Informationen über die Klassenzugehörigkeit der Daten vor (kein Klassen-Vorwissen). Es sollen neue Gruppen in Daten identifiziert werden und nicht wie bei der Klassifikation Daten bestehender Klassen zugeordnet werden. Somit sind bei Clusterverfahren neben der Beschreibung der unterschiedlichen Cluster auch die entsprechenden Ausgangsgrößen zu ermitteln.

Hierarchische Clusterverfahren

<ul style="list-style-type: none"> • Distanzbasierte Verfahren zur Clusteranalyse mit hierarchischem Aufbau • Erzeugung mehrerer, aufeinander aufbauenden Partitionierungen pro Datensatz <ul style="list-style-type: none"> ○ Agglomerativ („Bottom-up-Prinzip“): jeder Datenpunkt wird zunächst einem Cluster zugeordnet und die Cluster schrittweise vermengt bis alle Datenpunkte in einem Cluster zugehören ○ Divisiv („Top-Down-Prinzip“): Umkehrung von agglomerativer Clustering 	[30], [82], [86], [91]
<u>Single-Linkage-Verfahren</u> <ul style="list-style-type: none"> • Bestimmung der Ähnlichkeit zwischen Clustergruppen auf Basis der kleinsten Distanz zwischen den Datenpunkten 	[91]
<u>Complete-Linkage-Verfahren</u> <ul style="list-style-type: none"> • Bestimmung der Ähnlichkeit zwischen Clustergruppen auf Basis der größten Distanz zwischen den Datenpunkten 	[91]
<u>Average-Linkage-Verfahren</u> <ul style="list-style-type: none"> • Bestimmung der Ähnlichkeit zwischen Clustergruppen auf Basis der mittleren Distanz zwischen den Datenpunkten 	[91]
<u>Ward-Verfahren</u> <ul style="list-style-type: none"> • Bestimmung der Ähnlichkeit zwischen Clustergruppen auf Basis der Zunahme der Varianz bei Vereinigung der Clustergruppen 	[91]

Partitionierende Clusterverfahren

<u>k-means-Algorithmus (Minimum-Distanz-Verfahren)</u> <ul style="list-style-type: none"> • Iterative Verschiebung der Mittelpunkte der Clusterzentren (Centroiden) bis deren Abstände zu den Beobachtungswerten im Datenraum minimal werden • Einsatz etablierter Distanzmaße wie Mahalanobis-Distanz, euklidische Distanz etc. • Beginn der Berechnung mit einer zufälligen Anfangspartitionierung der Daten bei einer fest vorgegeben Clusteranzahl 	[86], [89]
---	------------

