



universität
wien

DIPLOMARBEIT

Titel der Diplomarbeit

“Vorhersageeigenschaften periodischer Modelle
für Strompreise”

Verfasser

Damir Zivkovic

angestrebter akademischer Grad

Magister der Sozial- und Wirtschaftswissenschaften
(Mag.rer.soc.oec.)

Wien, im März 2009

Studienkennzahl lt. Studienblatt:
Studienrichtung:
Betreuer:

A 140
Diplomstudium Volkswirtschaft
Univ.-Prof. Dipl.-Ing. Dr. Robert M. Kunst

Inhaltsverzeichnis

1.	Einleitung	5
2.	Spotstrompreise	7
2.1.	Liberalisierung der Strommärkte	7
2.2.	Literaturzusammenfassung	10
2.3.	Handelskonzept	13
3.	Datenanalyse	17
3.1.	Datenbearbeitung	17
3.2.	Tägliche Spotstrompreise	20
3.3.	Testregression	26
3.4.	Wöchentliche Spotstrompreise	27
4.	Beschreibung der Modelle	31
4.1.	Autoregressive moving average Modelle	31
4.2.	Separate autoregressive moving average Modelle	33
4.3.	Periodische autoregressive Modelle	34
5.	Modellierung von täglichen Spotstrompreisen	37
5.1.	ARMA(p,q) Modelle	37
5.2.	Separate ARMA(p,q) Modelle	45
5.3.	PAR(p) Modelle	48
6.	Vorhersageeigenschaften	51
6.1.	Methodische Vorgehensweise	51
6.2.	Out-of-sample Prognose	52
6.2.1.	ARMA Modelle	52
6.2.2.	Separate ARMA Modelle	56
6.2.3.	PAR Modelle	59
6.3.	Ergebnisse	64
7.	Schlussfolgerungen	68
A.	Appendix	69
	Literaturverzeichnis	81
	Zusammenfassung / Abstract	85

Abbildungsverzeichnis

2.1.	Regelzonen der EXAA	14
2.2.	Handelbare Produkte	15
3.1.	Durchschnittliche Stundenpreise gesplittet auf Wochentage	19
3.2.	bEXAbase (11.02.2003 - 21.07.2008)	20
3.3.	Histogramm von bEXAbase (gesamter Datensatz)	23
3.4.	Wöchentliche Spotstrompreise (gesamter Datensatz)	28
5.1.	Correlogram von bEXAbase (in-sample Periode)	38
5.2.	Correlogram des restringierten ARMA(1,9) Modells mit Wochendummyvariablen	42
5.3.	Correlogram der Zeitreihe TUE (in-sample Periode)	45
6.1.	1-step-ahead Prognose AIC	55
6.2.	7-step-ahead Prognose BIC	55
6.3.	RMSE für alle 28 PAR Modelle mit Trend	62
6.4.	MAE für alle 28 PAR Modelle mit Trend	63
A.1.	in-sample Datensatz bEXAbase (11.02.2003 - 28.01.2008)	69
A.2.	out-of-sample Datensatz bEXAbase (29.01.2008 - 21.07.2008)	69
A.3.	bEXAbase 2003 (erweitertes Sample)	70
A.4.	bEXAbase 2004	70
A.5.	bEXAbase 2005	70
A.6.	bEXAbase 2006	70
A.7.	bEXAbase 2007	70
A.8.	bEXAbase 2008 (erweitertes Sample)	70
A.9.	Volatilität verschiedener Energiebörsen 2007	71
A.10.	Koeffizienten der Testregression (verschiedene Perioden)	71
A.11.	Zeitreihe TUE (gesamter Datensatz)	72
A.12.	Zeitreihe WED (gesamter Datensatz)	72
A.13.	Zeitreihe THU (gesamter Datensatz)	72
A.14.	Zeitreihe FRI (gesamter Datensatz)	72
A.15.	Zeitreihe SAT (gesamter Datensatz)	72
A.16.	Zeitreihe SON (gesamter Datensatz)	72
A.17.	Zeitreihe MON (gesamter Datensatz)	72
A.18.	Correlogram der Zeitreihe WED (in-sample Periode)	73
A.19.	Correlogram der Zeitreihe THU (in-sample Periode)	73
A.20.	Correlogram der Zeitreihe FRI (in-sample Periode)	74
A.21.	Correlogram der Zeitreihe SAT (in-sample Periode)	74
A.22.	Correlogram der Zeitreihe SUN (in-sample Periode)	75
A.23.	Correlogram der Zeitreihe MON (in-sample Periode)	75

A.24.	RMSE für alle 28 PAR Modelle ohne Trend	.	.	.	80
A.25.	MAE für alle 28 PAR Modelle ohne Trend	.	.	.	80

Tabellenverzeichnis

3.1.	Deskriptive Statistiken der Einzelstunden	18
3.2.	Deskriptive Statistiken von bEXAbase (verschiedene Perioden)	21
3.3.	Klassenhäufigkeiten von bEXAbase (gesamter Datensatz)	23
3.4.	Augmented Dickey-Fuller Test (verschiedene Perioden)	25
3.5.	Regression mit Dummyvariablen für Wochentage	26
3.6.	Deskriptive Statistiken der Wochentage (gesamter Datensatz)	28
3.7.	Augmented Dickey-Fuller Test für alle Wochentage (in-sample Datensatz)	30
5.1.	ARMA Modelle	40
5.2.	ARMA Modelle mit deterministischer Wochensaison	41
5.3.	ARMA Modelle für bEXAbase (white noise)	44
5.4.	separate ARMA Modelle (BIC)	46
5.5.	separate ARMA Modelle mit Trend (BIC)	47
5.6.	PAR Modelle (AIC)	49
5.7.	PAR Modelle (BIC)	50
6.1.	RMSE ARMA Modelle	53
6.2.	MAE ARMA Modelle	54
6.3.	RMSE separate ARMA Modelle	57
6.4.	MAE separate ARMA Modelle	58
6.5.	beste Modelle für separate ARMA Prozesse	58
6.6.	RMSE PAR Modelle	59
6.7.	MAE PAR Modelle	60
6.8.	beste Ergebnisse laut RMSE, MAE	61
6.9.	Anzahl Modelle, die mit Trend bessere Ergebnisse liefern	62
6.10.	bestes PAR Modell	63
6.11.	Ergebnisse ARMA und separate ARMA Modelle	65
6.12.	Ergebnisse PAR Modelle	66
A.1.	RMSE, PAR(1)-PAR(14)	76
A.2.	RMSE, PAR(15)-PAR(28)	77
A.3.	MAE, PAR(1)-PAR(14)	78
A.4.	MAE, PAR(15)-PAR(28)	79

1. Einleitung

In den meisten OECD Ländern waren bis vor kurzem öffentliche Unternehmen für die Stromversorgung verantwortlich. Ende der 1990er Jahre fand aber in vielen europäischen Staaten eine Privatisierung des Stromhandels statt, die von der Elektrizitätsbinnenmarktrichtlinie der Europäischen Union vorangetrieben wurde. Seit dieser voranschreitenden Deregulierung wird der Preis verstärkt durch das wirtschaftliche Gesetz von Angebot und Nachfrage bestimmt. Es entstanden Energiebörsen, an denen Unternehmen in täglich stattfindenden Auktionen ihren Strombedarf decken konnten. Die Marktteilnehmer mussten sich aber den Unsicherheiten des Handels aussetzen. Eine der wichtigsten Besonderheiten von Strommärkten ist die wesentliche Eigenschaft des zugrunde liegenden Gutes. Strom ist nicht lagerfähig. Daraus ergibt sich eine verstärkte Volatilität der Strompreise. Ebenfalls spielen mehrere sich überlagernde Saisonen eine wichtige Rolle bei der Preisbildung [Escribano et al. (2002)].

Eine Plattform für den Handel von Elektrizität bietet die österreichische Energiebörse (EXAA) in Wien. Die täglichen Spotstrompreise vom 11. Februar 2003 bis zum 21. Juli 2008 werden in dieser Arbeit untersucht. Es soll versucht werden, passende Modelle für die Daten zu spezifizieren, wobei ich mich auf univariate, lineare Modelle beschränke. Darüber hinaus sollen vor allem die Vorhersageeigenschaften dieser Modelle beurteilt werden. Nach meinem Wissen gibt es keine publizierte empirische Studie, die sich mit diesem Datensatz beschäftigt.

Die verstärkte Liberalisierung der Strommärkte hat ein reges Interesse ausgelöst, verlässliche ökonometrische Vorhersagemodelle für Strompreise zu entwickeln. Robinson (2000) stellte fest, dass Nicht-Lineare Modelle zu empfehlen sind um die Volatilität von Spotstrompreisen zu beschreiben. Huurman et al. (2007) bauten Wettervorhersagedaten in ihre Modelle ein und zeigten, dass die Prognosegenauigkeit dadurch verbessert werden konnte. Crespo Cuaresma et al. (2004) haben eine interessante Schlussfolgerung für stündliche Spotstrompreise gezogen. Die Vorhersageeigenschaften konnten signifikant verbessert werden, wenn man die Zeitreihe aufteilt und jede Stunde einzeln spezifiziert. Dadurch konnte die Saison, die innerhalb eines Tages auftrat, auf einfache Weise modelliert werden. Das Potenzial dieser Herangehensweise wurde davor von Ramanathan et al. (1997) erfolgreich zur Schau gestellt. Jedoch wurden nicht Strompreise, sondern stündliche Netzbelastungen analysiert. Zusätzlich bewerkstelligten Ramanathan et al. (1997) einen ersten faszinierenden Ansatz bezüglich periodischer Modelle, indem sie für die Prognose von Netzbelastungen Werktage und Wochenenden ebenfalls separat behandelten.

Ich möchte in dieser Arbeit einer einfachen Überlegung nachgehen und für tägliche Strompreise eine ähnliche Herangehensweise untersuchen. Die Saison innerhalb einer Woche soll modelliert werden, indem man die einzelnen Wochentage separat behandelt. Nicht-Linearitäten und die für Spotstrompreise charakteristischen Preis-

spitzen werden in dieser Studie nicht behandelt. Obwohl dadurch wahrscheinlich bessere Vorhersagen erzeugt werden könnten, soll das Hauptaugenmerk dieser Arbeit auf der Modellierung der Wochensaison liegen.

Als Vergleichsmodell werden autoregressive moving average Modelle herangezogen, die den gesamten Datensatz chronologisch betrachten. Der Wochenzyklus wird dabei als konstant angenommen und soll nur von Dummyvariablen modelliert werden. Dann werden ARMA Modelle auf die aufgespaltete Zeitreihe angewendet, wo jeder Wochentag als eine separate Zeitreihe betrachtet wird. Eine Alternative das Mittelwertsverhalten von saisonalen Zeitreihen zu analysieren, ist es Modelle zu berücksichtigen, deren Parameter abhängig von der Saison variieren, siehe Bollerslev & Ghysels (1994). Diese werden als periodische Modelle bezeichnet. Da die Annahme einer zeitunabhängigen, deterministischen Wochensaison eher unplausibel scheint, werde ich als dritte Modellart einfache periodische autoregressive Modelle untersuchen. Dabei werden die Wochentage ebenfalls theoretisch getrennt behandelt, jedoch beinhalten PAR Modelle zusätzlich Variablen der anderen Wochentage in den Spezifikationen. Koopman et al. (2005) haben mit nicht-linearen periodischen Modellen tägliche Strompreise gut modellieren können. Jedoch wurden keine Vergleiche mit nicht-periodischen Modellen gezogen und auch keine Vorhersageeigenschaften veranschaulicht.

Die Organisation dieser Arbeit lautet wie folgt: Kapitel 2 beschreibt Charakteristiken und die Entwicklung des Strommarktes und fasst einige wichtige Studien zusammen. Ebenfalls wird das Handelskonzept der österreichischen Energiebörse erörtert. Kapitel 3 analysiert den Datensatz und in Kapitel 4 werden die oben angeführten Modelle beschrieben. In Kapitel 5 werden die Ergebnisse der Modellspezifikationen veranschaulicht während Kapitel 6 die Vorhersageeigenschaften vergleicht. Das letzte Kapitel beinhaltet die Schlussfolgerungen dieser Arbeit und weist auf mögliche zukünftige Forschungsansätze hin.

2. Spotstrompreise

Dieses Kapitel soll den Stromhandel beschreiben und Charakteristiken von Spotstrompreisen verdeutlichen. Ebenfalls werden einige Studien vorgestellt, die eine Vielzahl von Modellierungsansätzen vorschlagen.

2.1. Liberalisierung der Strommärkte

1999 begann in Österreich die Liberalisierung des Elektrizitätsmarktes. Diese Deregulierung wurde durch die Elektrizitätsbinnenmarkttrichtlinie der Europäischen Union gefordert und hatte als Ziel, den Wettbewerb im Bereich Produktion und Angebot zu steigern. Jedoch verblieb die Übertragung und Verteilung von elektrischem Strom weiterhin als ein natürliches Monopol [Escribano et al. (2002)], welches in Österreich von der staatlichen Energie-Control GmbH [E-CONTROL (2008)] reguliert wird. Deutliche Senkungen der Nettopreise konnten beobachtet werden. Trotzdem waren diese für den Endverbraucher nicht in vollem Maße wahrnehmbar, da in dem Zeitraum auch neue Abgaben zur Förderung von Ökostrom eingeführt und Energiesteuern erhöht wurden. Laut einer Studie von Kurt Kratena (2004) konnte aber bis 2003 durch die Maßnahmen der Energiemarktliberalisierung eine BIP-Steigerung von 0,3% erzielt werden, verglichen mit einem Szenario ohne einer Privatisierung in Österreich.

Die Stromindustrie in England und Wales wurde bereits 1990 privatisiert [ELECPOOL (2008)]. Ein Handelsplatz wurde geschaffen, der als Spotmarkt Nachfrage und Angebot zusammenführen sollte. In einer täglich stattfindenden Auktion wurden im Voraus Gleichgewichtspreise und -mengen für jede halbe Stunde des kommenden Tages bestimmt. Obwohl die durchschnittlichen Preise nach einer Zeit gefallen sind, waren Preisschwankungen auf der Energiebörse an der Tagesordnung. Wenn sich die Stromnachfrage der Kapazitätsgrenze näherte, stiegen die Fluktuationen. Ebenfalls waren nun saisonale Schwankungen zu verzeichnen. Aufgrund der Variationen waren sich Stromerzeuger nie sicher über ihre zu erwartenden Einnahmen und Energieversorger waren mit ungewissen Kosten konfrontiert [Robinson (2000)]. Demnach gewann die Dynamik von Spotstrompreisen eine große wirtschaftliche Bedeutung.

Ramanathan et al. (1997) erwähnten in diesem Zusammenhang ebenfalls das große Interesse der Energieversorger die eigenen Netzbelastungen und vor allem die Belastungsspitzen zuverlässig vorherzusagen. Somit konnte man Wartungsarbeiten bei Generatoren geschickt planen aber auch einen optimalen Mix aus zur Verfügung stehenden Kapazitäten managen. Da gewisse Betriebsanlagen ineffizient und teuer in der Stromerzeugung sein können, wäre es geschickt diese nur dann in den Dienst zu stellen, wenn für gewisse Stunden eine hohe Stromnachfrage zu erwarten ist. In dieser Hinsicht kamen die Energiebörsen vielen Stromanbietern sehr gelegen. Der

Kauf und Verkauf von Strom ermöglicht es, Kapazitäten optimal anzupassen. Man kann überschüssige Energie verkaufen und andererseits Fehlmengen dazukaufen. Der Handel kann aber auch einfach deshalb attraktiv sein, weil der angebotene Strom auf der Börse billiger ist, als die Kosten ein ineffizientes Kraftwerk für wenige Stunden zu reaktivieren. Somit ermöglichen geschickte Berechnungen der Nachfrage höhere Erträge zu erwirtschaften.

