



Thomas Paulsen



**Modeling and Forecasting Wholesale
Electricity Prices under Consideration
of Wind and Solar Power**



Cuvillier Verlag Göttingen
Internationaler wissenschaftlicher Fachverlag



Modeling and Forecasting Wholesale Electricity Prices under Consideration of Wind and Solar Power





Modeling and Forecasting Wholesale Electricity Prices under Consideration of Wind and Solar Power

Von der
Carl-Friedrich-Gauß-Fakultät
der Technischen Universität Carolo-Wilhelmina zu Braunschweig

zur Erlangung des Grades eines
Doktors der Wirtschaftswissenschaften (Dr. rer. pol.)

genehmigte Dissertation

von
Thomas Paulsen
geboren am 04.06.1984
in Eutin

Eingereicht am: 01.10.2018
Disputation am: 13.12.2018
1. Referent: Prof. Dr. Marc Gürtler
2. Referent: Prof. Dr. Thomas Spengler

2018



Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliographische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

1. Aufl. - Göttingen: Cuvillier, 2018

Zugl.: (TU) Braunschweig, Univ., Diss., 2018

© CUVILLIER VERLAG, Göttingen 2018

Nonnenstieg 8, 37075 Göttingen

Telefon: 0551-54724-0

Telefax: 0551-54724-21

www.cuvillier.de

Alle Rechte vorbehalten. Ohne ausdrückliche Genehmigung des Verlages ist es nicht gestattet, das Buch oder Teile daraus auf fotomechanischem Weg (Fotokopie, Mikrokopie) zu vervielfältigen.

1. Auflage, 2018

Gedruckt auf umweltfreundlichem, säurefreiem Papier aus nachhaltiger Forstwirtschaft.

ISBN 978-3-7369-9938-1

eISBN 978-3-7369-8938-2

Dieses Werk ist copyrightgeschützt und darf in keiner Form vervielfältigt werden noch an Dritte weitergegeben werden.
Es gilt nur für den persönlichen Gebrauch.

Zusammenfassung der Dissertation

Modeling and Forecasting Wholesale Electricity Prices under Consideration of Wind and Solar Power

(Modellierung und Prognose von Großhandelspreisen für Strom unter Berücksichtigung von Wind- und Solarenergie)

Der deutsche Strommarkt unterliegt infolge der Marktliberalisierung und dem zunehmenden Anteil der Stromerzeugung aus Erneuerbaren Energien einem fundamentalen Wandel. Einerseits müssen aufgrund der technischen Restriktion der Nicht-Speicherbarkeit von Strom saisonale Nachfrageschwankungen stets zeitgleich durch Erzeugungsmengen abgedeckt werden. Andererseits orientieren sich vor allem die Erzeugungskapazitäten von Windenergie von Photovoltaik nicht am Nachfrageverhalten der Verbraucher. Zudem ist die Stromerzeugung aus Erneuerbaren Energien per Gesetz vorrangig gegenüber konventionellen Energieträgern zu behandeln. Daher verdrängen Erneuerbare Energien zunehmend die Stromerzeugung auf Basis konventioneller Energieträger. Das steigende Angebot bei langfristig relativ konstantem Nachfrageniveau wirkt sich auf dem Großhandelsmarkt, der dem Handel von Strommengen zwischen Erzeugern und Endkundenversorgern dient, preismindernd aus. Dieser Zusammenhang wird als Merit-Order Effekt bezeichnet und ist von hoher Relevanz für das Verständnis des Strommarktes. Erneuerbare Energien beeinflussen die kurzfristigen Preisentwicklungen, ihr Einfluss sollte aber auch bei der Erstellung von Preisprognosen, die für die wirtschaftliche Praxis von Bedeutung sind, berücksichtigt werden.