<u>Fuzzy-C-means Algorithmus</u> <ul style="list-style-type: none"> • Erweiterung des k-means-Algorithmus durch Verwendung von Fuzzy-Methoden • Im Gegensatz zu „harten“ Clustermethoden Zuordnung der Datenpunkte zu mehreren Clustergruppen mittels spezifischer Zuordnungsfunktionen • Im Ergebnis keine strenge Partitionierung der Daten 	[86], [89]
<u>Self-organized maps (Kohonen-Karte)</u> <ul style="list-style-type: none"> • Anwendung neuronaler Netzen für Clusteranalyse mittels unüberwachtem Lernverfahren, d.h. ohne Vorgabe spezieller Ausgabemuster • Clusteranzahl im Vorfeld festgelegt durch Anzahl der Neuronen des Netzes • Verwendung von Nachbarschaftsfunktionen zur Charakterisierung der Stärke der Zusammengehörigkeit zwischen den Neuronen 	[93]
Signifikanztests (Allgemein)	
<p>Signifikanztests dienen der Entscheidungsfindung durch Überprüfung von zwei sich logisch ausschließenden Hypothesen (Nullhypothese H_0 und Gegenhypothese H_1). Es gilt dabei das Prinzip der Falsifikation bei dem H_1 durch Ausschließen von H_0 akzeptiert wird, wenn die Irrtumswahrscheinlichkeit des Tests (p-Wert) kleiner ist als das zugrundeliegende Signifikanzniveau (α). Allgemein können folgende Hypothesentests unterschieden werden:</p> <ul style="list-style-type: none"> • Einseitig: gerichtete Überprüfung auf Über- oder Unterschreiten eines zulässigen Grenzwerts • Zweiseitig: ungerichtete Überprüfung der Über- und Unterschreiten eines zulässigen Grenzwerts • eine Stichprobe, mehrere voneinander unabhängige Stichproben oder mehrere voneinander abhängige Stichproben • Parametertests zur Überprüfung bestimmter Parameter einer Verteilung • Anpassungstests zur Überprüfung der Art der Verteilung • Parametrisch: Untersuchung eines Verteilungsparameters • Nicht-parametrisch: Untersuchung der gesamten Verteilung 	[82], [84], [86], [88], [92]
Signifikanztests (Parametertests) <p>Parametertests sind statistische Testverfahren zur Prüfung eines oder mehrerer unbekannter Parameter in einer Verteilung einer Grundgesamtheit bzw. Zufallsgröße. Die Verteilung wird dabei als bekannt vorausgesetzt.</p>	
<u>Einstichproben-t-Test</u> <ul style="list-style-type: none"> • Statistischer Test anhand einer Stichprobe zur Prüfung, ob der Mittelwert einer Grundgesamtheit sich von einem vorgegebenen Sollwert unterscheidet • Normalverteilungsannahme der Daten der Stichprobe bzw. genügend großer Stichprobenumfang 	[82], [92]
<u>Zweistichproben-t-Test</u> <ul style="list-style-type: none"> • Statistischer Test zweier Stichproben zur Prüfung, wie sich Mittelwerte zweier Grundgesamtheiten zueinander verhalten • Normalverteilungsannahme der Daten der Stichproben bzw. genügend großer Stichprobenumfänge 	[84], [86], [92]

<u>Wilcoxon-Vorzeichen-Rangsummen-Test</u> <ul style="list-style-type: none"> • Nicht parametrischer statistischer Test zur Überprüfung, ob die Differenzen zweier abhängiger Stichproben symmetrisch um den Median verteilt sind • Alternative für t-Test mit Beachtung der Größe und der Richtung (Vorzeichen) der Differenzen zwischen den abhängigen Stichproben 	[86], [92]
<u>Welch-Test</u> <ul style="list-style-type: none"> • Variante des Zweistichproben-t-Test • Dass beide Stichproben aus Grundgesamtheiten mit gleicher Varianz entstammen, wird nicht vorausgesetzt 	[92]
<u>Wilcoxon-Rangsummen-Test</u> <ul style="list-style-type: none"> • Nicht-parametrischer statistischer Test zur Überprüfung der Signifikanz der Übereinstimmung der Verteilung zweier unabhängiger Stichproben bezüglich ihrer Lage • Vergleich der Stichproben anhand ihrer summierten Rangordnungen 	[86], [92]
<u>F-Test</u> <ul style="list-style-type: none"> • Statistische Test zur Prüfung der Gleichheit der Varianzen zweier Stichproben • Normalverteilungsannahme der Daten der Stichproben 	[88], [92]
<u>Durbin-Watson-Test</u> <ul style="list-style-type: none"> • statistischer Test auf Autokorrelation 1. Ordnung 	[45]
<u>Chi-Quadrat-Streuungstest</u> <ul style="list-style-type: none"> • Statistischer Test zur Prüfung der Varianz einer Stichprobe bei unbekanntem Mittelwert • Nur für normalverteilte Daten • Ein- oder zweiseitig 	[82]
<u>Periodogrammtest</u> <ul style="list-style-type: none"> • Verteilungsunabhängiger Nullhypothesentest, bei dem eine zweiseitige Prüfung des kumulierten Periodogramms gegenüber einem $(1-\alpha)$-Quantil vorgenommen wird • Verwendung für den Nachweis für die Eigenschaft von weißem Rauschen 	[45]
<u>Z-Test</u> <ul style="list-style-type: none"> • Statistischer Test zur Prüfung auf Normalverteilung anhand des Mittelwerts einer Stichprobe bei bekannter Standardabweichung • Normalverteilungsannahme der Daten der Stichproben bzw. genügend großer Stichprobenumfänge • Ein- oder zweiseitig 	[82]