Trotzdem sind die Marktteilnehmer einem hohen Risiko ausgesetzt, dass auf die fehlende Lagerfähigkeit von Elektrizität zurückzuführen ist. Das Fehlen von Lagerbeständen impliziert dass zu jedem Zeitpunkt Angebot und Nachfrage exakt abgestimmt sein müssen [Huurman et al. (2007)]. Selbst ein Wasserkraftwerk samt Wasserspeicher könnte nicht als sicherer Warenvorrat bezeichnet werden. Im Falle eines Störfalls von nur einer Turbine könnte man nicht mehr auf die volle Kapazität des Energiespeichers zugreifen. Um eine Kontinuität der Stromversorgung zu gewährleisten, müssen die Stromanbieter somit immer mit einer ausreichenden Reservekapazität kalkulieren.

Durch Angebots- und Nachfrageseitige Schocks lassen sich Preisspitzen erklären. Ein unplanmäßiger Ausfall eines Kraftwerks oder eine überraschende Hitzewelle können den Wert des angebotenen Gutes in die Höhe treiben. Aber auch Fehler im Marktmechanismus oder Kapazitätsbeschränkungen des Stromnetzes können kurzfristige Abweichungen vom Gleichgewichtspreis hervorrufen [Crespo Cuaresma et al. (2004)]. Wetterdaten, die verschiedenen Technologien und Eigenheiten der Kraftwerke, sowie saisonale Effekte sind ebenfalls preisbestimmend. Durch den Börsenhandel lassen sich sogar Ähnlichkeiten zu Finanzmärkten erkennen [Koopman et al. (2005)]. Trotzdem ist die Preisentwicklung auf Strommärkten weit komplexer, nicht zuletzt wegen mehreren, sich überlagernden Saisonen. Da dieses Phänomen eher untypisch für Finanzmärkte ist, können die für diese Branche gängigen Modelle Spotstrompreise nicht so einfach beschreiben.

Escribano et al. (2002) haben mehrere Energiebörsen untersucht. Sie stellten fest, dass Spotstrompreise für gewöhnlich folgende Eigenschaften besitzen:

(i) *Saisonalität*, diese beruht einerseits auf den Zusammenhängen zwischen Nachfrage und Wetterlage und spiegelt sich in einem eventuellen Jahreszyklus wieder. Ebenfalls sind Abhängigkeiten von sozialen und wirtschaftlichen Aktivitäten ersichtlich, wie typischen Arbeits- und Schlafenszeiten. Gesellschaftliche Rahmenbedingungen wie Ruhe- und Feiertage beeinflussen ebenfalls den Preis.

(ii) *Mean-Reversion-Effekt* (Mittelwertannäherung), da Preisschwankungen nur durch kurzfristige Marktgegebenheiten ausgelöst werden. Langfristig sollte der Preis gegen ein Gleichgewicht streben, welches durch den Mittelwert approximiert werden kann. Dieser Gleichgewichtspreis sollte nur langsamen Änderungen unterworfen sein.

(iii) *Preisspitzen* erklären sich durch die Tatsache, dass elektrischer Strom in großen Mengen nur schwer lagerfähig ist. Somit lassen sich Nachfrage- bzw. Angebotschocks schwerer mildern, siehe auch Koopman et al. (2005).

(iv) *Volatility Clustering* (Zusammenlagerung von Volatilitäten) sind auch typische Merkmale von Finanzmarktdaten. In Phasen hoher Schwankungen ist es wahr-

scheinlich, dass im Folgezeitraum ebenfalls mit höheren Varianzen zu rechnen ist. Umgekehrt erwartet man, dass nach ruhigen Handelstagen eine Zeit lang geringere Preisvolatilitäten vorherrschen.

Noch vor 10 Jahren, als die Strommärkte vielerorts verstaatlicht und Preise zentral reguliert wurden, hatten nachfrageseitige Schwankungen, Saisonsen oder Wettereffekte keinerlei Auswirkungen auf den Preis [Huurman et al. (2007)]. Doch durch die verstärkte Öffnung und Liberalisierung der Märkte sehen sich die Marktteilnehmer einer Vielzahl von Unsicherheiten, aber auch Möglichkeiten gegenüber. In vielen europäischen Ländern haben sich weitere Energiebörsen gebildet. Die European Energy Exchange mit Sitz in Leipzig [EEX (2008)] ist die größte Energiebörse Kontinentaleuropas, während die Nordic Power Exchange mit Norwegen, Dänemark, Schweden und Finnland die erste multinationale Energiebörse der Welt darstellt [NORDPOOL (2008)].

Die heutige Entwicklung von Energiebörsen läuft darauf hinaus, dass eine weite Palette von finanzmarktähnlichen Produkten angeboten wird. Neben dem Day Ahead Spotmarkt (Handel ein Tag im Voraus) hat sich auf der EEX auch ein Intraday Spotmarkt gebildet, wo Stromkontrakte mit Lieferung am selben Tag gehandelt werden können. Ebenfalls hat sich ein Terminmarkt gebildet, wo man Futures auf den zukünftigen Durchschnittspreis handelt. Dabei können diese langfristigen Verträge mit bis zu 6-jähriger Bindung abgeschlossen werden [EEX (2008)].

Diese Arbeit untersucht die Day Ahead Spotstrompreise der österreichischen Energiebörse (Energy Exchange Austria) mit Sitz in Wien [EXAA (2008a)], die am 8. Juni 2001 gegründet wurde. Der Handel mit elektrischer Energie wurde aber erst am Donnerstag, dem 21. März 2002 aufgenommen und 2005 wurde das Produktangebot durch den Handel von CO₂-Emissionsrechten erweitert. Seit Handelsbeginn konnte die Anzahl der Marktteilnehmer gesteigert werden. Mit heutigem Stand sind fast 50 Unternehmen aus über 10 verschiedenen Ländern am Spothandel mit Strom involviert. Eines der letzten neu hinzugekommenen Unternehmen war die Royal Bank of Scotland, was die internationale Ausrichtung der EXAA widerspiegelt. Der Anteil ausländischer Mitglieder überwiegt sogar.

Die physische Erfüllung des Spotstrommarktes war anfangs innerhalb der österreichischen Grenzen beschränkt. Die Lieferzonen wurden aber 2004 und 2005 ausgedehnt auf Regelzonen der deutschen E.ON und RWE Konzerne. Die österreichische Energiebörse verfolgt längerfristig das Ziel seinen Aktionsradius weiter in Zentral- und Südosteuropa zu erweitern [EXAA (2008c)]. Dabei scheiterte 2007 eine Erweiterung der Lieferzonen auf den Schweizer Raum aufgrund mangelnder Ertragshaltigkeit. 2007 wurden 2266 Gigawattstunden Strom an der EXAA gehandelt. Dieses Marktvolumen entspricht ungefähr 3,75% des gesamten österreichischen Energieverbrauchs [EXAA (2008b)].

Die österreichische Energiebörse ist Mitglied der CISMOgroup, der Clearing Integrated Services and Market Operations Group. Diese ist ein Zusammenschluss von selbstständig agierenden Unternehmen, welche auf den liberalisierten Energiemärkten verschiedenen, zusammenhängenden Tätigkeiten nachgehen. Die EXAA an sich ist selber eine Aktiengesellschaft mit der Wiener Börse als einem der Hauptaktionäre [EXAA (2008a)].

2.2. Literaturzusammenfassung

Die verstärkte Deregulierung der Strommärkte hat ein reges Interesse ausgelöst, die Dynamiken der Preisbildung besser zu verstehen und die Entwicklung zuverlässiger ökonometrischer Vorhersagemodelle voranzutreiben. Dieses Kapitel soll Einsicht in eine ausgewählte Reihe empirischer Studien geben.

Die ersten Anfänge, Daten der Stromindustrie vorherzusagen, bezogen sich auf die zu erwartenden Netzbelastungen. Es war für Stromversorger von enormer Wichtigkeit, einen Überblick über kommende Belastungsspitzen zu haben, um Kapazitäten optimal anzupassen. Die Vorhersagen von Netzbelastungen sind für unsere Arbeit deswegen relevant, weil die Daten Ähnlichkeiten mit Spotstrompreisen aufweisen, vor allem im Bezug auf Saisonalität.

Ackerman (1985) berücksichtigte für stündliche Netzbelastungen drei Alternativen, darunter integrierte autoregressive moving average Modelle, kurz ARIMA(p,d,q). Er differenzierte die Daten in der Form $y_t - y_{t-24}$ und berechnete einen AR(1) Prozess. Eine andere Variante war das ARIMA(24,1,1) Modell. Beide Versuche erwiesen sich aber als inferior gegenüber der dritten Variante, in der einfache autoregressive Modelle auf gefilterte bzw. manipulierte Daten angewandt wurden.

Gupta (1985) schlug ein lernfähiges Modell vor. Die Parameter würden sich automatisch anpassen, abhängig von den sich verändernden Bedingungen. Darüber hinaus flossen neben historischen Daten auch Wetterdaten in die Berechnungen mit ein.

Ramanathan et al. (1985) verwendeten eine zweistufige Methode. Zuerst wurde ein kurzfristiges Modell erstellt. Dieses baute auf schnell variierenden Daten wie Temperatur und saisonalen Dummyvariablen auf. In einem zweiten Schritt hingen diese Parameter dann von Variablen ab, die sich nur sehr langsam änderten. Darunter wirtschaftliche Faktoren wie Bevölkerungsanzahl, Endverbraucherstrompreise und Einkommen.

Ramanathan war später an noch einem Projekt mit den Nobelpreisträgern Engle und Granger beteiligt. Das Ziel der Studie war es, für stündliche Netzbelastungen Modelle zu kreieren, die besonders gut für kurzfristige Vorhersagen geeignet waren. Die Herangehensweise von Ramanathan et al. (1997) war ein multiples Regressionsmodell, welches jede Stunde separat behandelt. Ebenfalls wurden die Wochenenden zusätzlich getrennt modelliert und Wettervorhersagedaten spielten eine wichtige Rolle.

Mehrere Forschungsteams beteiligten sich dabei an einem in Echtzeit stattfindenden Wettbewerb. Gastgeber war die Puget Sound Power and Light Company, deren historische Daten als Grundlage dienten. Die Modelle der anderen Teams wurden nicht veröffentlicht, um das geistige Eigentum der jeweiligen Forscher zu schützen. Das erste offizielle Experiment für den Vorhersagewettbewerb fand im Winter 1990 statt. Danach wurden unter den Teilnehmern Informationen ausgetauscht und jeder

hatte die Möglichkeit seine Modelle zu überarbeiten. Ein zweites in Echtzeit stattfindendes Experiment fand 1991-1992 statt.

Alle konkurrierenden Modelle verwendeten die Daten als eine fortlaufende Zeitreihe, d.h. die Stunden waren chronologisch angeordnet. Ramanathan et al. (1997) entschieden sich, jede Stunde einzeln als separate Zeitreihe zu modellieren. Dazu kam, dass für die Wochenenden ebenfalls unterschiedliche Regressionen verwendet wurden. Somit wurden die aufgeteilten Daten von insgesamt 48 Modellen beschrieben, die aber alle die gleichen Variablen beinhalteten. Deterministische Variablen wie die Wochentage und Monate wurden von Dummyvariablen modelliert. Ein eventueller langfristiger Anstieg der Nachfrage wurde von einem linearen Trend berücksichtigt. Temperaturdaten sollten vor allem kurzfristige Schwankungen innerhalb der Nachfrage berücksichtigen. Vergangene Netzbelastungen und gelaggte Fehler wurden ebenfalls mitspezifiziert.

Einer der Kritiken an der Herangehensweise von Ramanathan et al. (1997) war, dass es sich nur um ein multiples Regressionsmodell handelt, in dem viele Variablen miteinander korreliert sind. Ebenfalls basiert das Modell auf keiner ökonomischen Theorie. Jedoch war das Ziel kurzfristige Vorhersagen zu modellieren und ökonomische Faktoren wie Endverbraucherpreise, Bevölkerungs- und Wirtschaftswachstum spielen in der kurzen Frist so gut wie keine Rolle. Ramanathan et al. (1997) erwähnten auch, dass mögliche Multikollinearität Prognosen nicht gefährden, sondern eher verbessern.

Die Resultate der Vorhersagen verdeutlichten für beide Wettbewerbsphasen, dass die Herangehensweise der Autoren den konkurrierenden Modellen, die meist komplizierter waren, überlegen ist. Ebenfalls bestätigte sich, dass die Koeffizienten systematisch über die verschiedenen Stunden variierten, was für die separate Behandlung der einzelnen Stunden spricht. Die Analyse von besonders schlecht gefitteten Werten zeigte, dass diese zu einem großen Teil auf ungenaue Wettervorhersagen der Temperaturdaten zurückzuführen sind.

Diese Idee der separaten Behandlung der Stunden wurde von Crespo Cuaresma et al. (2004) für Spotstrompreise untersucht. Die Studie vergleicht die Vorhersageeigenschaften univariater, linearer Modelle für stündliche Strompreise der Leipziger Energiebörse von Juni 2000 bis Oktober 2001. Dabei wurden vorwiegend ARMA Modelle untersucht. Preissprünge wurden mit einem rekursiven Filter identifiziert und dann aus dem Datensatz entfernt.

Wichtigste Eigenschaft der Studie ist die Aufteilung der Analysen in zwei Gruppen. Einerseits wurde die gesamte Zeitreihe chronologisch betrachtet, wobei ein zeitabhängiger Mittelwert durch Dummyvariablen modelliert wurde. Das Saisonmuster wird aber dadurch als konstant angenommen. Andererseits wurden die Daten aufgeteilt, um die saisonalen Effekte innerhalb eines Tages besser zu erfassen. So wurden alle 24 Stunden separat betrachtet. Somit unterstellt man den verschiedenen Stunden, sie hätten unterschiedliche Dynamiken.

Als Bezugsmodell galt ein einfacher AR(1) Prozess, der die Eigenschaft der Mittelwertsannäherung von Strompreisen beschreiben sollte. Danach wurden ARMA(p,q) Modelle berücksichtigt. Bei den separaten Zeitreihen wurde eine sinnvolle Ergänzung miteinbezogen. Die ARMA Prozesse beinhalten zusätzlich die

benachbarten Preise der anderen 23 Stunden als Variablen. Dabei handelt es sich nicht um periodische ARMA Modelle, da z.B. für die Modellierung der 12. Stunde nicht nur die vergangenen 11 Stundenpreise verwendet werden, sondern auch noch die zukünftigen 12 Stunden bis Mitternacht.

Die Ergebnisse der Prognosen waren eindeutig. Jedes einzelne Modell, welches auf separaten Zeitreihen basierte übertrumpfte seinen gleich spezifizierten Konkurrenten, der den Datensatz als ganzes hernahm. Somit zeigte sich für lineare, univariate Zeitreihenmodelle, dass eine separate Behandlung der einzelnen Stunden auch für Spotmarktpreise vorteilhaft sein kann.

Robinson (2000) untersuchte die Strompreise der englischen und walisischen Energiebörse und berücksichtigte Nicht-Lineare Modelle. Er begründete diese Entscheidung mit der Annahme, dass Veränderungen der Nachfrage oder des Angebots zu überproportionalen, nicht-linearen Preisschwankungen führen können. Er betrachtete ebenfalls die Vermutung, dass theoretisch die Strompreise kurzfristig unbegrenzt in die Höhe steigen könnten. Jedoch erwähnte er, dass diese Annahme in der Praxis eher als absurd anzunehmen ist. Ab einem gewissen Zeitpunkt würden die Stromversorger ihren Endkunden eher einen Stromausfall zumuten, als einen übertrieben hohen Preis für ein zusätzliches Kilowatt Strom zu bezahlen.

Der Autor verwendete STAR (smooth transition autoregressive) Modelle um die Nicht-Linearität der Daten adäquat zu beschreiben. Diese Modelle erlauben es, zwischen zwei diskreten Regimen zu wechseln. Somit können zwei Phasen innerhalb der Zeitreihe beschrieben werden, deren Übergang gleichmäßig vonstatten gehen kann. Die Studie schlussfolgert, dass Nicht-Lineare Modelle die Charakteristiken der Strompreise angebracht beschreiben. Jedoch wurden in der Arbeit keine Vorhersageeigenschaften analysiert und die technische Schwierigkeit angedeutet, die Nicht-Lineare Modelle bei der Prognose aufweisen.