Im Bereich Preisprognosen auf Strommärkten wurde bereits eine Vielzahl wissenschaftlicher Studien, speziell mit dem Fokus auf Zeitreihenmodellen, durchgeführt. Allerdings unterscheiden sich einerseits die Rahmenbedingungen der Analysen, andererseits sind die Ergebnisse

widersprüchlich, wodurch eine Generalisierung der erhaltenen Ergebnisse erschwert wird. Vor diesem Hintergrund ist es erstaunlich, dass bisher keine statistisch basierten Auswertungen der wissenschaftlichen Literatur zu diesem Thema existieren. Daher wird im Rahmen dieser Arbeit ein umfassender Literaturüberblick über 86 wissenschaftliche Studien im Zeitraum von 2000 bis 2015 zum aktuellen Stand der Forschung im Bereich Zeitreihenanalyse auf Strommärkten gegeben. Zentraler Aspekt der Studie, die als Quasi-Meta-Analyse beschrieben werden kann, ist der Vergleich verschiedener Modelltypen hinsichtlich ihrer Prognosegüte.

Die Ergebnisse der Studie werden in einer nachfolgenden empirischen Analyse für den deutschen Strommarkt (inkl. des österreichischen Marktes) über die Jahre 2010 bis 2014 validiert. Die Studie dient als Erweiterung zur bereits bestehenden empirischen Literatur und untersucht verschiedene Zeitreihenmodelle bei unterschiedlichen Marktbedingungen. Durch eine iterative Betrachtung rollierender Kalibrierungs- und Prognosefenster erfolgt die Bewertung in verschiedenen Marktphasen. Um allgemeingültige Aussagen treffen zu können, werden zudem Datentransformationen und die Längen der Kalibrierungs- und Prognosezeiträume variiert.

Auf Basis der Literaturanalyse und der empirischen Studie werden zwei zentrale Forschungsfragen dieser Dissertation beantwortet:

- Was ist der aktuelle Stand der wissenschaftlichen Forschung im Bereich Zeitreihenanalyse auf Großhandelsmärkten für Strom?
- Welche Zeitreihenmodelle weisen die beste Prognosequalität auf?

Für deren Beantwortung wird in Kapitel 3 im Rahmen einer Literaturanalyse die Prognosequalität diverser Zeitreihenmodelle untersucht. Als Ergebnis zum aktuellen Stand der Forschung wird herausgestellt, dass AR, ARMA oder GARCH Modelle in der wissenschaftlichen Literatur jeweils in gleichem Maße verwendet werden. Die gängigsten Datentransformationen sind Logarithmierung und Differenzierung. Die häufigsten Kriterien für die Bewertung von Prognosen sind MAE, RMSE und MAPE. Die beste Prognosegüte liefern GARCH(X) Modelle vor ARMA(X) Modellen, gefolgt von AR(X) Modellen. Dabei ist die Berücksichtigung von zeitvariablen Strukturen über z.B. Splits von Datensätzen oder Modellierung von Regimewechseln vorteilhaft. Unabhängig vom spezifischen Modelltypen trägt die Hinzunahme von Erklärvariablen (speziell der Nachfrage) zu deutlichen Prognoseverbesserungen bei.

Die darauf folgende empirische Studie zu verschiedenen Zeitreihenmodellen in Kapitel 4 führt zu dem Ergebnis, dass ARMA Modelle mit Erklärvariablen zur Stromnachfrage und zur Stromerzeugung aus Windenergie und Photovoltaik die beste Prognosegüte liefern. Die Prognosefehler sind geringfügig, aber signifikant niedriger als von GARCH Modellen, gefolgt von AR Modellen. Der Widerspruch gegenüber der Literaturanalyse lässt sich über die Argumentation anderer Literaturquellen begründen: In „normalen“ Zeiten geringer Volatilität sind Prognosen von GARCH Modellen schlechter als von ARMA Modellen – ein Aspekt, der auf diese Studie zutrifft. Darüber zeigt sich, dass sich eine Dämpfung von Preisspitzen als grundsätzlich vorteilhaft erweist. Durch zahlreiche Variationen sind die Studienergebnisse als robust gegen Veränderungen der Rahmenbedingungen anzusehen.