Signifikanztests (Anpassungstests)

Anpassungstest oder Verteilungstests sind statistische Testverfahren zur Prüfung einer Verteilungshypothese. Es wird geprüft, ob einer Stichprobe aus einer unbekannten Verteilung mit einer bestimmten Verteilungsfunktion entstammt.

Chi-Quadrat-Anpassungstest

[82], [92]

- Statistischer Test zur Prüfung der Verteilung einer Stichprobe

Kolmogoroff-Smirnoff-Test (KS-Test)

[88], [92]

- Statistischer Test zur Prüfung der Verteilungen zweier Stichproben, ob die Stichproben die gleiche Verteilung besitzen (bzw. KS-Anpassungstest, ob eine Stichprobe einer bekannte zuvor angenommen Verteilung entspricht)

Anderson-Darling-Test

[92]

- Statistische Test zur Prüfung, ob die Verteilung einer Stichprobe von einer vorgegebenen Verteilung abweicht
- Modifikation des KS-Tests, bei dem die Abweichung vom Verteilungsmodell an den Rändern der Verteilung eher berücksichtigt wird als mit dem KS-Test

Shapiro-Wilk-Test

[92]

- Statistischer Test zur Prüfung einer Stichprobe auf Normalverteilung
- auch für kleine Stichprobenumfänge geeignet

Signifikanztests (Unabhängigkeitstests)

Unabhängigkeitstests sind statistische Testverfahren zur Prüfung der Abhängigkeit oder Unabhängigkeit verschiedener Merkmale oder Datenreihen.

Chi-Quadrat-Unabhängigkeitstest

[82], [92]

- Statistischer Test zur Prüfung der Unabhängigkeit zweier Stichproben auf Basis bedingter, relativer Häufigkeiten
- Für beliebig skalierte Daten

Spearman's Rangkorrelationstest

[82], [92]

- Überprüfung der Unabhängigkeit zweier Merkmale auf Basis ihrer Rangkorrelation
- Insbesondere für nicht-normalverteilte Daten und großer Stichprobenumfang

Fisher-Test

[88], [92]

- Statistischer Test zur Prüfung auf Unabhängigkeit von Häufigkeiten in einer 2x2 Kontingenztafel
- Alternative zum Chi-Quadrat-Test und geeignet für geringe Anzahl von Beobachtungen

Vorhersagbarkeit

Bei der Erstellung eines Modells zur Beschreibung oder Vorhersage eines Prozesses ist eine wesentliche Fragestellung, ob die zugehörigen Zeitreihen Informationen einhalten, welche die Erstellung eines Modells überhaupt ermöglichen bzw. ob der Prozess überhaupt vorhersagbar ist. Die Vorhersagbarkeit ist ein Maß für die Abhängigkeit zwischen Variablen, wobei zwischen linearer und nichtlinearer Abhängigkeit unterschieden wird. Die Vorhersagbarkeit basiert auf der Berechnung der Entropie aus der Informationstheorie.