Koopman et al. (2005) untersuchten Periodizitäten für die einzelnen Wochentage. Es wurde angenommen, dass Preisstrukturen für unterschiedliche Tagestypen variieren. Die empirische Studie untersuchte unter anderem die täglichen Spotstrompreise der norwegischen Nord Pool Energiebörse. Eine Besonderheit dieses Marktes ist, dass der Großteil der Energieversorgung in Norwegen durch Wasserkraftwerke gedeckt ist. Deshalb hängt das kurzfristige Angebot stark von Wetterbedingungen bzw. dem Niveau der Wasserspeicher ab.

Als Modell wurde ein periodisches saisonales Reg-ARFIMA Modell verwendet, um die täglichen Strompreise zu analysieren. Die Saisonlänge bezog sich auf den Wochenzyklus. Damit variierten die Parameter je nachdem, welcher Wochentag betrachtet wurde. Als Besonderheit dieser Studie wurde zusätzlich die Varianz von einem GARCH Prozess modelliert. Die Analyse der Residuen zeigte eine gute Anpassung des Modells an die Strompreise. Es wurden aber keine Vorhersageeigenschaften untersucht.

Die Arbeit von Huurman et al. (2007) versuchte, Wettervorhersagedaten in etablierte Modelle für Spotstrompreise einzubauen. Die Ergebnisse zeigen, dass dadurch die Prognosegenauigkeit verbessert werden kann. Vor allem bieten Wetterdaten wichtige Informationen um kommende Preisspitzen vorherzusagen. Der Einfluss von Wetterfaktoren auf Energiebörsen hat zwei wesentliche Begründungen. Einerseits beein-

flusst das Wetter die Nachfrageseite durch Hitze- und Kältewellen. Andererseits können Unregelmäßigkeiten des Stromangebots ausgelöst werden. Die Produktion in Solar- und Windanlagen sowie in Wasserkraftwerken hängt stark von den unterschiedlichen Umwelteinflüssen ab.

Weron & Misiolek (2005) haben einfache ARMA Modelle evaluiert, in denen zusätzlich exogene Variablen miteinbezogen wurden. Diese beinhalteten vergangene Netzbelastungen und andere Informationen über die Kraftwerke. Die Ergebnisse der Vorhersageeigenschaften waren nicht eindeutig, ließen aber ein einfaches autoregressives Modell mit zusätzlichen exogenen Variablen als Sieger hervorgehen. Das hinzufügen großer moving average Teile verschlechterte die Prognosen und die exogenen Variablen waren modellabhängig nicht immer von Vorteil.

Escrignano et al. (2002) präsentierten eine allgemeine Strategie zum modellieren von täglichen Spotstrompreisen. Diese wandten sie auf Datensätze verschiedener Energiebörsen an und stellten ebenfalls einige Gemeinsamkeiten zwischen den unterschiedlichen Märkten fest. Bei der Modellierung der Preise wurde versucht, Saisonalität, Mittelwertannäherung, GARCH Effekte und zeitabhängige Preissprünge mitzubetrachten.


2.3. Handelskonzept

In diesem Kapitel soll der genaue Handelsablauf auf der österreichischen Energiebörse beschrieben werden, siehe EXAA (2008). Alle 24 Einzelstunden sowie verschiedene Blockprodukte sind an der EXAA handelbar. Die Gebiete, in denen tatsächlich eine physische Stromlieferung ermöglicht wurde, sind in Abbildung 2.1 ersichtlich. Diese umfassen den gesamten österreichischen Raum, der sich aufteilt in die Zonen der VERBUND-Austrian Power Grid AG (APG), Tiroler Wasserkraft-Netz AG (TIWAG) und der Vorarlberger Kraftwerke-Netz AG (VKW). Ebenfalls sind die beiden deutschen Regelzonen der E.ON und RWE Energiekonzerne seit den Jahren 2004 und 2005 zugänglich.

Es wird vorausgesetzt, dass länderübergreifend genügend Netzkapazitäten vorhanden sind, damit die Händler die Bestimmungsorte nach Wunsch auswählen können. Bei eventuellen Beschränkungen werden diese frühzeitig bekannt gegeben. Bei der Frage nach den Transportkosten von Strom können die Fixkosten der Hochspannungsleitungen theoretisch entfallen, wenn ausreichend Kapazitäten vorhanden sind. Die direkten Kosten aber betragen ca. 3 % der transportierten Energiemenge bei einer Wegstrecke von 1000 km, da durch den elektrischen Widerstand der Leitungen ein Leistungsverlust entsteht. Dies gilt aber nur bei der Verwendung von Hochspannungsgleichstromleitungen. Die Verlustleistung beim Transport von Wechselstrom über große Strecken ist hingegen noch unwirtschaftlicher [TRECERS (2008)].

Neben den einzelnen Stunden sind auch 11 Blockprodukte handelbar, die den Strompreis über mehrere aufeinander folgende Stunden definieren. Dadurch entsteht für die Kunden ein verringertes Risiko hinsichtlich eines unterbrechungsfreien Kaufs

bzw. Verkaufs von Strom. In Abbildung 2.2 wurden die verschiedenen Blockprodukte abhängig von ihrer Zeitspanne wiedergegeben. Das Blockprodukt, mit dem sich diese Arbeit beschäftigt heißt bEXAbase (00-24 Uhr). Dieses bezieht sich auf den Preis, der für einen gesamten Tag gilt. Dabei ist wichtig zu erwähnen, dass sich der Preis der Blockprodukte einfach durch den Mittelwert der jeweiligen Stundenpreise errechnen lässt.




[http://www.exaa.at/static/cms/sites/exaa.at/media/downloads/EXAA_broschuere_dt_2.pdf]

Abbildung 2.1.: Regelzonen der EXAA

Die Mindesthandelsmenge sowie alle weiteren Erhöhungen der Volumen betragen 0,1 Megawattstunden. Alle Preise sind in Euro pro Megawattstunde angegeben und werden in Cent genau berechnet.

Die Ermittlung von Preis und Menge erfolgt einen Tag im Voraus über ein Auktionssystem, jeweils an Werktagen. Kauf- und Verkaufsgebote der einzelnen Marktteilnehmer werden für alle fünf Regelzonen gesammelt und zusammengeführt.

Durch die einzelnen Gebote erstellt die EXAA aggregierte Nachfrage- und Angebotskurven für jede Einzelstunde. Dadurch lassen sich Gleichgewichtspreise und -mengen bestimmen, wobei die Energiebörse als Ziel hat, das verkaufte Energievolumen zu maximieren. Diese Motivation lässt sich mit dem zugrunde liegenden Gebührenkonzept der Börse erklären, welches von der gehandelten Menge abhängt. Der gemeinsame Marktpreis gilt für alle fünf Regelzonen. Die bei der Auktion ermittelten Handelsvolumen inkludieren ebenfalls jene Mengen, die durch Gebote für die Blockprodukte abgegeben wurden.



[http://www.exaa.at/static/cms/sites/exaa.at/media/downloads/EXAA_broschuere_dt_2.pdf]

Abbildung 2.2.: Handelbare Produkte

Direkt nach der Auktion werden den Marktteilnehmern ihre Lieferverpflichtungen bzw. die zugeteilten Strommengen bekannt gegeben. Die physische Erfüllung der Geschäfte erfolgt zumeist am nächsten Tag (Day-Ahead-Handel). An den Wochenenden und Feiertagen sind die Börsen geschlossen. Deshalb muss am letzten Werktag vor den Ruhetagen der Handel im Vorhinein abgeschlossen werden. Vor Wochenenden wird demnach jeden Freitag Preis und Menge für drei Liefertage im Voraus ausgemacht, einschließlich Montag. Die besagte Auktion findet täglich um 10.15 Uhr an Werktagen statt. Somit ist dies die erste in Europa stattfindende Spotauktion um diese frühe Uhrzeit. Die EXAA kann als Indikator für die Preisentwicklung an anderen Energiebörsen fungieren, wie etwa der Europäischen Energiebörse (EEX) in Leipzig.

Die EEX bietet zeitlich eine der letzten Möglichkeiten, die Energieversorgung zu sichern. Die Auktionen finden erst um 12.00 Uhr statt. Händler die auf der EEX noch dringend ihren Energiebedarf decken wollen, müssen sich dies mit höheren Geboten erkaufen. Andererseits bietet die EEX auch die letzte Möglichkeit überschüssige Strommengen zu verkaufen. Somit besteht hier die Möglichkeit für Händler auch sehr günstig Strom zu erwerben. In jedem Fall ist auf der später stattfindenden Auktion der EEX mit höheren Preisschwankungen zu rechnen. Händler, die an beiden Börsen agieren, könnten gegebenenfalls ihr Handelsportfolio optimieren und Preisrisiken verringern. Indem man auf der EXAA günstigere Preislimits abgibt,

kann man möglicherweise bessere Erträge erwirtschaften. Eventuell verbleibende Lücken kann man dann später auf der EEX noch decken. Diese Preis- und Risikounterschiede liefern Raum für eventuelle Arbitragemöglichkeiten und Spekulationen zwischen verschiedenen Energiebörsen. Somit lassen sich Marktteilnehmer wie die Royal Bank of Scotland erklären, die als Bank eigentlich wenige direkte Verwendungsmöglichkeiten für Strom aufweist.

Die österreichische Energiebörse fungiert als Vertragspartner für Verkäufer und Käufer und gewährleistet unter anderem die Anonymität der Geschäfte. Sie übernimmt das Risiko aller getätigten Geschäfte und garantiert vor allem die finanzielle Erfüllung. Darüber hinaus haftet die Strombörse bei möglichen Lieferausfällen. Dem gegenüber steht aber die Verpflichtung der Teilnehmer, vor Markteintritt und Abgabe von Geboten, Sicherheiten in ausreichender Höhe zu hinterlegen. Diese Sicherheiten werden täglich neu bewertet, ob sie angemessen sind, bezogen auf die zu erwartenden Handelsvolumina der einzelnen Marktteilnehmer. Ein Risiko stellt ebenfalls die zeitgerechte Erfüllung aller Geschäfte dar. Die EXAA hat hier die Aufgabe dies zu überwachen und zu organisieren.

Dabei erfolgt der gesamte Handelsablauf elektronisch und standortunabhängig über das Internet. Es ist keine börsenspezifische Infrastruktur notwendig. Dadurch reduziert man Aufwand und Kosten, die bei direkten bilateralen Geschäften anfallen würden. Die Finanzierung der EXAA selber erfolgt über Gebühren, die alle Handelsteilnehmer abführen müssen. Diese betragen 0,075 Euro pro Megawattstunde die gehandelt wird. Ebenfalls fallen unter anderem fixe Abgaben für den Beitritt an sowie diverse jährliche Geschäftsgebühren.

In manchen Fällen kann es aufgrund von mangelnder Liquidität der Marktteilnehmer passieren, dass kein Handel für gewisse Stunden zustande kommt [Kovac (2008)]. Dies war nur in den anfänglichen Jahren einige Male der Fall. Dieses Fehlen an Datenwerten wird uns im nächsten Kapitel noch weiter beschäftigen.

3. Datenanalyse

3.1. Datenbearbeitung

Die Daten der österreichischen Spotmarktpreise sind kostenfrei auf der Homepage der EXAA zugänglich [EXAA (2008a)]. Preisdaten für die Einzelstunden sind ab Freitag dem 22. März 2002 vorhanden. Der Handelsbeginn von Blockprodukten war jedoch offiziell später. Da wir die täglichen Spotstrompreise modellieren wollen, beschäftigen wir uns nur mit den Daten des Blockproduktes bEXAbase (00-24 Uhr). Dieser gibt den durchschnittlichen Tagespreis an. Marktstart dieses Blockproduktes war am Montag, dem 10. Februar 2003. Erste Datenwerte sind demnach erst für den Folgetag vorhanden. Wir untersuchen den Zeitraum von Dienstag, dem 11. Februar 2003 bis Montag, dem 21. Juli 2008, der 1988 Tage umfasst. Dies entspricht knapp fünfeinhalb Jahren bzw. exakt 284 vollständigen Wochen.

Leider gibt es innerhalb der Daten einige Lücken. Aufgrund von mangelnder Liquidität der Marktteilnehmer kann es geschehen, dass für einzelne Stunden kein Handel zustande kommt. Dies war vor allem vor dem Handelsbeginn mit Blockprodukten üblich. Falls für gewisse Stunden kein Preis zustande kommt, so werden auch die jeweils betroffenen Blockprodukte nicht angeboten, da dadurch die Definition des unterbrechungsfreien Stromangebots nicht gewährleistet wäre.

Seit Dienstag, dem 11. Februar 2003 ist es nur zwei Mal vorgekommen, dass für bEXAbase kein Preis in den Datensätzen auftaucht. Jeweils an zwei Sonntagen Anfang 2005, nämlich am 16. und am 30. Januar. An diesen Tagen sind auch fünf bzw. drei Stundenpreise nicht zustande gekommen. Ich habe beide Datenwerte für diese Sonntage rekonstruiert, indem ich den Mittelwert über die übrigen Stundenpreise gebildet habe. Auf diese Art und Weise ist der gesamte Datensatz von bEXAbase konzipiert. Die Rekonstruktion der einzelnen fehlenden Stundenpreise wäre technisch weit komplexer. Die Mittelwertsberechnung für bEXAbase bietet aber eine gute Approximation an einen möglichen wahren Wert. Diese adäquate Konstruktion beider Datenpunkte bietet den Vorteil, dass man nicht auf große Teile der Datensätze verzichten muss, um eine lückenlose Zeitreihe vorzufinden.

Tabelle 3.1 zeigt einige deskriptive Statistiken der einzelnen Stundendaten im Vergleich zum Blockprodukt bEXAbase. Die 12. Stunde (11-12 Uhr) hat den höchsten Mittelwert aber auch den globalen Maximalwert vorzuweisen. Ebenfalls ist die Standardabweichung am größten. Auffällig ist ein sehr geringer Minimalwert verglichen mit anderen Stunden der Mittagszeit. An der Anzahl der Beobachtungen erkennt man die Lücken der einzelnen Stunden, an denen keine Preise zustande gekommen sind. Ebenfalls fehlen für die 3. Stunde sechs Datenwerte. Dies ist auf die Sommerzeitumstellung jedes Jahr zurückzuführen, die am letzten Sonntag im März stattfindet. Im umgekehrten Fall, am letzten Sonntag im Oktober, findet die Winterzeitumstellung statt. An diesen Tagen wird tatsächlich 25 Stunden lang Strom

angeboten. Jedoch wird dieses Phänomen in den Datensätzen nicht berücksichtigt. Für bEXAbase wurde der um die zwei fehlenden Datenpunkte ergänzte Datensatz verwendet und ich beziehe mich von nun an bei der Erwähnung dieses Blockproduktes nur noch auf die lückenfreie, bearbeitete Variante.

Hierbei sei noch hinzuzufügen, dass die p-Werte der Jarque-Bera Tests für alle Einzelstunden und bEXAbase einen Wert von 0,00 aufweisen. Somit wird die Nullhypothese von normal verteilten Preisen für alle 25 Zeitreihen einzeln verworfen. Bezüglich des Jarque-Bera Tests auf Normalverteilung siehe Bera & Jarque (1980) und (1981).