Um nun ein Verständnis der preistreibenden Faktoren wie Stromerzeugung aus Wind- und Solarenergie zu entwickeln, sollten aber nicht Prognosen, sondern Erklärmodelle betrachtet werden. Zahlreiche Studien haben bereits die preismindernden Wirkungen der Stromerzeugung aus Erneuerbaren Energieträgern untersucht. Gängig in wissenschaftlichen Studien ist die Anwendung von OLS-Regressionsmodellen. In Abgrenzung zur bestehenden Literatur erfolgt im zweiten Teil dieser Dissertation eine Modellierung von Strompreisen als fixed-effects Panel-Regression. Der Vorteil der Paneldatenanalyse gegenüber einer gepoolten Regression ist die Vermeidung eines omitted variable bias aufgrund von unbeobachteter Heterogenität.

Für das Preismodell wird angenommen, dass eine schwankende Stromerzeugung mit relativ höheren Marktpreisen einhergeht als eine konstante Last. Zum anderen wird der Merit-Order Effekt quantifiziert unter der Annahme, dass die Marktpreise nicht linear abhängig von der Nachfrage sind. Das Modell für den deutschen Strommarkt (inkl. des österreichischen Marktes) über die Jahre 2010 bis 2016 beinhaltet damit Erklärvariablen, welche die Spezifika dieses Strommarktes widerspiegeln, dadurch aber auch ein dementsprechend komplexes Design aufweisen. Gegenüber anderen Studien ist gerade die Nicht-Linearität von Preisentwicklungen besonders hervorzuheben. Dazu fließen Simulationsergebnisse zur aktuellen Zusammensetzung des gesamten deutschen Kraftwerksparks hinsichtlich verschiedener Energieträger in das Regressionsmodell mit ein. Dadurch können die Preisauswirkungen der Stromerzeugung aus Erneuerbaren Energien exakt berechnet werden. Vor dem Hintergrund des generellen Fokus dieser Arbeit auf Erneuerbare Energien ermöglicht das beschriebene Modell die folgende, dritte Forschungsfrage zu beantworten:

- Welche Preiseffekte hat die Stromerzeugung aus Erneuerbaren Energien auf dem Großhandelsmarkt für Strom?

Die Analyse der Preiseffekte in Kapitel 5 führt zu dem Ergebnis, dass der Merit-Order Effekt im Verlauf des analysierten Zeitraums zunächst bis 2013 anstieg, um danach deutlich zu sinken. Dies steht im Zusammenhang zur Entwicklung von Preisen für die Energierohstoffe Kohle und Erdgas und für CO₂-Emissionszertifikate. Für das Jahr 2016 ergibt sich ein Preisdämpfungseffekt von 10 €/MWh durch die Einspeisung von Strom aus Erneuerbaren Energie. Im Jahr 2013 lag dieser Wert noch bei 14 €/MWh. Falls die Marktpreisbildung auf Basis ungenauer Prognosen für die Stromerzeugung durch Windkraft- und Photovoltaikanlagen erfolgt, resultieren deutliche Preiseffekte, die über den Merit-Order Effekt hinausgehen. Ebenso wirkt sich die Volatilität der Nachfrage überproportional auf die Preisvolatilität aus, was dadurch entsteht, dass kurzfristige Anpassungen der Erzeugungsmengen zu steigenden Stromerzeugungskosten führen.

Kapitel 6 fasst die Ergebnisse dieser Arbeit zusammen.

Acknowledgement

This dissertation was mainly written during my time as a research associate at the Department of Finance at the Technische Universität Braunschweig and finished after starting my career as a risk manager at Volkswagen AG.

I would like to thank everyone who contributed to the success of my doctoral thesis. Of course, many thanks go to my supervisor, Prof. Dr. Marc Gürtler, who offered profound discussions, asked critical questions, and gave me the freedom to define my research focus. I also want to thank Prof. Dr. Spengler, who reviewed my thesis.