Nichtlineare Vorhersagbarkeit

[94]

- Maßzahl aus der Informationstheorie als Maß für die gegenseitige Information zweier Zufallsvariablen
- Beschreibung der vollständigen Abhängigkeit (sowohl die lineare als auch die nichtlineare) zweier Zufallsvariablen

Lineare Vorhersagbarkeit

[94]

- Maßzahl der gegenseitigen Information zweier Zufallsvariablen basierend auf dem Korrelationskoeffizienten

Bedingte Vorhersagbarkeit

[94]

- Methode zur Prüfung, ob die Hinzunahme einer zusätzlichen Eingangsgröße die Vorhersagbarkeit verbessert
- Basierend auf der Maßzahl der Vorhersagbarkeit

Punktschätzung

Als wesentliche Aufgabe der induktiven Statistik wird mit der Punktschätzung eine Schätzfunktion zur Bestimmung von Verteilungsparametern von Merkmalen wie Mittelwert, Varianz oder Schiefe. Wichtige Eigenschaften der Punktschätzung, anhand derer die Qualität beurteilt werden kann, sind Erwartungstreue, Konsistenz und Effizienz. Folgende Methoden der Punktschätzung werden unterschieden:

[45], [82], [92]

- Momentenmethode: Schätzung der Momente der Verteilung einer Grundgesamtheit mit entsprechenden Momenten der Stichprobe
- Maximum-Likelihood-Methode: Schätzung eines unbekannten Parameters, welcher angesichts des Stichprobenergebnisses am wahrscheinlichsten ist (d.h. die Wahrscheinlichkeitsfunktion maximal wird)
- Methode der kleinsten Quadrate: Schätzung des Mittelwertes, von der die Summe der quadrierten Differenzen zum Stichprobenmittelwert minimal ist (Minimierung der Fehlervarianz mit quadratischen Bewertung der Fehler)

Bereichsschätzung

Bei der Bereichsschätzung werden im Gegensatz zur Punktschätzung die Grenzen bestimmt, innerhalb derer die wahren Verteilungsparameter der Merkmale mit einer gewissen Wahrscheinlichkeit liegen. So werden Konfidenzintervalle der gesuchten Verteilungsparameter auf Basis vordefinierter Konfidenzniveaus ermittelt.

[45], [82], [92]

Anhang B: Parametervorgaben für synthetische Zeitreihen

Zur Bereitstellung der Datengrundlage für die Untersuchungen im Rahmen der vorliegenden Arbeit wurde der im Abschnitt 5.1.1 vorgestellte Zeitreihengenerator für Energiezeitreihen entwickelt. Der für die Evaluierung des Lösungskonzeptes verwendete Datensatz wurde mit Hilfe des Zeitreihengenerators erzeugt. Der synthetische Datensatz kann der zu untersuchenden Prozessklasse aufgrund dessen spezifischer Eigenschaften zugeordnet werden. Die spezifischen Eigenschaften wurden in Abschnitt 5.3.1.1 mit Hilfe der durchgeführten Zeitreihenanalyse nachgewiesen. Für die Erzeugung des synthetischen Datensatzes werden Zeitreihen mit Hilfe des in Abschnitt 2.1.5 vorgestellten Komponentenmodells interpretiert. Die mathematische Formulierung der angewendeten Modellansätze zur Beschreibung der einzelnen Komponenten wird in der Tabelle 5.1 aufgeführt. Für die Zuordnung einer synthetisch generierten Zeitreihe müssen die spezifischen Modellparameter und die Modellstruktur je Komponente vorgegeben werden. Für einen möglichst realitätsnahen Beispieldatensatz entsprechend der angenommenen Prozessklasse sollen dabei folgende charakteristische Eigenschaften für $y_V[k]$ simuliert werden:

- Unterschiedliche Verbrauchsmuster (Tagesmuster) durch kalenderabhängige (bzw. wochentagabhängige) Standardlastprofile,
- Unterschiedliche Lastniveaus in Abhängigkeit vom Typtag (Wochenrhythmus),
- Nichtlinearer Jahrestrend (saisonale Effekte),
- Stochastischer normalverteilter Rauschanteil.

Die beeinflusste Zeitreihenkomponente $y_R[k]$ soll dabei folgende charakteristische Eigenschaften aufweisen:

- Zeitvariante Preiselastizität in Abhängigkeit von Uhrzeit, Typtag und Saison,
- Dynamische zeitversetzte Verbraucherreaktion durch Ausprägung von Eigen- und Kreuzpreiselastizität (Planungshorizont von einem Tag),
- Begrenztes Lastverschiebungspotenzial.