Tabelle 3.1.: Deskriptive Statistiken der Einzelstunden

	Obs.	Mean	Max.	Min.	Std. Dev.	Skewness	Kurtosis
h1	1988	30,24	81,00	6,83	11,52	0,97	3,46
h2	1988	25,89	62,00	0,55	10,62	0,80	3,15
h3	1982	23,26	56,81	0,01	9,94	0,71	3,01
h4	1988	21,37	75,00	0,01	9,47	0,76	3,45
h5	1988	21,74	55,00	0,01	9,52	0,68	3,09
h6	1988	25,86	65,01	0,01	11,07	0,53	3,00
h7	1988	31,08	89,12	0,01	15,08	0,49	3,08
h8	1987	43,33	208,21	0,01	24,59	1,38	7,18
h9	1988	48,90	267,14	0,01	26,81	1,68	9,14
h10	1988	52,80	376,93	9,73	29,93	2,92	21,82
h11	1988	56,37	837,03	10,90	36,47	7,08	120,91
h12	1988	62,75	888,00	0,07	46,31	6,77	87,09
h13	1988	55,19	500,00	12,37	31,88	4,68	50,11
h14	1988	52,26	409,65	9,34	29,05	3,22	26,38
h15	1988	49,03	350,00	3,51	27,68	3,07	23,83
h16	1988	46,29	300,00	6,49	25,20	2,50	16,88
h17	1988	45,36	240,00	6,10	24,54	2,11	10,72
h18	1987	51,05	517,55	7,40	38,93	5,06	42,84
h19	1988	53,60	519,93	8,23	38,79	4,60	37,15
h20	1987	49,26	302,37	10,08	25,73	2,36	13,65
h21	1987	44,89	127,78	13,47	18,12	1,02	3,64
h22	1986	40,18	89,49	9,99	14,37	0,86	3,07
h23	1987	39,39	90,00	1,00	14,14	0,98	3,31
h24	1987	32,83	84,27	1,00	11,71	0,99	3,62
base*	1988	41,78	177,85	9,30	19,70	1,74	8,34

* Verwendung des bearbeiteten Datensatzes.

In Abbildung 3.1 sieht man für die einzelnen Stunden den Verlauf der Mittelwerte, aufgespaltert auf alle Wochentage. Im Allgemeinen erkennt man, dass Preise an Werktagen größer sind als an Wochenenden. Sie haben aber einen ähnlichen Verlauf

innerhalb des Tages. Ab 5 Uhr, für Wochenenden ab 7 Uhr, beginnen die Preise zu steigen, bis sie ihre erste und größte Spitze um 12 Uhr erreichen. Dann fallen die Preise bis ca. 17 Uhr. Gegen 19 Uhr ist dann ein zweiter Hochpunkt sichtbar. Danach sinken die Preise bis sie am Morgen ihren Wendepunkt erreichen.

Interessant sind die markanten Abweichungen zwischen Samstag und Sonntag. Dies könnte unter Umständen auf eine unterschiedliche Dynamik innerhalb der Woche schließen lassen. Die einzelnen Werkzeuge haben ein relativ ähnliches Muster. Einzig der Freitag hat zu späteren Stunden ein geringeres Preisniveau, was auf einen früheren Feierabend am Arbeitsplatz zurückzuführen ist. Am Montag hingegen ist an frühen Morgenstunden mit niedrigeren Preisen zu rechnen, was auf eine verringerte Motivation zu Wochenbeginn schließen lässt.




Abbildung 3.1.: Durchschnittliche Stundenpreise gesplittet auf Wochentage

Aufgrund von Abbildung 3.1 lässt sich ein erster Eindruck darüber gewinnen, dass neben einer deutlichen Tagessaison auch Wochenzyklen vorhanden sein könnten. Da nur das Blockprodukt bEXAbase für weitere Analysezwecke verwendet wird, haben wir nur mit täglichen Daten zu rechnen. Somit entfällt die Tagessaison.

3.2. Tägliche Spotstrompreise

Die täglichen Strompreise der österreichischen Energiebörse EXAA sind in Abbildung 3.2 ersichtlich. Der gesamte Datensatz umfasst den Zeitraum von Dienstag, dem 11. Februar 2003 bis Montag, dem 21. Juli 2008.

Theoretisch reicht die Beobachtungsperiode nicht von Dienstag bis Montag, sondern von Montag bis Freitag, da an der Börse am Montag der Preis für Dienstag im Voraus bestimmt wird und am Freitag die Preise für Samstag, Sonntag und Montag.

Die gesamte, chronologische Zeitreihe umfasst insgesamt 1988 Beobachtungen bzw. 284 vollständige Wochen. Alle Preise sind in Euro pro Megawattstunde angegeben.




Abbildung 3.2.: bEXAbase (11.02.2003 - 21.07.2008)

Zum Zwecke einer späteren out-of-sample Prognose müssen wir den Datensatz in zwei Abschnitte teilen. Die out-of-sample Periode beinhaltet ungefähr die letzten 10 Prozent der Beobachtungen und wird benützt, um später die Vorhersageeigenschaften zu evaluieren. Der genaue Zeitraum umfasst die Preise von Dienstag, 29. Januar 2008 bis Montag, 21. Juli 2008. Dies sind 175 Beobachtungen bzw. 25 Wochen. Mit der in-sample Periode werden die Modellspezifikationen durchgeführt. Alle berechneten Modelle verwenden nur die ersten 1813 Datenwerte. Der in-sample Zeitabschnitt von Dienstag, 11. Februar 2003 bis Montag, 28. Januar 2008 beinhaltet somit die ersten 259 Wochen. Beide Perioden sind im Appendix als Abbildung A.1 und A.2 separat wiedergegeben.

Tabelle 3.2 zeigt einige deskriptive Statistiken für verschiedene Zeitabschnitte. Die Jahre 2004 und 2008 sind Schaltjahre. Dies spiegelt sich auf die Anzahl der Observationen pro Jahr wider. Die Jahre 2003 und 2008 sind natürlich unvollständig, bezogen auf ein gesamtes Jahr.

Tabelle 3.2.: Deskriptive Statistiken von bEXAbase (verschiedene Perioden)

	Obs.	Mean	Max.	Min.	Std. Dev.	Skewness	Kurtosis	p*
Gesamt	1988	41,78	177,85	9,30	19,70	1,74	8,34	0,00
in-sample	1813	39,68	177,85	9,30	18,82	2,15	11,04	0,00
out-of-sample	175	63,55	109,75	32,78	14,77	0,29	3,01	0,28
2003	324	31,12	164,88	9,30	14,60	3,59	28,33	0,00
2004	366	28,71	44,24	13,43	6,10	-0,54	2,83	0,00
2005	365	46,46	140,00	11,50	18,35	2,24	10,00	0,00
2006	365	50,97	177,85	16,00	19,93	1,97	11,62	0,00
2007	365	38,96	152,38	13,60	20,28	2,21	9,08	0,00
2008	203	62,52	109,75	30,20	14,62	0,27	3,13	0,27

* p-Wert des Jarque-Bera Tests.

Abgesehen von 2004 und 2007 scheint es über die Jahre hinweg einen Anstieg in den Preisen gegeben zu haben. 2004 war das ruhigste und billigste Jahr, bezogen auf Standardabweichung, Mittelwert und Maximalwert. Das Jahr 2007 weist einen relativ niedrigen Mittelwert auf, verglichen mit den beiden vorigen Jahren. Trotzdem hat dieses Jahr die höchste Volatilität der Preise aufzuweisen.

Bis auf die out-of-sample Periode und das Jahr 2008 sind alle anderen Zeitreihen nicht normal verteilt. Die p-Werte des Jarque-Bera Tests sind nur für den letzten Abschnitt der gesamten Zeitreihe größer als 0,10. Deswegen kann die Nullhypothese normal verteilter Preise im Jahr 2008 nicht verworfen werden. Die Skewness, ein Maß der Schiefe bzw. Asymmetrie, hat annähernd den geforderten Wert von Null. Die Kurtosis der anderen Zeitabschnitte liegt über dem für eine Normalverteilung typischen Wert von 3. Dies impliziert, dass die Dichte der Verteilung stärker an den Rändern liegt bzw. fette Enden hat. Eine starke Konzentration der Werte um den Mittelwert ist ebenfalls eine Erklärung [Bera & Jarque (1980) und (1981)].

Ein bedeutendes Merkmal des Datensatzes ist die Wochensaison. Zoomt man in die Daten und schaut sich die Preise von jedem Jahr separat an, ist diese Saison eindeutig zu erkennen. Im Appendix sind unter Abbildung A.3 - A.8 alle einzelnen Jahresabschnitte von 2003 bis 2008 separat ersichtlich. Die Samplegröße wurde hierfür erweitert, damit die Jahre 2003 und 2008 nicht verzerrt dargestellt werden. So soll ein einfaches Vergleichen von möglichen Sommer- und Winterextremwerten ermöglicht werden.

Zählt man die markanten Spitzen bzw. Schwingungen in den Graphen für jedes Jahr, kommt man auf die obligatorischen 52 Wochen pro Jahr, bzw. knapp 47 Wochen im Jahr 2003 und 29 Wochen im Jahr 2008. Das sind insgesamt 284 Spitzen für jeweils 284 Wochen die unsere Zeitreihe enthält.

Aus den jeweiligen Jahresgraphen ist ersichtlich, dass 2004 ein eher ruhiges Jahr war, bezüglich Preisschwankungen. Gleiches könnte man auch für die erste Jahreshälfte 2008 schlussfolgern. Rein optisch ist nicht ersichtlich, ob es einen deterministischen Jahreszyklus gibt. Für die Jahre 2005 und 2007 gab es vor der Weihnachtszeit höhere Preisschwankungen. In den anderen Jahren tritt dieses Phänomen nur unscheinbar auf. Im Jahre 2007 sind diese Preisschwankungen womöglich mit politischen Spannungen zwischen Russland und der Ukraine zu erklären. In diesem Winter kam es zu einer Unterbrechung von Gaslieferungen. Aufgrund der geringer werdenden Lagermengen waren die Börsenteilnehmer bereit, höhere Gebote abzugeben. Das niedrigere Angebot an fossilen Brennstoffen führte somit zu höheren Unsicherheiten im Bereich Energieversorgung und dies spiegelte sich auf das Preisniveau wider.

Ebenfalls auffällig ist, dass die jeweils letzte Woche im Jahr einen markanten Preisabfall zu verzeichnen hat. Dies könnte mit den Weihnachtsferien direkt erklärt werden. In dieser Zeit haben viele Unternehmen und Einkaufszentren geschlossen und so ist eine generell niedrigere Energiemenge erforderlich.

Für die Jahre 2003 und 2006 sind höhere Preise für die Sommerzeit zu erkennen. Jedoch ist dies nicht für die anderen Jahre deutlich ersichtlich. Im Jahre 2005 und 2007 ist Anfang August sogar ein geringfügiger Preisrückgang zu verzeichnen. Eine mögliche Erklärung dafür könnten die vielen Urlaubsreisen zu dieser Zeit sein. Viele Häuser und Wohnungen sind im Sommer leer, sodass man nicht generell auf einen erhöhten Preis im Sommer schließen kann. Im Jahre 2003 war der berühmte Jahrhundertssommer, mit einer extrem heißen Periode im August. Dies könnte die damaligen Preisschwankungen erklären.

Die Daten scheinen bis auf die regelmäßige Wochensaison keine weiteren jahres-spezifischen Muster aufzuweisen. Sommer- und Winterschwankungen sind eher unregelmäßig. Man könnte auch vermuten, dass der Datensatz zu wenige Jahre umfasst, um eine klare Interpretation zu geben. Aber trotzdem ist an dieser Stelle zu vermuten, dass sich Dummyvariablen für die einzelnen Monate als nicht all zu hilfreich erweisen sollten.

In Tabelle 3.3 wurde die Zeitreihe in Gruppen verschiedener Preisspannen unterteilt. Somit soll die Anzahl an möglichen Ausreißern veranschaulicht werden. Man sieht, dass 95 Prozent der Observationen einen Preis von unter 80 Euro aufweisen. Die Preisspanne mit den häufigsten Beobachtungen liegt zwischen 20 und 40 Euro. Die Anzahl an Ausreißern mit einem Wert von über 100 Euro liegt gerade einmal bei 25. Diese machen nur 1,26 Prozent des Datensatzes aus. Das dazugehörige Histogramm in Abbildung 3.3 soll die Verteilung der Daten noch deutlicher veranschaulichen. Wie oben bereits getestet ist hier noch einmal optisch zu erkennen, dass die gesamte Zeitreihe nicht normal verteilt ist. Vor allem ist eine relativ starke Asymmetrie zu beobachten.

Tabelle 3.3.: Klassenhäufigkeiten von bEXAbase (gesamter Datensatz)

	Mean	Std. Dev.	Obs.	Obs. in %	kumulierte Obs. in %
[0, 20)	16,44	2,70	129	6,49	6,49
[20, 40)	30,73	4,95	1012	50,91	57,39
[40, 60)	48,28	5,43	544	27,36	84,76
[60, 80)	68,22	5,54	204	10,26	95,02
[80, 100)	88,05	5,19	74	3,72	98,74
[100, 120)	108,03	6,77	13	0,65	99,40
[120, 140)	129,69	5,11	5	0,25	99,65
[140, 160)	146,42	7,42	4	0,20	99,85
[160, 180)	170,91	6,53	3	0,15	100,00
Gesamt	41,78	19,70	1988	100,00	




Abbildung 3.3.: Histogramm von bEXAbase (gesamter Datensatz)

Ausreißer bzw. Preisspitzen lassen sich, wie in Kapitel 2.1 erörtert, durch Fluktuationen im Bereich Angebot und Nachfrage erklären. Wenn genügend unerwartete Schocks im selben Zeitraum zustande kommen, kann ein unverhältnismäßig hoher Preis entstehen.

Eine von Crespo Cuaresma et al. (2004) verwendete Herangehensweise war, diese Preissprünge zu lokalisieren und aus dem Datensatz zu entfernen. Diese Methode, gewisse Datenpunkte komplett zu entfernen, lehne ich ab. Dadurch würden Informationen verloren gehen, die für die Modellierung der Wochensaison wichtig wären.

Laut Aussagen der EXAA zeichnen sich die Preise der österreichischen Energiebörse vor allem dadurch aus, dass sie relativ zu anderen europäischen Energiebörsen eine geringere Volatilität besitzen. Die Glaubwürdigkeit dieser These sei dahingestellt, vor allem da nur das Jahr 2007 untersucht wurde, siehe EXAA (2008b) und (2008c). Der Vergleich ist unter Abbildung A.9 im Appendix vorzufinden.

Aufgrund von einigen unregelmäßigen Ausreißern und einem leichten positiven Anstieg unserer Zeitreihe, könnte man darauf schließen, dass die Zeitreihe nicht schwach stationär ist. Um genauer zu sein, scheint die Kovarianz-Stationarität verletzt zu sein. Diese wird durch folgende 3 Bedingungen an die ersten und zweiten Momente eines stochastischen Prozesses X_t definiert [Schira (2003)]:

$$E(X_t) = \mu \quad \forall t, \quad \mu \in \mathfrak{R} \quad (3.1)$$

$$Var(X_t) = \sigma^2 \quad \forall t, \quad \sigma^2 \in \mathfrak{R}^+ \quad (3.2)$$

$$Cov(X_t, X_{t-h}) = \gamma(h) \quad \forall t, \forall h, \quad \gamma(h) \in \mathfrak{R} \quad (3.3)$$

Bedingungen (3.1) - (3.3) implizieren, dass Mittelwert, Varianz und Kovarianz konstant über die Zeit sein müssen. Vor allem die ersten beiden Bedingungen könnten für unsere Zeitreihe verletzt sein, da Erwartungswert und Varianz scheinbar für verschiedene Zeitabschnitte variieren. Wie in Tabelle 3.2 sichtbar, unterscheidet sich vor allem das Jahr 2004 stark von den anderen Perioden.

Ein Test der Zeitreihe auf eine Unit Root soll diese Frage klären. Wir verwenden den Augmented Dickey-Fuller Test. Ohne die Miteinbeziehung zusätzlicher Lags sind die p-Werte des Ljung-Box Q-Tests für die Residuen nicht alle größer als 0,10. Somit wären die Fehler bzw. die Residuen nicht white noise¹ [Box & Ljung (1979)] und eine Bedingung für den Dickey-Fuller Test wäre verletzt. Die Ergebnisse für verschiedene Perioden sind in Tabelle 3.4 sichtbar.