I spent six years at the Department of Finance. I would like to thank my former colleagues for a friendly, informal working atmosphere during this time. I am convinced that especially my officemate Piet Usselman helped me a lot improving my thesis (but also my personal horizons) by means of numerous critical and fruitful discussions. I would also like to thank Sebastian Gutknecht for the good collaboration within the project with Volkswagen FS and regarding our effective, and perfectly planned conference trips. Of course, many thanks go to Silvia Nitschke, who always keeps the department running.

I owe particular thanks to my wife Dr. Jana Paulsen who supported and encouraged me through all ups and downs – especially on the final meters. I am so glad having you and our children Julian, Levke and Kira. Now, we are really the *family Dr. Paulsen!*





Contents

1	Introduction	1
1.1	Problem Definition and Objectives of this Thesis.....	1
1.2	Course of Investigation.....	4
2	The German Electricity Market	7
2.1	Historical Development from a Legal Perspective	7
2.1.1	The Market Prior to its Liberalization	7
2.1.2	Amendments of EnWG and Liberalization	8
2.1.3	The EEG and its Amendments from 2000 to 2017	9
2.1.4	European Union Emission Trading Scheme	10
2.2	The Situation in the Retail Market.....	11
2.3	The Wholesale Market	13
2.3.1	Power Exchanges EEX and EPEX.....	13
2.3.2	Market Design.....	14
2.3.2.1	Day-Ahead Auction Market	14
2.3.2.2	Continuous Intraday Market	15
2.3.2.3	Futures Market.....	16
2.3.2.4	Temporal Sequence of Trading Periods	16
2.3.3	Balancing Energy	17
2.4	Structure of the Power Plant Portfolio.....	18
2.4.1	Marginal Costs of Power Plants	18
2.4.2	Recent Developments	21
3	Forecasting Performance of Time Series Models: A Quasi-Meta-Analysis.....	23
3.1	Motivation.....	23



3.2	Theory of Modeling and Forecasting Electricity Spot Prices	26
3.2.1	Data Transformation	27
3.2.2	Types of Models.....	28
3.2.3	In-Sample and Out-of-Sample Horizon.....	30
3.2.4	Forecasting Accuracy Measures	32
3.3	Characteristics of the Analyzed Studies	33
3.3.1	Characteristics in General	34
3.3.2	Frequency and Segmentation of Data	35
3.3.3	Data Transformation	36
3.3.4	Types of Models.....	36
3.3.5	Exogenous Variables	38
3.3.6	In-Sample and Out-of-Sample Horizon.....	39
3.3.7	Forecasting Accuracy Measures	41
3.4	Quasi-Meta-Analysis	42
3.4.1	Methodology	43
3.4.2	Results of Forecasting Performance Evaluation	44
3.4.3	Robustness Check	48
3.5	Interim Results	50
3.6	Appendix	53
3.6.1	Definitions of ARMA and GARCH models	53
3.6.1.1	AR.....	53
3.6.1.2	MA	53
3.6.1.3	ARMA	54
3.6.1.4	ARIMA	55
3.6.1.5	Seasonal ARIMA.....	55
3.6.1.6	Seasonal ARIMA with Exogenous Input	56
3.6.1.7	GARCH and Extensions.....	56
3.6.2	List of Related Literature	60
3.6.3	Detailed Vote Count Table	73
4	Forecasting Performance of Time Series Models: Empirical Study	75
4.1	Motivation.....	75