Für die Vorgabe der Modellparameter zur Erzeugung der einzelnen Zeitreihenkomponenten wurden vorab entsprechende reale Lastzeitreihen im Rahmen von Zeitreihenanalysen im Hinblick auf eine Dekomposition nach dem Konzept des Komponentenmodells untersucht. Dabei wurden die Modellparameter der einzelnen Modelle der Zeitreihenkomponenten mittels Regression geschätzt und ausgewertet. Die für die Erzeugung des synthetischen Datensatzes vorgegebenen Modellparameter werden in der Tabelle B 1 aufgeführt. Diese entsprechen den in der vorab durchgeführten Analyse ermittelten Parameterrahmen.

Tabelle B 1

Zeitreihenkomponente	Ausprägungen	Modellparameter
Trendkomponente y_T $y_T[k] = a_0 + \sum_{i=1}^m a_i \cdot [k]^i$ mit: m – Ordnung des Modells a_0, a_i – Modellparameter	<ul style="list-style-type: none"> • Linear ($m = 1$) 	<ul style="list-style-type: none"> • $a = [0,9756 \quad 0,0000013922]$ (entspricht ca. 5 % Jahresanstieg)

Zeitreihenkomponente	Ausprägungen	Modellparameter
<p>Periodische Komponente y_P</p> $y_P[k] = \sum_{i=1}^m \left[a_i \cos \left(\omega_i[k] + \frac{\varphi_i}{100\% \cdot 2\pi} \right) \right]$ <p>mit: ω - Kreisfrequenz pro Frequenz a_i - Amplitude pro Frequenzanteil φ - Nullphasenverschiebung pro Frequenzanteil in %</p>	<ul style="list-style-type: none"> • Tageszyklus • Wochenzyklus • Jahreszyklus ($m = 3$) 	<ul style="list-style-type: none"> • $\omega =$ [0,0654 0,0093 0,002] • $a =$ [0,035 0,021 0,084] • $\varphi =$ [0 28,5714 - 0,8333]
<p>Stochastische Komponente y_S</p> $y_S[k] = \sum_{i=1}^p [a_i \cdot y[k-i]] + \varepsilon[k] + \sum_{i=1}^q b_i \cdot \varepsilon[k-i]$ <p>mit: ε - weißes Rauschen a_i, b_i - Modellparameter</p>	<ul style="list-style-type: none"> • ARMA-Modellansatz mit $p = 0$ und $q = 0$ • $\varepsilon \hat{=}$ weißes Rauschen mit Normalverteilung $\varepsilon \sim N(\mu, \sigma^2)$ 	<ul style="list-style-type: none"> • $\mu = 0$ • $\sigma^2 = 0,0016$
<p>Musterkomponente y_M</p> $y_M[k] = a_0 \cdot \left(a_1 \cdot SLP_H[k] + a_2 \cdot \frac{1}{7} \sum_{i=0}^6 [SLP_{G,i}[k]] + a_3 \frac{1}{2} \sum_{j=1}^2 SLP_{L,j}[k] \right)$ <p>mit: a_i - Modellparameter SLP_H - Zeitreihe mit ausgerollten Lastprofilen H0 $SLP_{G,i}$ - Zeitreihe mit ausgerollten Lastprofilen G0 bis G6 $SLP_{L,j}$ - Zeitreihe mit ausgerollten Lastprofile L1 und L2</p>	<ul style="list-style-type: none"> • Verwendung der Standardlastprofile des BDEW (H0, G0-G6, L1 und L2) • Berücksichtigung bundeseinheitlicher Feiertage 	<ul style="list-style-type: none"> • $a =$ [1,07 0,5 0,3 0,2]