Die Definition von white noise lautet wie folgt [Schira (2003)]: Ein stochastischer Prozess ε_t definiert sich als white noise oder weißes Rauschen, wenn:

$$E(\varepsilon_t) = 0 \quad (3.4)$$

$$Var(\varepsilon_t) = \sigma_\varepsilon^2 \quad \forall t \quad (3.5)$$

$$Cov(\varepsilon_t, \varepsilon_{t-h}) = 0 \quad \forall t, \forall h \quad (3.6)$$

Da unsere Zeitreihe scheinbar langfristig einen leichten Anstieg zu verzeichnen hat, nehmen wir a priori an, dass ein deterministischer, linearer Trend plausibel für eine Modellspezifikation ist. Somit wird der ADF- τ Test verwendet, der Intercept und

¹ Es ist zu beachten, dass sich die white noise Nullhypothese des Ljung-Box Q-Tests auf die Eigenschaften des Fehlerprozesses beziehen. Dieser ist im Allgemeinen nicht beobachtbar. Somit können nur die Residuen, welche aus der Schätzung hervorgehen, überprüft werden.

Trend beinhaltet. Die Laglängen der ADF- τ Tests wurden durch das Minimum des AIC bestimmt. Dabei wurde eine maximale Laglänge von 40 angenommen.

Sowohl für die gesamte Zeitreihe als auch für die in-sample Periode, die später für unsere Modellspezifikationen wichtig sein wird, kann die Nullhypothese einer Unit Root auf dem 5% Signifikanzniveau verworfen werden. Die Laglänge des ADF- τ Tests stellte sich laut AIC für beide Perioden mit 35 heraus.

Tabelle 3.4.: Augmented Dickey-Fuller Test (verschiedene Perioden)

Null Hypothesis: BASE has a unit root
Exogenous: Constant, Linear Trend

	t-Statistic	Prob.*
gesamter Datensatz Lag Length: 35 (Automatic based on AIC, MAXLAG=40)		
Augmented Dickey-Fuller test statistic	-3.728337	0.0207
Test critical values:		
1% level	-3.962750	
5% level	-3.412112	
10% level	-3.127973	
in-sample Periode Lag Length: 35 (Automatic based on AIC, MAXLAG=40)		
Augmented Dickey-Fuller test statistic	-3.665642	0.0249
Test critical values:		
1% level	-3.963215	
5% level	-3.412340	
10% level	-3.128108	
out-of sample Periode Lag Length: 21 (Automatic based on AIC, MAXLAG=40)		
Augmented Dickey-Fuller test statistic	-2.540212	0.3086
Test critical values:		
1% level	-4.011352	
5% level	-3.435708	
10% level	-3.141907	

*MacKinnon (1996) one-sided p-values.

Der ADF- τ Test für die out-of-sample Periode hat ein unterschiedliches Ergebnis. Die Nullhypothese einer Unit Root kann auf keinem der üblichen Signifikanzniveaus verworfen werden. Da aber nur die letzten 10 % der Beobachtungen getestet werden, und die gesamte Zeitreihe für schwach stationär befunden wurde, ist die power des ADF- τ Tests für diese kleine Periode sicher geringer. Wir werden uns auf die

Ergebnisse der größeren Zeitabschnitte verlassen und keine Differenzierung unserer Daten vornehmen.

Bezüglich Unit Root und Dickey-Fuller Test siehe unter anderem Brockwell & Davis (2002), Greene (2000) und Hamilton (1994).

3.3. Testregression

Eine Testregression mit Dummyvariablen für die verschiedenen Wochentage (diese sind 1 für gewisse Tage und sonst 0, siehe Kapitel 4.1) soll einen Anhaltspunkt liefern, wie sinnvoll eine deterministische Wochensaison sein könnte. Dabei werden verschiedene Zeitabschnitte betrachtet, um Veränderungen der Koeffizienten zu beobachten. Eine Konstante wurde in der Gleichung natürlich nicht verwendet, da wir sonst perfekte Multikollinearität hätten. Alle Werte wurden auf zwei Dezimalstellen genau gerundet.

Tabelle 3.5.: Regression mit Dummyvariablen für Wochentage

	Obs.	R ²	TUE	WED	THU	FRI	SAT	SUN	MON
Gesamt	1988	0,16	48,42	48,04	46,88	43,79	33,65	26,33	45,38
in-sample	1813	0,17	45,97	45,83	44,71	41,58	31,61	24,68	43,40
out-of-sample	175	0,46	73,79	70,99	69,37	66,61	54,81	43,36	65,90
2003	324	0,27	38,70	37,03	35,52	31,98	22,79	16,81	34,73
2004	366	0,58	32,89	32,25	31,31	30,08	24,43	19,18	30,78
2005	365	0,18	52,05	53,32	51,13	48,42	37,99	31,53	50,91
2006	365	0,26	58,44	59,26	58,08	54,22	40,71	30,91	55,56
2007	365	0,17	46,29	44,81	45,30	41,08	29,99	22,79	42,43
2008	203	0,45	71,35	70,41	68,50	65,42	53,40	42,89	65,67

* Koeffizient ist nicht signifikant auf dem 1% Signifikanzniveau.

Alle Koeffizienten sind höchst signifikant auf dem 1 % Signifikanzniveau. Berechnet man für jedes einzelne Jahr den Durchschnitt der Koeffizienten, so kommt man auf die jeweiligen Jahresmittelwerte die in Tabelle 3.2 ersichtlich sind.

Für die Periode 2004 erhalten wir das beste R². Laut Tabelle 3.2 war dies auch der Zeitraum mit der geringsten Volatilität. Es gab keine unerwartet großen Schocks und scheinbar lassen sich die Daten dann sehr gut durch einfache Dummyvariablen modellieren. Dies sind wiederum deutliche Anzeichen für das Vorhandensein einer Wochensaison. Ebenfalls interessant ist das besonders hohe R² im Jahre 2008 bzw. in der out-of-sample Periode. Scheinbar hat das Evaluationssample andere Eigen-

schaften als der restliche Datensatz. In der in-sample Periode ist der Einfluss purer Dummyvariablen nicht so groß. Dieser Unterschied könnte eventuell nicht zum gewünschten Erfolg beim späteren Prognostizieren der Zeitreihe führen.

Die Jahre 2005 bis 2007 weisen die schlechtesten Werte für das R^2 auf. Dies lässt sich auch mit der besonders hohen Varianz dieser Zeitabschnitte vereinbaren. Die Dummyvariablen sind alleine nicht in der Lage die großen Schwankungen zu modellieren.

Abbildung A.10 im Appendix visualisiert die Veränderungen der Koeffizienten. Der kontinuierliche Preisanstieg über die Zeit, mit Ausnahme der Jahre 2004 und 2007, ist klar ersichtlich. Die jeweils höchsten Durchschnittspreise bilden die Werktage Dienstag und Mittwoch. Interessant ist die Entwicklung von 2003 bis 2004. Scheinbar nähern sich die Koeffizienten einander an. 2005 und 2006 driften alle Koeffizienten wieder stärker auseinander, verbleiben aber in einem überschaubaren Zusammenhang zueinander. Dies könnte ein Anzeichen für eine nichtkonstante Wochensaison darstellen, die abhängig vom Zeitverlauf unterschiedliche Ausmaße annimmt. Die relativ stark variierenden einzelnen Koeffizienten lassen darauf schließen, dass die Mittelwerte nicht konstant über die Jahre sind. In diesem Fall wäre eine deterministische Saison nicht angemessen.

Ein Test, ob eine deterministische Wochensaison unsere Daten angebracht beschreiben kann, im Sinne eines Canova-Hansen oder Caner Tests [Ghysels & Osborn (2001)], halte ich für unnötig. Denn das Ziel dieser Studie ist es, direkt über die Vorhersageeigenschaften zu vergleichen, ob autoregressive moving average Modelle mit einer deterministischen Saison bessere Ergebnisse liefern als periodische autoregressive Prozesse. Zusätzlich soll auch eine separate Behandlung der Wochentage durchgeführt werden. Eine Beschreibung dieser einzelnen aufgespalteten Zeitreihen findet sich im nächsten Kapitel.

3.4. Wöchentliche Spotstrompreise

Der gesamte Datensatz wurde auf seine einzelnen Wochentage aufgespalten. Da die 1988 Beobachtungen genau 284 Wochen entsprechen, erhalten wir demnach 284 Datenpunkte für jede der sieben separaten Zeitreihen. Da der gesamte Datensatz am Dienstag anfängt, behandeln wir diesen Wochentag immer als ersten.

Abbildung 3.4 veranschaulicht alle 284 Werte der einzelnen Wochentage. Für die späteren Regressionen verwenden wir nur die ersten 259 Werte bzw. Wochen, wie für die Modellierung der chronologischen Zeitreihe. Die restlichen 25 Wochen dienen der out-of-sample Prognose. Eine genaue Visualisierung aller sieben Wochentage einzeln ist im Appendix unter Abbildung A.11 - A.17 vorzufinden.

Man sieht, dass nun keine erkennbare Saison innerhalb der sieben einzelnen Zeitreihen mehr vorhanden ist. Ein augenscheinlicher Monats- oder Jahreszyklus ist auch nicht zu erkennen.




Abbildung 3.4.: Wöchentliche Spotstrompreise (gesamter Datensatz)

Tabelle 3.6.: Deskriptive Statistiken der Wochentage (gesamter Datensatz)

	Obs.	Mean	Max.	Min.	Std. Dev.	Skewness	Kurtosis	p*
Tue	284	48,42	164,88	18,75	21,33	1,83	7,65	0,00
Wed	284	48,04	170,00	18,00	20,98	1,85	8,30	0,00
Thu	284	46,88	177,85	10,41	21,06	2,06	10,60	0,00
Fri	284	43,79	153,30	11,41	18,38	1,69	7,81	0,00
Sat	284	33,65	65,60	11,53	12,15	0,82	2,78	0,00
Sun	284	26,33	55,75	9,50	10,03	0,74	2,68	0,00
Mon	284	45,38	129,00	9,30	19,15	1,20	4,35	0,00

* p-Wert des Jarque-Bera Tests.

Bei einer genaueren Betrachtung stellt man fest, dass der Verlauf der einzelnen Werkzeuge sich durchaus kreuzen kann. Trotzdem führen diese 5 Zeitreihen eine relativ ähnliche Bewegung über die Zeit durch. Am auffälligsten sind die markant niedrigeren Preise am Wochenende, wobei das Preisniveau am Sonntag fast immer

geringer ist als am Samstag. Ebenfalls kreuzen sich diese beiden Zeitreihen so gut wie nie.

Tabelle 3.6 zeigt einige deskriptive Statistiken für alle sieben Zeitreihen. Hierbei bestätigen sich unsere Erwartungen bezüglich der Mittelwerte. Ebenfalls sind die Varianzen am Wochenende geringer. Die Nullhypothese einer Normalverteilung wird wie beim gesamten chronologischen Datensatz verworfen. Die p-Werte der Jarque-Bera Tests sind für alle Wochentage 0,00.

Beim Testen auf eine Unit Root verwenden wir wieder den Augmented Dickey-Fuller- τ Test für die jeweiligen in-sample-Perioden, siehe Tabelle 3.7. Die Laglänge des ADF- τ Tests wird durch das Minimum des AIC Informationskriteriums bestimmt wobei eine maximale Laglänge von 20 festgesetzt wurde. Die p-Werte des Ljung-Box Q-Tests für die Residuen aller 7 Regressionen sind alle größer als 0,10. In diesem Testszenario werden somit für alle 7 Spezifikationen die Fehler als white noise angenommen.

Die Nullhypothese einer Unit Root kann für alle 5 Zeitreihen der Werktage verworfen werden. Für Montag bis Donnerstag auf dem 1% Signifikanzniveau, für Freitag kann die Verwerfung der Nullhypothese nur auf dem 5% Signifikanzniveau erfolgen.

Für Samstag und Sonntag hingegen kann die Nullhypothese einer Unit Root auf keinem der üblichen Signifikanzniveaus verworfen werden. Erkennbar ist, dass AIC für die Wochenenden höhere Laglängen auswählt als für die Werktage. Vertraut man dem BIC Informationskriterium die Auswahl der Laglänge an, so ergeben sich kleinere Modelle. Für die ADF- τ Tests mit dem BIC als Minimierungskriterium ergibt sich, dass alle sieben Zeitreihen schwach stationär sind. Da eine Verwerfung der Unit Root Nullhypothese für Samstag und Sonntag je nach Auswahl der Laglänge stark variiert, müssen wir eine Entscheidung treffen.

Da sowohl die gesamte chronologische Zeitreihe, als auch die meisten Wochentage der separaten Datensätze allem Anschein nach schwach stationär sind, werden wir weiterhin mit den Niveauwerten der Spotstrompreise arbeiten. Ein Differenzieren erscheint mir nicht angebracht. Eine optische Begutachtung der Wochenendzeitreihen zeigt keine all zu großen Unterschiede zu den Werktagen bezüglich Varianz- und Erwartungswertfluktuation über die Zeit. Ebenfalls wäre die Annahme, gewisse Wochentage beruhen auf $I(0)$ -Modellen und gewisse auf $I(1)$ eher unlogisch. Dies würde nämlich implizieren, dass über lange Sicht die Preise der Wochentage auseinander driften würden. Da diese Annahme für unsere Daten und Spotstrompreise im Allgemeinen nicht überzeugend genug gegeben ist, entscheiden wir uns für die relativ plausible Erklärung, dass $I(0)$ -Modelle alle Wochentage angebracht beschreiben können.

Tabelle 3.7.: Augmented Dickey-Fuller Test für alle Wochentage (in-sample Datensatz)

Exogenous: Constant, Linear Trend
(Lag Length: Automatic based on AIC, MAXLAG=20)

	t-Statistic	Prob.*
Null Hypothesis: TUE has a unit root Lag Length: 2		
Augmented Dickey-Fuller test statistic	-4.661252	0.0010
Null Hypothesis: WED has a unit root Lag Length: 2		
Augmented Dickey-Fuller test statistic	-4.548437	0.0015
Null Hypothesis: THU has a unit root Lag Length: 3		
Augmented Dickey-Fuller test statistic	-4.323580	0.0034
Null Hypothesis: FRI has a unit root Lag Length: 3		
Augmented Dickey-Fuller test statistic	-3.918663	0.0126
Null Hypothesis: SAT has a unit root Lag Length: 6		
Augmented Dickey-Fuller test statistic	-2.180050	0.4982
Null Hypothesis: SUN has a unit root Lag Length: 5		
Augmented Dickey-Fuller test statistic	-2.598391	0.2815
Null Hypothesis: MON has a unit root Lag Length: 2		
Augmented Dickey-Fuller test statistic	-4.648073	0.0011

*MacKinnon (1996) one-sided p-values.

4. Beschreibung der Modelle

Dieses Kapitel soll eine kurze Darstellung der verwendeten Modelle illustrieren. Die für den empirischen Teil in Betracht gezogenen linearen, univariaten Modelle sind einerseits autoregressive moving average Modelle (im weiteren mit ARMA Modelle abgekürzt). Die einfache Erweiterung mit Dummyvariablen wird erklärt, genauso wie die Beschreibung der ARMA Modelle für die separaten Zeitreihen. Zuletzt werden die periodischen autoregressiven Modelle vorgestellt.

4.1. Autoregressive moving average Modelle

In diesem Abschnitt werden kurz autoregressive moving average Modelle beschrieben sowie die Erweiterung mit Dummyvariablen erklärt. Diese sind in der Regel gebräuchlich um einfache, konstante Saisonmuster zu beschreiben. Unsere ARMA Modelle mit einer deterministischen Saison sollen als generelles Bezugsmodell dienen, um die Prognoseeigenschaften der anderen beiden Modellklassen vergleichen zu können.