4.2	Hypotheses	77
4.2.1	Performance of Different Time Series Models	77
4.2.2	Choice of Data Transformation and Segmentation	79
4.2.3	Choice of the In-Sample Time Horizon	80
4.3	Methodology	80
4.4	Data	84
4.5	Model Structures and Identification	86
4.6	Forecasting Performance Study	91
4.6.1	Performance of Time Series Models	91
4.6.2	Choice of Data Transformation and Segmentation	97
4.6.3	Choice of the In-Sample Time Horizon	99
4.7	Recap of the Obtained Results.....	102
4.8	Interim Results	103
4.9	Appendix	105
4.9.1	Appendix to Transformation and Segmentation.....	105
4.9.2	Ranking for Different In-Sample Periods	106
4.9.3	Results for Different Out-of-Sample Periods.....	107
5	The Effect of Wind and Solar Power on Electricity Prices	110
5.1	Motivation.....	110
5.2	Literature Review	112
5.2.1	Merit-Order Effect.....	112
5.2.2	Ramping Power Plants.....	116
5.2.3	Forecasting Errors on Wind and Solar Feed-Ins.....	117
5.3	Model Estimation.....	118
5.3.1	Data and Descriptive Analysis.....	118
5.3.2	Model Design	121
5.3.2.1	Regression Model Structure.....	121
5.3.2.2	Variable Design: Technology of the Marginal Power Plant	124
5.3.2.3	Variable Design: Ramping Effects.....	126
5.3.2.4	Model Modification: Intraday Prices and Forecasting Errors	128
5.4	Empirical Results	130



5.4.1	Price Effects of Residual Demand Changes.....	130
5.4.2	Price Effects of Ramping.....	137
5.4.3	Price Effects of Forecasting Errors.....	138
5.4.4	Robustness of Results	140
5.5	Interim Results	142
5.6	Appendix	145
5.6.1	Full Regression Table	145
5.6.2	Appendix to 5.4.1 Price Effects of Residual Demand Changes	148
5.6.3	Appendix to 5.4.3 Price Effects of Forecasting Errors.....	149
5.6.4	Tables of Robustness Check -2-	150
5.6.5	Tables of Robustness Check -3-	152
6	Conclusion.....	155
7	References.....	159

List of Figures

Figure 2.1: Unbundling in the power supply sector	8
Figure 2.2: Course of retail electricity prices in Germany from 1998 to 2017	12
Figure 2.3: Pricing at the German day-ahead market	15
Figure 2.4: Futures market (EEX) and spot market (EPEX) in the course of time	17
Figure 2.5: Schematic merit-order curve.....	19
Figure 2.6: Schematic course of electricity consumption in an average week.....	20
Figure 2.7: Schematic representation of the merit-order effect	22
Figure 3.1: Classification of electricity price models.....	28
Figure 4.1: Scheme of iteratively estimating and forecasting	82
Figure 4.2: EPEX spot price vs. load and generation from RES	85
Figure 4.3: Hourly electricity prices in €/MWh from April 2010 to May 2014.....	86
Figure 4.4: ACF and PACF of spot prices.....	88
Figure 4.5: ACF of the demand	89
Figure 5.1: Plot of spot prices vs. residual demand (from April 2010 to August 2016)	120
Figure 5.2: Merit-order curve for Germany/Austria for April 2016.....	124
Figure 5.3: Average power consumption per hour	127
Figure 5.4: Course of the MOE as per €/MWh from 2010 to 2016	135

List of Tables

Table 2.1: Technologies and their characteristics on the German power market	20
Table 2.2: Gross power generation in TWh in Germany from 1990 to 2015.....	21
Table 3.1: Number of publications depending on frequency and segmentation	35
Table 3.2: Number of publications for different types of price data transformation	36
Table 3.3: Number of different model types applied.....	37
Table 3.4: Number of publications using different types of exogenous variables	39
Table 3.5: Number of publications depending on the length of IS and OS periods.....	40
Table 3.6: Number of publications applying accuracy measures of different types	42
Table 3.7: Vote count for comparison of different model types and specifications	45
Table 3.8: Average forecasting accuracy improvements.....	46
Table 3.9: Results of OLS regression of average forecast accuracy improvements.....	48
Table 3.10: Robustness check of average forecasts improvements.	49
Table 3.12: Related literature	60
Table 3.13: Detailed vote count table	73
Table 4.1: Applied accuracy measures.....	83
Table 4.2: Descriptive statistics	84
Table 4.3: Model lag structures	90
Table 4.4: Forecasting performance of different time series models	92
Table 4.5: Results of DM tests as average values for MAE and MSE.....	93
Table 4.6: Forecasting performance comparison applying data transformations	97
Table 4.7: Results of DM tests.....	98
Table 4.8: Forecasting performance comparison for lengths of calibration windows	100