Zeitreihenkomponente	Ausprägungen	Modellparameter
<p>Exogene Komponente (beeinflusste Zeitreihenkomponente) y_R</p> $y_R[k] = \sum_j^{96} \zeta_{i,j,c}[k] \cdot \left(\frac{\Delta p_{j,c}[k]}{p_{ref}[k]} \right) \cdot y_{ref}[k]$ <p>mit: $\zeta_{i,j,c}$ – Kreuzpreiselastizität in Abhängigkeit der Klasse c und des Uhrzeitindexes</p> <p>y_{ref} – Referenzverbrauch</p> <p>p_{ref} – Referenzpreis</p>	<ul style="list-style-type: none"> Individuelle Besetzung der Matrix Z_c in Abhängigkeit von $c = 1, \dots, 7$ Typtagen (Montag, Dienstag, Mittwoch, Donnerstag, Freitag, Samstag, Sonntag/Feiertag) 	<ul style="list-style-type: none"> Skalierter Preiseinfluss Individuelle Besetzung der Matrizen Z_c siehe Abbildung B 1
Stauchung/ Streckung und Skalierung	<ul style="list-style-type: none"> Stauchung oder Streckung der Gesamtzeitreihe 	<ul style="list-style-type: none"> Skalierung auf Jahresenergiewert von 200 MWh 10% Stauchung des Wertebereichs




Abbildung B 1 Heatmap - Darstellung der individuellen Besetzungen der Matrizen Z_c in Abhängigkeit von $c = 1, \dots, 7$ Typtagen




Abbildung B 2 Ausschnitt der beeinflussten Zeitreihe $y[k]$ über 14 Tage




Abbildung B 3 Ausschnitt der Trendkomponente $y_T[k]$ über 14 Tage




Abbildung B 4 Ausschnitt der periodischen Komponente $y_P[k]$ über 14 Tage




Abbildung B 5 Ausschnitt der stochastischen Komponente $y_S[k]$ über 14 Tage




Abbildung B 6 Ausschnitt der Musterkomponente $y_M[k]$ über 14 Tage




Abbildung B 7 Ausschnitt der beeinflussten Zeitreihenkomponente $y_R[k]$ über 14 Tage




Abbildung B 8 Ausschnitt der unbeeinflussten Zeitreihenkomponente $y_U[k]$ über 14 Tage