Wir betrachten eine Zeitreihe y_t mit $t = 1, \dots, n$ wobei für die in-sample Periode $n = 1813$ gilt. Die Spezifikation eines autoregressiven Modells der Ordnung p lautet

$$y_t = \mu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + z_t, \quad (4.1)$$

wobei $\phi_1, \dots, \phi_p$ unbekannte Parameter sind und μ die Konstante widerspiegelt. z_t stellt den Fehlerterm dar der white noise sein sollte. Andernfalls lässt sich daraus schließen, dass in den Residuen z_t weiterhin eine Struktur enthalten ist. Somit wäre die Linearkombination der vergangenen p Beobachtungen nicht ausreichend um den stochastischen Prozess y_t adäquat zu beschreiben. Ein moving average Prozess der Ordnung q mit $\mu = 0$ wird durch folgende Gleichung beschrieben:

$$z_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (4.2)$$

ε_t sollte white noise sein. $\theta_1, \dots, \theta_q$ sind ebenfalls unbekannte Parameter. Ersetzt man den white noise Prozess z_t aus (4.1) mit der Gleichung in (4.2), so erhält man einen ARMA(p, q) Prozess. Durch eine simple Umformung kann ein ARMA Modell der Ordnung p und q wie folgt angeschrieben werden:

$$y_t - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p} = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (4.3)$$

Berechnungen von ARMA Modellen erfolgen hierbei durch die Methode der kleinsten Quadrate Schätzer (Ordinary Least Squares). Das Hauptaugenmerk liegt aber in der Bestimmung der Lagordnung für p und q. Da uns diese in der Regel unbekannt sind, muss eine adäquate Herangehensweise zu deren Bestimmung angewendet werden.

Eine berühmte Idee von Box & Jenkins (1976) war die Autokorrelationsfunktion und die partielle Autokorrelationsfunktion der Zeitreihe zu begutachten, um die richtige Größe von p und q zu bestimmen.

Bezüglich Autokorrelationsfunktion (ACF) und partielle Autokorrelationsfunktion (PACF) siehe unter anderem Box & Jenkins (1976), Brockwell & Davis (2002) und Schira (2003).

Wenn eine optische Bestimmung nicht eindeutig möglich ist, gibt es eine andere Möglichkeit. Man schätzt ARMA(p,q) Modelle für mehrere Kombinationen von p und q und vergleicht mindestens ein Informationskriterium. Oft werden hierbei das Akaike Informationskriterium AIC [Akaike (1973) und (1974)] und das Schwarz Informationskriterium BIC [Schwarz (1978)] genannt.

Mit AIC hat man das Risiko zu große Modelle zu spezifizieren, die sich aber in der Regel gut für Prognosen eignen. BIC wählt, durch seinen größeren Strafterm für zusätzliche, eventuell unnütze Variablen, kleinere Modelle aus. Jedoch soll bei großen Stichproben bzw. $t \rightarrow \infty$ das BIC eher das theoretisch wahre Modell auswählen.

Das Modell welches das Informationskriterium minimiert sollte gewählt werden. Dabei muss man bei diesem Verfahren letztendlich auch testen, ob der Fehlerterm white noise ist. Dieser ist jedoch nicht beobachtbar. Deswegen können nur die Residuen, die aus der Schätzung stammen, herangezogen werden. Die Überprüfung der white noise Nullhypothese erfolgt mit dem Ljung-Box Q-Test [siehe Box & Ljung (1979)]. Wird die Annahme verworfen könnte es sein, dass weitere Strukturen und Prozesse nicht mitberücksichtigt wurden.

Bezüglich ARMA Modelle siehe auch Box & Jenkins (1976), Franses (1996), Greene (2000) und Hamilton (1994).

Eine zusätzliche Erweiterung stellen Dummyvariablen dar. Diese ermöglichen es unter anderem die Konstante μ so zu spezifizieren, dass sie über eine deterministische Saison variiert, siehe unter anderem Crespo Cuaresma et al. (2004) und Franses (1996). Der zeitabhängige Intercept μ_s kann in einem ARMA Modell wie folgt spezifiziert werden:

$$\mu_s = \sum_{s=1}^S \delta_s D_{s,t}, \quad (4.4)$$

wobei δ_s die saisonabhängigen Mittelwerte symbolisiert und $D_{s,t}$ die S verschiedenen Dummyvariablen darstellt. Diese nehmen für gewisse Zeitpunkte t den Wert 1 an und sind sonst 0. In Matrixschreibweise bilden Dummyvariablen einen

(nx1) Vektor. Für ein Beispiel mit $S = 4$, also einer Quartalssaison, und $\frac{n}{S} = N$ mit $N \in \mathbb{N}^+$ (N ist die Anzahl an Schwingungen bzw. Saisonzyklen pro Samplegröße, in diesem Fall die Anzahl der vollständigen Jahre), bilden die Dummyvariablen eine (nx4) Matrix, die transponiert wie folgt aussieht:

$$D' = \begin{bmatrix} D_1' \\ D_2' \\ D_3' \\ D_4' \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & \dots & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & \dots & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & \dots & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & \dots & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.5)$$

Diese Methode kann für unsere Daten mit $S=7$ für eine deterministische Wochensaison erweitert werden. Ebenfalls können durch Dummyvariablen zusätzlich weitere, sich überlagernde, deterministische Saisonen miteinbezogen werden. So kann μ_s sowohl für verschiedene Wochentage variieren, aber auch je nach Monat oder Jahr, in dem man sich gerade befindet, unterschiedliche Werte annehmen. Dabei muss aber berücksichtigt werden, dass man keine perfekte Multikollinearität durch zu viele Dummyvariablen hervorruft.

Eine weitere Erweiterung stellt ein linearer, deterministischer Trend τ dar. Dieser soll einen eventuellen langfristigen Anstieg der Preise modellieren und kann mit $\lambda \cdot \tau_t$ beschrieben werden, wobei τ_t in Matrixschreibweise einen (nx1) Vektor bildet mit linear ansteigenden Werten von 0 bis (n-1).

4.2. Separate autoregressive moving average Modelle

Hier benützen wir das gleiche ARMA Modell wie in Kapitel 4.1, nur wenden wir dieses auf die 7 separaten Zeitreihen an. Somit behandeln wir die Preisdaten von jedem Wochentag einzeln, ohne Berücksichtigung der anderen Tage. Es werden nur jene Beobachtungen hergenommen, die genau eine Woche von einander entfernt liegen. Hierbei soll der Modellierungsansatz von Crespo Cuaresma et al. (2004) und Ramanathan et al. (1997) auf die täglichen Spotstrompreise angewendet werden. Es soll erörtert werden, ob damit bessere Vorhersageergebnisse erzielt werden können, wie es mit stündlichen Preisen der Fall war.

Wir benennen jede der einzelnen S Zeitreihen mit $Y_{s,T}$ für $s = 1, \dots, S$ und $T = 1, \dots, N$. Ebenfalls definieren wir $n = S \cdot N$. Somit erhalten wir für unseren Fall mit $S = 7$ und $N = 259$ Wochen genau die $n = 1813$ Beobachtungen der in-sample Periode. T definiert für $S = 7$ in welcher Woche wir uns gerade befinden. T kann theoretisch für $S = 7$ mit $T_t = \text{int}\left\{\frac{(t-1)}{7} + 1\right\}$ berechnet werden.

Das ARMA(p,q) Modell für die separaten Wochenzeitreihen sieht wie folgt aus:

$$Y_{s,T} = \delta_s + \Phi_{s,1}Y_{s,T-1} + \dots + \Phi_{s,p}Y_{s,T-p} + \Theta_{s,1}\varepsilon_{s,T-1} + \dots + \Theta_{s,q}\varepsilon_{s,T-q} + \varepsilon_{s,T} \quad (4.6)$$

δ_s stellt die Konstante dar, die natürlich für jeden Wochentag unterschiedliche Werte aufweisen kann, und $\Phi_{s,1}, \dots, \Phi_{s,p}, \Theta_{s,1}, \dots, \Theta_{s,q}$ sind unbekannte Parameter. Der Fehlerterm $\varepsilon_{s,T}$ sollte white noise sein.

Da unsere gesamte chronologische Zeitreihe am Dienstag anfängt, setzen wir ohne Beschränkung der Allgemeinheit für $s = 1$ die Dienstagszeitreihe fest, womit sich $s = 7$ auf die Montagsdaten bezieht.

Da wir hierbei theoretisch nur wöchentliche Daten betrachten, entfällt die Wochensaison und somit verzichten wir auf die Miteinbeziehung von Dummyvariablen für diese Modellklasse. Somit modellieren wir auch keine eventuelle deterministische Jahressaison. Auch für die nächste Modellklasse, den periodischen Prozessen, werden wir keine Dummyvariablen für die einzelnen Monate oder für die verschiedenen Jahre verwenden. Die letzten beiden Modellklassen sollen somit absichtlich benachteiligt werden, um zu zeigen, dass sie ohne eine deterministische Saison eventuell bessere Prognoseergebnisse erzielen können. Für die ARMA Modelle der chronologischen Zeitreihe werden später mehrere Kombinationen der Dummyvariablen in Betracht gezogen. Somit wird eine Vergleichsmöglichkeit ohne einer deterministischen Jahressaison für alle drei Modellklassen gegeben sein.

4.3. Periodische autoregressive Modelle

Als letzte Modellklasse sollen periodische autoregressive Modelle (im Folgenden mit PAR Modell abgekürzt) herangezogen werden. Ein PAR Modell erlaubt den Parametern mit der jeweiligen Saison zu variieren. Somit unterstellt man, dass die Beobachtungen jeder Saison beschrieben werden können, indem man unterschiedliche Modelle verwendet. Diese Annahme ist angebracht, wenn man vermutet, dass sich die verschiedenen ökonomischen Agenten in jeder Saison unterschiedlich verhalten [Franses (1998)]. Da wir vermuten, dass dies vor allem für die Wochenenden zutrifft, aber auch für die Werktage generell möglich ist, möchten wir diesen Modellierungsansatz für eine Wochensaison in Betracht ziehen.

Dabei konzentrieren wir uns auf PAR Modelle, da diese Prozesse unterstellen, dass vergangene Werte voneinander abhängen und ein gewisser saisonaler Zyklus damit beschrieben werden kann. Periodische moving average Prozesse geringer Ordnung können diese Eigenschaft nicht modellieren. Vergangene Werte sind nicht miteinander korreliert, weswegen sie für uns, aber auch für viele andere ökonomische Fragestellungen uninteressant sind [Ghysels & Osborn (2001)].

Ein PAR Modell der Ordnung p kann wie folgt angeschrieben werden:

$$y_t = \mu_s + \phi_{s,1} y_{t-1} + \dots + \phi_{s,p} y_{t-p} + \varepsilon_t, \quad (4.7)$$

μ_s entspricht theoretisch genau dem oben eingeführten Ausdruck (4.4) und ε_t sollte white noise sein. $\phi_{s,1}, \dots, \phi_{s,p}$ sind unbekannte Parameter, die je nach Saison in der man sich befindet unterschiedliche Werte annehmen können.

Die Lagordnung kann je nach Saison ebenfalls unterschiedlich groß sein. Deshalb bezieht sich die Ordnung p des Gesamtmodells auf den größten Wert p der S verschiedenen Lagordnungen. D.h. das maximale p wird unter allen $\phi_{s,1}, \dots, \phi_{s,p}$ für $s = 1, \dots, S$ ausgewählt, um das Gesamtmodell PAR(p) zu benennen.

PAR(p) Modelle können ebenfalls für jede Saison einzeln angeschrieben werden, indem man die separaten Zeitreihen hernimmt. Dabei bedienen wir uns der gleichen Notation die im vorigen Kapitel eingeführt wurde. Für den einfachen Fall eines PAR(2) Modells und $S = 7$ erhalten wir folgende Darstellung für die multiple Repräsentation:

$$\begin{aligned} Y_{1,T} &= \delta_1 + \phi_{1,1} Y_{7,T-1} + \phi_{1,2} Y_{6,T-1} + \varepsilon_{1,T} \\ Y_{2,T} &= \delta_2 + \phi_{2,1} Y_{1,T} + \phi_{2,2} Y_{7,T-1} + \varepsilon_{2,T} \\ Y_{3,T} &= \delta_3 + \phi_{3,1} Y_{2,T} + \phi_{3,2} Y_{1,T} + \varepsilon_{3,T} \\ Y_{4,T} &= \delta_4 + \phi_{4,1} Y_{3,T} + \phi_{4,2} Y_{2,T} + \varepsilon_{4,T} \\ Y_{5,T} &= \delta_5 + \phi_{5,1} Y_{4,T} + \phi_{5,2} Y_{3,T} + \varepsilon_{5,T} \\ Y_{6,T} &= \delta_6 + \phi_{6,1} Y_{5,T} + \phi_{6,2} Y_{4,T} + \varepsilon_{6,T} \\ Y_{7,T} &= \delta_7 + \phi_{7,1} Y_{6,T} + \phi_{7,2} Y_{5,T} + \varepsilon_{7,T} \end{aligned} \quad (4.8)$$

In diesem Fall erlauben wir, dass die Varianz von ε_t nicht konstant sein muss. Somit kann sie ebenfalls über die Saisonen variieren. Das besondere an dieser Modellklasse ist auch die Tatsache, dass man für jede Saison unterschiedliche Laglängen für p wählen kann. Somit hat man die Möglichkeit, eine noch genauere Spezifikation der Daten vorzunehmen. Das gleiche gilt auch für die separaten ARMA Modelle. Hier sei zu erwähnen, dass ein PAR(1) Modell für jede der 7 Saisonen ungleich einem AR(1) Prozess für die separaten Zeitreihen ist. Ein spezielles PAR(7) Modell mit $\phi_{s,1} = \dots = \phi_{s,6} = 0$ wäre aber mit der Spezifikation von (4.6) mit $p = 1$ und $q = 0$ identisch.

Die Auswahl von p kann im Prinzip auf dieselbe Art und Weise wie für die ARMA Modelle erfolgen, siehe Franses & Paap (2004). Man vertraut auf eines der Informationskriterien AIC oder BIC und wählt jenes Modell, welches diese minimiert.

Eine ebenfalls mögliche Erweiterung wäre die Miteinbeziehung eines saisonalen Trends τ_s . Dieser wäre wie in Kapitel 4.1 beschrieben linear und deterministisch.

Der saisonale Trend könnte einfach durch die Subtraktion des Ausdrucks $\lambda_s \cdot \tau_{s,T}$ von jeder Zeitreihe $Y_{s,T}$ im Modell implementiert werden. Dadurch würde man aber unterstellen, dass die einzelnen Wochentage eine andere Tendenz bezüglich ihrer linearen Steigung verfolgen. Langfristig würde dies bedeuten, dass die Preise der verschiedenen Wochentage auseinanderdriften können. Dies ist aber eher unplausibel, da man vermuten kann, dass die Strompreise der Wochentage zueinander immer in einem überschaubaren Verhältnis stehen werden. Mittelfristige Abweichungen sind immer möglich. Aber eine starke Divergenz auf Dauer ist nicht anzunehmen.

Jedoch könnte ein saisonaler Trend für kurzfristige Prognosen in Betracht gezogen werden, wenn man dadurch erwartet die Vorhersagen zu verbessern. So unplausibel dies auch scheint, in der kurzen Frist wären dadurch keine logischen Annahmen verletzt. Denn es könnte vielleicht sein, dass genau in dem Zeitabschnitt, in dem wir unsere Daten beobachten, die Preise gerade unterschiedlich große Steigungen aufweisen um ein neues Verhältnis zueinander aufzubauen.

Bezüglich periodischer Modelle siehe Franses (1996), Franses & Paap (2004) und Ghysels & Osborn (2001).

5. Modellierung von täglichen Spotstrompreisen

Dieses Kapitel soll die eigentliche Modellierung der Daten veranschaulichen. Um eine gewisse Übersichtlichkeit beizubehalten werden nicht alle berechneten Modelle explizit angeführt. Es wird nur eine kleine Gruppe an ausgewählten Spezifikationen genauer betrachtet, welche sich zuvor als scheinbar vorteilhaft herauskristallisiert haben.