Table 4.9: DM statistics for lengths of calibration windows	100
Table 4.10: Forecasting performance of time series models in related literature	102
Table 4.11: Summary of the results of testing the research hypotheses	103
Table 4.12: ARMAX: Forecasting performance depending on the transformation.....	105
Table 4.13: MAX: Forecasting performance depending on the transformation.....	105
Table 4.14: GARCH: Forecasting performance depending on the transformation.....	105
Table 4.15: GJR: Forecasting performance depending on the transformation	105
Table 4.16: ARX: Forecasting performance depending on the transformation	106
Table 4.17: ARMA: Forecasting performance depending on the transformation	106
Table 4.18: Forecasting performance for IS = 730 days	106
Table 4.19: Forecasting performance for IS = 365 days	106
Table 4.20: Forecasting performance for IS = 182 days	107
Table 4.21: Forecasting performance for IS = 91 days	107
Table 4.22: Forecasting performance for IS = 50 days	107
Table 4.23: Forecasting performance for OS = 14 days	108
Table 4.24: Results of DM tests for OS = 14 days	108
Table 4.25: Forecasting performance OS = 28 days.....	108
Table 4.26: Results of DM tests for OS = 28 days	109
Table 5.1: Literature on the merit-order effect.....	114
Table 5.2: Descriptive statistics	119
Table 5.3: Regression characteristics.....	130
Table 5.4: Effects of the marginal power generation technology of regression (A).....	131
Table 5.5: Effects of RES feed-ins.....	133
Table 5.6: Average merit-order effect from 2010-2016	136
Table 5.7: Effects of ramping.....	137
Table 5.8: Effects of forecasting errors of feed-in of wind power and solar power.....	138
Table 5.9: Average effects of forecasting errors	140
Table 5.10: Full regression table	145



Table 5.11: Appendix to Table 5.5	148
Table 5.12: Appendix to Table 5.8	149
Table 5.13: Robustness of the results provided in Table 5.4 for regression (A)	150
Table 5.14: Robustness of the results provided in Table 5.4 for regression (A)	150
Table 5.15: Robustness of the results provided in Table 5.5 for regression (A)	151
Table 5.16: Robustness of the results provided in Table 5.7 for regression (A)	151
Table 5.17: Robustness of the results provided in Table 5.8 for regression (F)	152
Table 5.18: Robustness of the results provided in Table 5.4 for regression (A)	152
Table 5.19: Robustness of the results provided in Table 5.4 for regression (A)	152
Table 5.20: Robustness of the results provided in Table 5.5 for regression (A)	153
Table 5.21: Robustness of the results provided in Table 5.7 for regression (A)	153
Table 5.22: Robustness of the results provided in Table 5.8 for regression (F)	154

Mathematical Symbols

B^b	Backshift operator (of degree b)
B^S	Seasonal backshift operator with length S of a seasonal cycle
$c_{O\&M}$	Variable costs on operation and maintenance
$CO_2_price_t$	Price of CO_2 emission allowance certificates at a day t
$coal_price_t$	Coal price at a day t
D	Order of a seasonal integrated process
d	Order of an integrated process
$DA_{i,t}$	Day-ahead price in hour i at a day t
dp	Degree of P-GARCH model
$duration(active)$	Duration of subsequent power plant utilization
$duration(inactive)$	Duration of subsequent power plant non-utilization
$E[\bullet]$	Expected value
e_t	Error of forecasts of electricity spot prices at point in time t
ε_t	IID random variable in a GARCH model at a point in time t
FE	Forecasting error
$fuel_type$	Fuel type variable $\in \{gas, coal, others\}$
$fuel_type_mar_MOC$	Fuel type of the marginal power plant identified on the merit-order curve
$g_t(\varepsilon_{t-i})$	Function in an E-GARCH process to capture asymmetric effects
gas_price_t	Gas price at a day t
$I(active)_{i,t}$	Indicator variable for short period power plant utilization
$I(day)_{d,i,t}$	Indicator variable for weekday d
$I(\varepsilon_t > 0)$	Indicator variable for asymmetric effects in a GJR-GARCH model
$I(fuel)_{fuel_type,i,t}$	Indicator variable for $fuel_type \in \{gas, coal, others\}$