Anhang C: Analyse der Klassenkonfiguration

Synthetischer Datensatz

Mit der Interpretation der Abbildung C 1 kann auf die Klassenkonfiguration geschlossen werden. Die Lastzeitreihe wurde in Datenbeispiele lokaler Abschnitte bezüglich der Typtage und des Uhrzeitindex zerlegt. Es werden die sieben Wochentage als Typtagklassen unterschieden. Feiertage werden dabei der Klasse Sonntag zugeordnet. Bei der Abtastzeit von 15 Minuten werden jeweils $h = 1 \dots 96$ Uhrzeitindizes unterschieden. Mit der Zerlegung der Verbrauchszeitreihe resultieren 672 Datenbeispiele ($96 \text{ Uhrzeitindizes} * 7 \text{ Typtagklassen}$) als lokale Abschnitte. In der Abbildung C 1 wird die Verteilung jedes Datenbeispiels mit der Verteilung aller anderen Datenbeispiele verglichen. Dazu wird der Kolmogoroff-Smirnoff-Test (KS-Test) angewendet. Der KS-Test ist ein statistischer Test zur Prüfung der Verteilungen zweier Stichproben auf Übereinstimmung der Verteilungen. Der KS-Test prüft, ob zwei unabhängige Stichproben die gleiche Verteilung besitzen, wobei die zugrundeliegenden Variablen keiner Normalverteilung folgen müssen. Der KS-Test arbeitet verteilungsunabhängig. Der Test wird jeweils mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ und $\alpha = 1\%$ angewendet. Die weißen Bereiche in der Abbildung zeigen die Ergebnisse, bei denen der KS-Test in beiden Fällen negativ war, d.h. die Verteilungen der Datenbeispiele unterschiedlich sind. Die schwarzen Bereiche in der Abbildung zeigen die Ergebnisse, bei denen der KS-Test mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ positiv war, d.h. die Verteilung der Datenbeispiele identisch ist. Die orangenen Bereiche zeigen die positiven Ergebnisse des Tests bei einer Irrtumswahrscheinlichkeit von $\alpha = 1\%$. Für die Abbildung C 1 ergibt sich ein an der Hauptdiagonalen gespiegeltes symmetrisches Bild. Beim Vergleich der einzelnen Typtagklassen untereinander in den einzelnen Rechtecken (abgegrenzt durch die gestrichelten Linien) ist zu erkennen, dass in zahlreichen Rechtecken die (Neben)-Diagonale mit schwarze und oder orange Markierungen besetzt ist. Das bedeutet, dass beim Vergleich zweier Typtagklassen, Datenbeispiele mit dem gleichen Uhrzeitindex eine identische Verteilung aufweisen und folglich einer Klasse zugeordnet werden können. Beispiele mit derart besetzten Nebendiagonalen kommen nur beim Vergleich der Werkzeuge untereinander vor. Beim Vergleich der Samstags- und Sonntagsklasse mit den Werktagen ist keine besetzte Nebendiagonale auszumachen. Auch beim Vergleich der Samstagsklasse mit der Sonntagsklasse kommt keine besetzte Nebendiagonale vor. Folglich sind Samstags- und Sonntags- gesonderten Klassen zuzuordnen. Bei genauerer Betrachtung der einzelnen Rechtecke in der Abbildung C 1 sind allerdings nicht bei allen Vergleichen der Werkzeuge untereinander durchgängig besetzte Nebendiagonalen auszumachen. Ein Zusammenfassen aller Werkzeuge in eine Klasse ist daher nicht uneingeschränkt sinnvoll. Zusätzlich sind bei weiterer Betrachtung der einzelnen Rechtecke Markierungen abseits der Nebendiagonalen zu erkennen. Es ist also prinzipiell möglich, Datenbeispiele unterschiedliche Typtagklassen mit unterschiedlichen Uhrzeitindizes einer Klasse zuzuordnen, was eine Reduzierung der Parameteranzahl bei der Modellierung zur Folge hätte.




Abbildung C 1 Ermittlung der Klassenzuordnung für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung in Abhängigkeit von Typtagen und Uhrzeitindex $h = 1 \dots 96$ (15 Minutenwerte)

Um die Parameteranzahl bei der Modellierung zu reduzieren wird zusätzlich die Möglichkeit in Betracht gezogen, Datenbeispiele mit benachbarten Uhrzeitindizes in Blöcken zusammenzufassen. Dazu wurden in Abbildung C 2 die Datenbeispiele der selben Stunde zusammengefasst, was die Parameteranzahl bei der Modellierung um den Faktor 4 verringern würde. Es ist allerdings zu erkennen, dass die Nebendiagonalen in den meisten Fällen nicht durchgängig besetzt sind. Außerdem geht aus der Analyse hervor, dass in den meisten Fällen nicht alle Datenbeispiele benachbarter Uhrzeitindizes eine identische Verteilung besitzen. Bei einer Zusammenfassung in Stundenblöcke würden somit Datenbeispiele mit unterschiedlichen Verteilungen durch ein Modell repräsentiert werden. Folglich ist mit einer Verschlechterung der Prognosequalität zu rechnen.




Abbildung C 2 Ermittlung der Klassenzuordnung für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung in Abhängigkeit von Typtagen und Uhrzeitindex $h = 1 \dots 24$ (Stundenblöcke)