Ebenfalls sollte erwähnt werden, dass die Modelle nur zum Zwecke der Vorhersage heran gezogen werden. Somit betrachten wir eine Interpretation von einzelnen Koeffizienten als eher unwichtig. Die einzigen Variablen die eine durchschaubare ökonomische Interpretation zulassen würden, wären die Koeffizienten der Dummyvariablen und des linearen Trends.

Alle Berechnungen und Vorhersagen wurden mit der ökonometrischen Software EViews 5 durchgeführt [EViews (2004)].

5.1. ARMA(p,q) Modelle

Unser erster Schritt für diese Modellklasse ist es, die Autokorrelationsfunktion (ACF) und die partielle Autokorrelationsfunktion (PACF) der chronologischen Zeitreihe zu begutachten. Dafür verwenden wir hier wie auch für alle anderen Modellklassen von nun an immer nur die in-sample Periode.

Abbildung 5.1 zeigt das Correlogram von bEXAbase. Erwähnenswert ist hier dass der Ljung-Box Q-Test ein eindeutiges Ergebnis liefert. Die Nullhypothese, dass die Zeitreihe white noise ist, wird auf dem 1% Signifikanzniveau verworfen. Angrenzende Werte sind stark miteinander korreliert, was uns zu dem Schluss führt, dass in der Zeitreihe eine Struktur vorhanden ist, die wir mit ARMA(p,q) Prozessen modellieren könnten.

Die p-Werte der dazugehörigen Q-Statistik müssen für alle Laglängen größer als 0,10 sein. Dann kann die Nullhypothese von white noise auf keinem der üblichen Signifikanzniveaus verworfen werden, siehe Box & Ljung (1979).

Die ACF bricht nicht ab, sondern schwingt auf eine besondere Art und Weise. Um aus der optischen Analyse einen MA(q) Prozess schlussfolgern zu können, müsste die ACF unter anderem bei dem Lag q abbrechen [Box & Jenkins (1976)]. Dies ist nicht der Fall. Umgekehrt müsste die PACF für einen AR(p) Prozess bei dem Lag p abbrechen und die ACF müsste geometrisch abnehmen. Ein Abbrechen der PACF nach dem 8. Lag ist theoretisch zu beobachten. Jedoch ist die ACF stark präsent mit

einer wöchentlichen Schwingung, also alle 7 Lags, deren Ausprägungen aber immer kleiner werden. Rein optisch könnte man eventuell einen AR(8) Prozess annehmen.

Jedoch sieht man für die PACF wiederkehrende negative Ausprägungen für das 2., 8., 15., 22., 29. und 36. Lag. Alle in einem Abstand von 7 Laglängen. Somit ist eventuell zu erwarten, dass ARMA Prozesse höherer Ordnung notwendig sein könnten, um die Struktur innerhalb der Zeitreihe zu modellieren.




Abbildung 5.1.: Correlogram von bEXAbase (in-sample Periode)

Da wir nicht mit Sicherheit die Werte für p und q ermitteln können, schätzen wir mehrere ARMA Prozesse. Dabei testen wir alle Kombinationen von p und $q \in [0,10]$. Dies sind jeweils 121 Regressionen. Wir entscheiden uns für das BIC als Informationskriterium, da wir kleine Modelle anpassen wollen. Anhand des kleinsten BIC wird das beste Modell herausgefiltert.

Dabei variieren wir zusätzlich verschiedene deterministische Variablen. Es wird wahlweise ein linearer Trend hinzugefügt, genauso wie Dummyvariablen für die Wochentage, wie sie in Kapitel 4.1 beschrieben wurden. In der Praxis müssen es nur sechs Dummyvariablen sein, wenn die Konstante in der Gleichung beibehalten wird. Durch diese beiden zusätzlichen Möglichkeiten kommen 2^2 , also 4 verschiedene Gruppen von Modellen zum Vorschein. Dies bedeutet, dass 484 Regressionen geschätzt werden müssen.

Ebenfalls wird nach der Modellauswahl die Signifikanz der einzelnen Koeffizienten berücksichtigt. Das laut BIC beste ARMA Modell in seiner Gruppe wird überprüft, ob die einzelnen Koeffizienten signifikant auf dem 5% Signifikanzniveau sind. Ist dies nicht der Fall, so wird jene Variable, die am insignifikantesten ist, zuerst eliminiert. Sind danach weitere Koeffizienten insignifikant wird dieser Vorgang solange wiederholt, bis alle einzelnen übrig gebliebenen Koeffizienten signifikant auf dem 5% Signifikanzniveau sind.

Diese Modelle benennen wir als restringierte Modelle. Unrestringierte Modelle hingegen beinhalten alle Variablen, auch wenn diese einzeln insignifikant sind.

Durch diesen weiteren Kritikpunkt sollten wir bis zu 8 verschiedene Modelle zum Vergleichen erhalten, die sich alle als scheinbar beste Spezifikation der jeweiligen Gruppe herausgestellt haben. Diese Modelle sind in Tabelle 5.1 und 5.2 wiedergegeben, wobei nur in Tabelle 5.2 eine deterministische Wochensaison miteinbezogen wurde.

Es werden die wichtigsten Statistiken für die Regressionen mit allen Koeffizienten aufgelistet. Darunter das adjusted R^2 , die Summe der quadrierten Residuen (SSR) sowie die beiden Informationskriterien AIC und BIC. Ebenfalls wird angegeben, ob die Residuen white noise sind laut Q-Test, da dies eine Bedingung war. Laut Definition von ARMA Prozessen sollte der Fehlerterm nur weißes Rauschen sein, und keine korrelierten Informationen mehr beinhalten. Andernfalls kann man vermuten, dass weitere Strukturen innerhalb der Daten nicht mitberücksichtigt wurden.

Tabelle 5.1.: ARMA Modelle

ARMA (p,q)	(8,9)		sig (8,9)		t; sig (7,8)	
c	42,455	***	41,144	***	28,722	***
t					0,012	***
AR(1)	0,887	***	0,857	***	-0,049	***
AR(2)	0,000				-0,044	***
AR(3)	0,004				-0,042	***
AR(4)	-0,003				-0,043	***
AR(5)	0,001				-0,044	***
AR(6)	-0,001				-0,047	***
AR(7)	0,991	***	0,994	***	0,951	***
AR(8)	-0,881	***	-0,857	***		
MA(1)	-0,107	***	-0,072	**	0,838	***
MA(2)	-0,266	***	-0,249	***	0,510	***
MA(3)	-0,020				0,465	***
MA(4)	-0,013				0,432	***
MA(5)	0,000				0,427	***
MA(6)	0,059	***	0,061	***	0,487	***
MA(7)	-0,863	***	-0,867	***	-0,420	***
MA(8)	0,105	***	0,084	***	-0,263	***
MA(9)	0,220	***	0,215	***		
Adj. R ²	0,7953		0,7953		0,7957	
SSR	130045		130632		129842	
AIC	7,1351		7,1308		7,1319	
BIC	7,1900		7,1612		7,1837	
w.n.	nein		nein		nein	

* (**) [***] Koeffizienten signifikant auf dem 10% (5%) [1%] Signifikanzniveau;
w.n. (white noise) gibt an, ob alle p-Werte des Ljung-Box-Q Tests größer als
0,10 sind; t = linearer Trend; sig = restringierte Modelle.

Das ARMA(7,8) Modell mit Konstante und linearem Trend hat von vornherein nur signifikante Koeffizienten. Trotzdem können durchgehend markant bessere Werte erzielt werden, wenn eine deterministische Wochensaison hinzugefügt wird, siehe Tabelle 5.2. Es wurde hierbei für jede Kombination ein ARMA(1,9) Prozess ausgewählt. Laut BIC ist das beste Modell jenes ohne Trend aber mit Dummyvariablen und signifikanten Koeffizienten.

Alle restringierten Modelle mit signifikanten Variablen weisen bessere Werte für AIC und BIC auf, jedoch schlechtere für SSR und sie können keine Verbesserungen des Adj. R² erzielen, was zu erwarten ist.

Tabelle 5.2.: ARMA Modelle mit deterministischer Wochensaison

ARMA (p,q)	w.D (1,9)		w.D; sig (1,9)		t; w.D (1,9)		t; w.D; sig (1,9)	
c	44,418	***	44,974	***	31,789	***	32,579	***
t					0,013	**	0,013	**
Tue	2,663	***	2,286	***	2,664	***	2,287	***
Wed	2,493	**	1,518	**	2,495	**	1,519	**
Thu	1,354				1,355			
Fri	-1,786	*	-2,821	***	-1,785	*	-2,821	***
Sat	-11,774	***	-12,450	***	-11,773	***	-12,450	***
Sun	-18,716	***	-19,033	***	-18,715	***	-19,033	***
AR(1)	0,989	***	0,988	***	0,984	***	0,982	***
MA(1)	-0,214	***	-0,215	***	-0,210	***	-0,211	***
MA(2)	-0,362	***	-0,374	***	-0,359	***	-0,370	***
MA(3)	-0,089	***	-0,098	***	-0,087	***	-0,095	***
MA(4)	-0,036				-0,034			
MA(5)	-0,013				-0,012			
MA(6)	0,072	***	0,064	***	0,074	***	0,066	***
MA(7)	0,164	***	0,159	***	0,165	***	0,161	***
MA(8)	-0,082	***	-0,081	***	-0,079	***	-0,078	***
MA(9)	-0,199	***	-0,199	***	-0,197	***	-0,196	***
Adj. R ²	0,8005		0,8004		0,8008		0,8006	
SSR	126933		127236		126707		126993	
AIC	7,1059		7,1049		7,1052		7,1041	
BIC	7,1575		7,1475		7,1598		7,1497	
w.n.	nein		nein		nein		nein	

* (**) [***] Koeffizienten signifikant auf dem 10% (5%) [1%] Signifikanzniveau;
w.n. (white noise) gibt an, ob alle p-Werte des Ljung-Box-Q Tests größer als
0,10 sind; w.D = Wochendummyvariablen; t = linearer Trend;
sig = restringierte Modelle.

Interessant wäre zu sagen, dass beide Male die Dummyvariable für den Donnerstag als insignifikant klassifiziert wurde. Dies lässt darauf schließen, dass der Montag und Donnerstag ähnliche Mittelwerte aufweisen und sich nicht signifikant voneinander unterscheiden.

Anzumerken sei, dass keines der Modelle die Annahme von white noise Residuen erfüllt. Die ersten Lags des Ljung-Box-Q Tests weisen zwar insignifikante Werte auf, jedoch sind die Residuen größerer Lagordnungen miteinander korreliert. Dies ist äußerst unbefriedigend und führt zu dem Schluss, dass einfache ARMA Modelle die

Prozesse innerhalb der Daten nicht ausreichend genug beschreiben können. Abbildung 5.2 zeigt das Correlogramm der Residuen des besten Modells laut BIC.




Abbildung 5.2.: Correlogramm des restringierten ARMA(1,9) Modells mit Wochendummyvariablen

Betrachtet man auch die verschiedenen Correlogramme der anderen Regressionen, sieht man das ACF und PACF vor allem in der Nähe der Laglängen 21 und 28 signifikant sind. Fügt man gewisse AR Koeffizienten für diese Lags in die Regressionen ein, werden die p-Werte des Q-Tests insignifikant und die Nullhypothese, dass unsere Residuen white noise sind kann nicht mehr verworfen werden.

Die Auswahl der hinzugefügten AR Terme richtete sich am BIC und wurde so klein wie möglich gehalten. Ebenfalls mussten die zusätzlich in die Gleichung mitgenommenen AR Terme alle einzeln signifikant auf dem 10% Signifikanzniveau sein.

Zu erwähnen sei, dass durch diese Maßnahme die p-Werte des Ljung-Box Q-Tests weit über 0,10 liegen. Die meisten weisen Werte über 0,90 auf.

Der nächste Schritt wird sein, Dummyvariablen für die Monate und die verschiedenen Jahre mit einzubeziehen. Es soll herausgefunden werden, ob dadurch eventuelle Verbesserungen der Regressionen erzielt werden können. Die Dummyvariablen für die Wochentage werden dabei fix beibehalten. Nur wenn sich einzelne Koeffizienten als insignifikant erweisen, werden sie für die restringierten ARMA Modelle aus der Regressionsgleichung entfernt.

Nach dem Schätzen dieser Modelle stehen wir wieder vor dem Problem, dass die Residuen nicht white noise sind. Schaut man sich die ACF und PACF der betroffenen Residuen genauer an, so sieht man, dass auch hier um den 21. und 28. Lag noch ein Muster vorhanden ist. Durch das hinzufügen von AR(20), AR(22), AR(27) und AR(29) Termen verbessert sich unser Regressionsmodell. AIC und BIC werden kleiner genauso wie die Summe der quadrierten Residuen (SSR). Auch das Adj. R^2 wird besser bzw. größer. Aber der wichtigste Punkt ist, dass alle p-Werte der Ljung-Box Q-Tests größer als 0,10 sind, die meisten sogar größer als 0,90. Die Nullhypothese, dass die Residuen white noise sind, kann damit nicht verworfen werden.

In Tabelle 5.3. sind die wichtigsten Werte aller 21 geschätzten ARMA Modelle aufgelistet, die white noise Residuen aufweisen.

Unter den neuen Varianten ist das beste Modell laut BIC das signifikante ARMA(1,9) Modell mit Wochen- und Jahresdummys und ohne Trend. Insgesamt ist jedoch das gleiche Modell, in dem von vornherein keine Jahresdummys miteinbezogen wurden, besser laut BIC.

Als besondere Variante wurde noch ein Modell angeführt, dass die Laggröße p und q abhängig vom AIC ausgewählt hat. Da dieses Kriterium vor allem große Modelle bevorzugt, wollen wir die Prognoseeigenschaft von jenem Prozess untersuchen, welcher alle Dummyvariablen und den linearen Trend beinhaltet. Anzumerken sei, dass dieses angeführte Modell auch das kleinste AIC unter allen Modellen aufweist.

Das restringierte ARMA(8,4) Modell laut AIC weist für beide Informationskriterien bessere Werte auf, als das unrestringierte Modell. Letzteres weist das schlechteste BIC unter allen Modellen auf.

Den derzeitigen Ergebnissen der verschiedenen Modelle untereinander sollte aber eher wenig Beachtung geschenkt werden. Erst bei den Prognosen wird sich herausstellen, welche Modellvariante sich als vorteilhaft herausstellen wird.

Tabelle 5.3.: ARMA Modelle für bEXAbase (white noise)

ARMA	(p,q)	p*	Adj. R ²	SSR	AIC	BIC
c	(8,9)	14,16,20,21	0,7975	127993	7,1311	7,1985
c, sig.	(8,8)	14,16,20,21	0,7973	128404	7,1298	7,1850
t, sig.	(7,8)	14,16,20,21,22	0,7997	126599	7,1207	7,1881
W	(1,9)	20,22,27,29	0,8052	122957	7,0944	7,1590
W, sig.	(1,9)	20,22,27,29	0,8054	123184	7,0906	7,1398
t, W	(1,9)	20,22,27,29	0,8054	122715	7,0935	7,1612
t, W, sig.	(1,9)	20,22,27,29	0,8057	122921	7,0896	7,1419
W, M, J	(1,9)	20,22,27,29	0,8068	120825	7,0948	7,2086
W, M, J, sig.	(1,9)	20,22,27,29	0,8066	122189	7,0859	7,1443
W, M	(2,9)	20,22,27,29	0,8061	121507	7,0960	7,1975
W, M, sig.	(1,9)	20,22,27,29	0,8062	122529	7,0875	7,1429
W, J	(1,9)	20,22,27,29	0,8058	122199	7,0938	7,1738
W, J, sig.	(1,9)	20,22,27,29	0,8058	122821	7,0888	7,1411
t, W, M, J	(1,9)	20,22,27,29	0,8086	119634	7,0861	7,2029
t, W, M, J, sig.	(1,9)	20,22,27,29	0,8082	120705	7,0815	7,1615
t, W, M	(2,9)	20,22,27,29	0,8064	121269	7,0951	7,1997
t, W, M, sig.	(1,9)	20,22,27,29	0,8065	122275	7,0866	7,1450
t, W, J	(1,9)	20,22,27,29	0,8061	121960	7,0930	7,1760
t, W, J, sig.	(1,9)	20,22,27,29	0,8064	122398	7,0865	7,1418
AIC, t, W, M, J	(10,5)	20,21	0,8088	119519	7,0838	7,2094
AIC, t, W, M, J, sig.	(8,4)	20,21	0,8089	119972	7,0797	7,1839

* zusätzlich hinzugefügte signifikante AR Terms;

c = Intercept; sig = restringierte Modelle; W = Wochendummyvariablen;

t = linearer Trend; M = Monatsdummyvariablen; J = Jahresdummyvariablen.