$I(inactive)_{i,t}$	Indicator variable for short period power plant non-utilization
$I(month)_{m,i,t}$	Indicator variable for month m
$I(steepest-down)_{i,t}$	Indicator variable for steep upward ramping
$I(steepest-up)_{i,t}$	Indicator variable for steep downward ramping
$I(year)_{y,i,t}$	Indicator variable for year y
k	Time parameter with $k < t$
L_t	Actual load at point in time t
$\hat{L}_t$	Load forecast at point in time t
l	Length of calibration window
$load_{i,t}$	Load in hour i at day t
MC	Marginal costs
N_t	Additive noise in an ARIMA process
P	Order of a seasonal AR process
P_t	Transformed price p_t after applying differencing
p	Lags according to the Schwert criterion
p	Level of significance
p	Order of an AR process
p	Order of a GARCH process
p_{CO_2}	Price of CO ₂ emission allowance certificates
p_{fuel}	Fuel price
p_t	Electricity spot price at point in time t
$\hat{p}_t$	Electricity spot price forecast at point in time t
$PV_FI_{i,t}$	PV feed-in in hour i at a day t
Q	Order of a seasonal MA process
q	Order of an MA process
q	Order of an ARCH process
$ramping_{i,t}$	Power plant ramping in hour i at a day t
$res_demand_{i,t}$	Residual demand in hour i at a day t
S	Length of a cycle in a seasonal process
$spot_price_{i,t}$	Spot price in hour i at a day t
T	Total sample length
t	Point in time

$WA_MOE_PV_y$	Weighted Waverage of PV-specific MOE in year y
$WA_MOE_wind_t$	Weighted average of wind-specific MOE in year y
$wind_FI_{i,t}$	Wind power feed-in in hour i at a day t
x	Constant shift added to prices prior to log-transformation
x_{CO_2}	Amount of CO ₂ emissions per power plant
x_t	Exogenous input variable in an ARIMAX model
y	Year
Y_t	Log-transformed electricity spot price
Z_t	Random number, $Z_t \sim \mathbb{N}(0, \sigma^2)$
α_i	i -th lag coefficient of an ARCH model
α_0	GARCH model constant
$\beta_{(\cdot)}$	Regression coefficient
β_j	j -th lag coefficient of a GARCH model
γ_i	E-GARCH model regression coefficient
δ_i	GJR-GARCH model coefficient capturing asymmetric effects
ε	Residuals of a regression model
η	Plant efficiency factor
Θ_j	j -th lag coefficient $j \in \{1, \dots, Q\}$ of a seasonal MA(Q) process
$\Theta_Q(B^S)$	Polynomial of seasonal coefficients of an MA(Q) process
ϑ_j	j -th lag coefficient $j \in \{1, \dots, q\}$ of an MA(q) process
$\vartheta_q(B)$	Polynomial of non-seasonal coefficients of an MA(q) process
μ_t	Conditional expected value of p_t in t
ν	Coefficient of the exogenous variable in an ARIMAX model
ρ	(Auto-)correlation coefficient
σ	Standard deviation of a sequence of residuals $\{\varepsilon_t\}$
σ^2	Variance of a sequence of residuals $\{\varepsilon_t\}$
σ_t^2	Conditional variance of a sequence of residuals $\{\varepsilon_t\}$
Φ_i	i -th lag coefficient $i \in \{1, \dots, P\}$ of a seasonal AR(P) process