Real gemessener Datensatz aus dem „Olympic Peninsula Project“

Zur Ermittlung einer geeigneten Klassenkonfiguration für die Anwendung der klassenbezogenen und uhrzeitabhängigen Mehrschrittmodellierung bei der Prognose wird die Abbildung C 3 ausgewertet. Dafür wurde die Lastzeitreihe analog zu Abbildung C 1 in Datenbeispiele lokaler Abschnitte bezüglich der Typtage und des Uhrzeitindex zerlegt, bei denen die sieben Wochentage als Typtagklassen unterschieden werden. Analog zu den Untersuchungen des synthetischen Datensatzes resultieren 672 Datenbeispiele ($96 \text{ Uhrzeitindizes} \times 7 \text{ Typtagklassen}$) als lokale Abschnitte, bei denen die Verteilungen untereinander mit Hilfe des KS-Tests verglichen werden. Der Test wird in der Abbildung C 3 jeweils mit einer Irrtumswahrscheinlichkeit von $\alpha = 5\%$ und $\alpha = 1\%$ angewendet, wobei die weißen Bereiche die in beiden Fällen negative Ergebnisse zeigen (d.h. unterschiedliche Verteilung der Datenbeispiele). Die schwarzen und orangen Bereiche in der Abbildung zeigen die positiven Ergebnisse des KS-Tests (Verteilung der Datenbeispiele ist identisch) jeweils für eine Irrtumswahrscheinlichkeit von $\alpha = 5\%$ und $\alpha = 1\%$. Es ergibt sich ein an der Hauptdiagonale ge-

spiegeltes symmetrisches Bild. Beim Vergleich der einzelnen Typtagklassen untereinander in den einzelnen Rechtecken (abgegrenzt durch die gestrichelten Linien) ist zu erkennen, dass in zahlreichen Rechtecken neben der (Neben-)Diagonale größere Flächen durch schwarze und oder orangene Markierungen besetzt sind. Beim Vergleich zweier Typtagklassen weisen Datenbeispiele mit dem gleichen Uhrzeitindex eine identische Verteilung auf, wenn die entsprechenden Nebendiagonale komplett besetzt ist. Diese können folglich einer Klasse zugeordnet werden. Prinzipiell könnten durch die auftretenden größeren besetzten Flächen auch mehrere Datenbeispiele mit unterschiedlichem Uhrzeitindex in einer Klasse zusammengefasst werden. Für den Vergleich der Werktage untereinander ergibt sich für alle Werktage ein ähnliches Bild, sodass auf eine ähnliche Charakteristik der Werktage geschlossen werden kann. Eine Unterscheidung verschiedener Werktage in separate Typtagklassen wird daher ausgeschlossen. Beim Vergleich der Werktage mit den Wochenenden sind allerdings leichte Unterschiede auszumachen und die entsprechenden Nebendiagonalen sind nicht durchgängig besetzt. Beim Vergleich zwischen den Typtagklassen Sonntag und den Werktagen sind dabei größere Unterschiede aus zwischen den Samstagen und den Werktagen auszumachen. Auch beim Vergleich zwischen den Klassen Samstag und Sonntag sind die Nebendiagonalen nicht vollständig besetzt.




Abbildung C 3 Ermittlung der Klassenzuordnung für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung in Abhängigkeit von Typtagen und Uhrzeitindex $h = 1 \dots 96$ (15 Minutenwerte)

Analog zu dem synthetischen Datensatz werden in Abbildung C 4 Datenbeispiele derselben Stunde für eine mögliche Parameterreduktion zusammengefasst. Es ist allerdings zu erkennen, dass die Nebendiagonalen in den meisten Fällen nicht durchgängig besetzt sind. Außerdem ist zu erkennen, dass in den meisten Fällen nicht alle Datenbeispiele benachbarter Uhrzeitindizes eine identische Verteilung besitzen. Bei einer Zusammenfassung in Stundenblöcke würden somit Datenbeispiele mit unterschiedlicher Verteilungen durch ein Modell repräsentiert werden. Folglich ist mit einer Verschlechterung der Prognosequalität zu rechnen.




Abbildung C 4 Ermittlung der Klassenzuordnung für klassenbezogene und uhrzeitabhängige Mehrschrittmodellierung in Abhängigkeit von Typtagen und Uhrzeitindex $h = 1 \dots 96$ (Stundenblöcke)