5.2. Separate ARMA(p,q) Modelle

Die Correlogramme aller einzelnen Zeitreihen lassen den Schluss zu, dass einfache AR Modelle die Daten gut beschreiben könnten. Als Beispiel sieht man in Abbildung 5.3 das Correlogramm der Dienstagszeitreihe. Die restlichen 6 Correlogramme sind im Appendix unter Abbildung A.18 - A.23 wiedergegeben. Die ACF nimmt langsam ab und die vorwiegend ersten drei Werte der PACF sind stark signifikant, was vor allem AR(3) Modelle empfehlen würde.




Abbildung 5.3.: Correlogramm der Zeitreihe TUE (in-sample Periode)

Auf die chronologische Zeitreihe bezogen handelt es sich eigentlich um ein Subset Modell eines AR(21) Prozesses. Beim AR(3) Prozess für die aufgeteilten Zeitreihen wird nämlich nur jeder siebte Wert des gesamten Datensatzes behandelt. Wir haben somit ein Modell, wo nur der 7., 14. und 21. gelagte Wert vorkommt. Jedoch sei hier noch einmal zu erwähnen, dass bei dieser separaten Behandlung die verschiedenen anderen Wochentage nicht in den Regressionen vorkommen.

Dies erscheint zuerst eher unlogisch, weil man meinen könnte, dass die Werte vom Sonntag stark vom Samstag abhängen oder dass die Preise der Werkstage miteinander korreliert sind. Die Sinnhaftigkeit dieser Modelle wird im Vorhinein nicht in Frage gestellt, da sich dieser Modellierungsansatz für stündliche Strompreise als vorteilhaft entpuppt hat. Letztendlich wird sich bei der Vorhersage herausstellen, wie gut sich diese Modelle schlagen.

Trotz dieser optischen Analyse werden wir für alle Wochentage einzeln ARMA(p,q) Prozesse mit p und $q \in [0,10]$ testen. Anhand des kleinsten BIC wird das beste Modell herausgefiltert. Dabei wird wahlweise ein deterministischer linearer Trend hinzugefügt. Die Ergebnisse sind in Tabelle 5.4 und 5.5 wiedergegeben.

Tabelle 5.4.: separate ARMA Modelle (BIC)

ARMA (p,q)	TUE (3,0)	WED (3,4)	THU (1,2)	FRI (4,4)	SAT (1,2)	SUN (1,2)	MON (1,2)
c	46,44 ***	43,72 ***	47,24 ***	28,31 ***	33,90 ***	26,05 ***	44,89 ***
AR(1)	0,50 ***	0,00	0,96 ***	-0,04	0,97 ***	0,96 ***	0,94 ***
AR(2)	-0,04	-0,07 **		-0,23 *			
AR(3)	0,30 ***	0,92 ***		0,51 ***			
AR(4)				0,60 ***			
MA(1)		0,63 ***	-0,44 ***	0,63 ***	-0,27 ***	-0,24 ***	-0,34 ***
MA(2)		0,37 ***	-0,27 ***	0,63 ***	-0,31 ***	-0,18 ***	-0,27 ***
MA(3)		-0,70 ***		-0,16			
MA(4)		-0,26 ***		-0,55 ***			
Adj. R ²	0,426	0,541	0,426	0,544	0,734	0,777	0,508
SSR	60151	47433	61111	34670	7485	4343	43050
AIC	8,329	8,122	8,336	7,821	6,237	5,692	7,986
BIC	8,384	8,233	8,391	7,946	6,292	5,747	8,041
w.n.	ja	ja	ja	ja	ja	ja	ja

* (**) [***] Koeffizienten signifikant auf dem 10% (5%) [1%] Signifikanzniveau

w.n. (white noise) gibt an, ob alle p-Werte des Ljung-Box-Q Tests größer als 0,10 sind.

Es ergeben sich relativ unterschiedliche ARMA Prozesse für die einzelnen Wochentage. Vor allem augenscheinlich ist die schlechte Performance der Modelle für die Werkstage. Das hinzufügen eines deterministischen Trends von Anfang an bewirkt teilweise unterschiedliche Endmodelle, siehe Tabelle 5.5. Einzig für Sonntag ist dieser insignifikant. Das laut dem Correlogram erwartete AR(3) Modell stellt sich nur für die Dienstagszeitreihe als scheinbar bestes Modell heraus.

Tabelle 5.5.: separate ARMA Modelle mit Trend (BIC)

ARMA (p,q)	TUE (3,0)	WED (3,4)	THU (1,2)	FRI (3,4)	SAT (5,3)	SUN (1,2)	MON (4,6)
c	33,56 ***	26,58 ***	29,36 ***	17,10 **	20,80 ***	17,61 ***	23,87 ***
t	0,09 **	0,14 **	0,12 **	0,16 ***	0,07 ***	0,06	0,13 ***
AR(1)	0,48 ***	-0,03	0,93 ***	0,47 ***	-0,36 **	0,94 ***	0,93 ***
AR(2)	-0,05	-0,10 **		-0,61 ***	-0,32 ***		-0,85 ***
AR(3)	0,28 ***	0,86 ***		0,90 ***	0,77 ***		0,60 ***
AR(4)					0,22		0,13
AR(5)					0,34 ***		
MA(1)		0,66 ***	-0,43 ***	0,06	1,08 ***	-0,23 ***	-0,36 **
MA(2)		0,45 ***	-0,25 ***	0,69 ***	1,04 ***	-0,17 **	0,74 ***
MA(3)		-0,65 ***		-0,59 ***	-0,04		0,01
MA(4)		-0,22 ***		-0,17 **			-0,32 ***
MA(5)							-0,09
MA(6)							0,07
Adj. R ²	0,432	0,563	0,431	0,563	0,770	0,777	0,584
SSR	59270	44969	60402	33294	6239	4312	35112
AIC	8,322	8,077	8,332	7,776	6,118	5,693	7,857
BIC	8,391	8,201	8,401	7,901	6,257	5,762	8,024
w.n.	ja	ja	ja	ja	ja	ja	ja

* (**) [***] Koeffizienten signifikant auf dem 10% (5%) [1%] Signifikanzniveau
w.n. (white noise) gibt an, ob alle p-Werte des Ljung-Box-Q Tests größer als 0,10 sind.

Da die Modelle relativ geringe adjusted R² aufweisen, sollten weitere Variablen hinzugefügt werden, die sinnvoll erscheinen. Vor allem ist zu erwarten, dass benachbarte Werte anderer Wochentage einen signifikanten Einfluss haben sollten. D.h. obwohl wir nur die Zeitreihe der separaten Wochentage verwenden, würden wir vergangene Datenpunkte der anderen Wochentage in die Regression mit einbeziehen wollen. Mit diesem Schritt würden wir uns schon den periodischen Modellen nähern. Die Modellierung dieser Prozesse wird im folgenden Kapitel wiedergegeben.

5.3. PAR(p) Modelle

Aufgrund eher nicht zufrieden stellender Ergebnisse der separaten Zeitreihen erhoffen wir uns von den periodischen Modellen bessere Ergebnisse. Hier wurden PAR(1) bis PAR(28) Modelle für die in-sample Periode geschätzt, und dies für jeden Wochentag einzeln. Ebenfalls wurde wie zuvor ein deterministischer Trend wahlweise hinzugefügt.

Wichtig zu erwähnen ist, dass periodische autoregressive Modelle es erlauben, für jede Saison eine unterschiedliche Modellgröße zu wählen. Da man dadurch in der Lage ist, für jede Saison separat die beste Laglänge auszuwählen, ergeben sich durchaus mehrere Kombinationsmöglichkeiten, um zufrieden stellende Gesamtergebnisse zu erzielen.

Die Ergebnisse aller 392 Regressionen werden Zwecks Übersichtlichkeit nicht alle aufgelistet. Stattdessen werden nur jene wiedergegeben, die sich laut AIC und BIC als bestes Modell herausgestellt haben. Tabelle 5.6 und 5.7 geben die verschiedenen Modelle für die einzelnen Wochentage wieder. Dabei wird je nach Tabelle unterschieden, welches Informationskriterium zur Auswahl der Laglänge geführt hat.

Man sieht, dass die Miteinbeziehung eines linearen Trends nur einmal zu einer unterschiedlichen Laglänge geführt hat. Nämlich für den Dienstag, siehe Tabelle 5.7. Der saisonale Trend ist bis auf Donnerstag und Samstag stark insignifikant. Für Sonntag ist er sogar negativ, was nicht unbedingt zu erwarten ist.

Das AIC wählt zumeist relativ ähnliche Modelle aus wie das BIC. Nur für Donnerstag, Freitag und Samstag werden weit größere Laglängen ausgewählt. Die Annahme, dass die Residuen white noise sind wird trotz unschlüssiger Angabe in den Tabellen weitestgehend erfüllt. Die Erörterungen in Klammern geben wieder, dass die p-Werte für den Q-Test nur für ein oder zwei Lagordnungen nur knapp nicht 0,10 betragen. Für Freitag sind bis zu 6 Lagordnungen knapp signifikant auf dem 10% Signifikanzniveau, wobei die anderen deutlich insignifikant sind. Deshalb werden wir die Nullhypothese von white noise Residuen nicht verwerfen. Nur für das laut BIC ausgewählte PAR(9) Modell für Samstag muss die Nullhypothese, die Residuen seien white noise, verworfen werden. Trotzdem werden wir die Verletzung dieser Annahme ignorieren, da das PAR(20) Modell laut AIC als Alternative in Betracht gezogen werden kann.

Ebenfalls erkennt man, dass der lineare Trend je nach Wochentag unterschiedliche Werte annimmt, laut unserer Modellauswahl. Demnach muss die Entscheidung getroffen werden, ob man wirklich einen saisonabhängigen Trend modellieren will. Dieser unterstellt, dass die einzelnen Wochentage langfristig auseinanderdriften. Für unsere eher kleine Stichprobe und für die kurzfristigen Prognosen, die wir durchführen werden, spielt dies aber eine eher geringe Rolle. Deshalb werden wir der Vollständigkeit halber ebenfalls die Modellklasse mit saisonabhängigem Trend in Betracht ziehen und für die Prognosen im kommenden Kapitel verwenden. Trotzdem muss einem bewusst sein, dass saisonale Trends für Spotstrompreise langfristig wahrscheinlich unsinnig sind.

Tabelle 5.6.: PAR Modelle (AIC)

PAR	(p)	Trend (p-Wert)	Adj. R ²	SSR	AIC	BIC	w.n.
TUE	(3)		0,7252	28799	7,5840	7,6391	ja
	(3)	0,003 (0,74)	0,7243	28786	7,5913	7,6602	ja
WED	(7)		0,7801	22741	7,3788	7,4890	(ja)
	(7)	0,006 (0,47)	0,7797	22693	7,3845	7,5084	(ja)
THU	(22)		0,8762	12173	6,8793	7,1979	ja
	(22)	0,015 ** (0,03)	0,8782	11928	6,8669	7,1992	ja
FRI	(9)		0,8997	7616	6,3004	6,4381	(ja)
	(9)	0,002 (0,66)	0,8994	7610	6,3074	6,4589	(ja)
SAT	(20)		0,8871	2948	5,4455	5,7363	ja
	(20)	0,005 (0,18)	0,8874	2926	5,4459	5,7506	ja
SUN	(8)		0,9400	1143	4,3965	4,5205	(ja)
	(8)	-0,001 (0,68)	0,9398	1143	4,4036	4,5413	ja
MON	(8)		0,8092	16368	7,0578	7,1817	ja
	(8)	0,001 (0,86)	0,8085	16367	7,0654	7,2031	ja

(**) Koeffizienten signifikant auf dem (5%) Signifikanzniveau
w.n. (white noise) gibt an, ob (alle) p-Werte des Ljung-Box-Q Tests
größer als 0,10 sind.

Tabelle 5.7.: PAR Modelle (BIC)

PAR	(p)	Trend (p-Wert)	Adj. R ²	SSR	AIC	BIC	w.n.
TUE	(3)		0,7252	28799	7,5840	7,6391	ja
	(1)	0,008 (0,38)	0,7151	29981	7,6165	7,6578	ja
WED	(6)		0,7769	23159	7,3893	7,4857	(ja)
	(6)	0,006 (0,49)	0,7765	23115	7,3952	7,5053	(ja)
THU	(3)		0,8508	15887	6,9892	7,0443	(ja)
	(3)	0,014 * (0,05)	0,8525	15651	6,9820	7,0508	(ja)
FRI	(5)		0,8958	8039	6,3235	6,4061	(ja)
	(5)	0,003 (0,58)	0,8955	8029	6,3300	6,4264	(ja)
SAT	(9)		0,8772	3372	5,4856	5,6233	nein
	(9)	0,007 ** (0,03)	0,8788	3313	5,4757	5,6272	nein
SUN	(8)		0,9400	1143	4,3965	4,5205	(ja)
	(8)	-0,001 (0,68)	0,9398	1143	4,4036	4,5413	ja
MON	(8)		0,8092	16368	7,0578	7,1817	ja
	(8)	0,001 (0,86)	0,8085	16367	7,0654	7,2031	ja

* (**) Koeffizienten signifikant auf dem 10% (5%) Signifikanzniveau
w.n. (white noise) gibt an, ob (alle) p-Werte des Ljung-Box-Q Tests
größer als 0,10 sind.

6. Vorhersageeigenschaften

Vorhersagen sind von fundamentaler Wichtigkeit in vielen Wissenschaften, einschließlich der Ökonomie [Diebold & Mariano (1995)]. Sie werden als Richtwert für weit reichende Entscheidungen herangezogen. Dementsprechend ist es ausschlaggebend in Erfahrung zu bringen, welche Modelle für gewisse Anwendungsbereiche vorteilhaft sind und welche nicht.

Dieses Kapitel soll klären, welches der drei vorgestellten Modellklassen sich scheinbar am meisten eignet, tägliche Spotstrompreise vorherzusagen.

6.1. Methodische Vorgehensweise

Der Datensatz wurde von vornherein in eine in-sample und eine out-of-sample Periode aufgeteilt. Die out-of-sample Periode beinhaltet ca. die letzten 10 Prozent der Beobachtungen und dient nun zur Evaluierung der Vorhersageeigenschaften.

Die mit dem in-sample Datensatz berechneten Modelle werden hergenommen, um Prognosen von einer Woche bzw. 7 Tagen in die Zukunft zu erstellen. Um genau zu sein, wird eine dynamische 7-step-ahead Prognose berechnet und die Prognosefehler einzeln gespeichert. Nach der ersten Vorhersage wird die in-sample Periode um eine Beobachtung erweitert. Die Modelle werden somit mit der um einen Datenpunkt erweiterten Samplegröße ($n+1$) neu berechnet. Mit den neuen Koeffizienten der Modelle wird erneut eine 7-step-ahead Vorhersage erstellt und die sieben neuen Prognosefehler gespeichert. Danach wird die in-sample Periode wieder um einen Datenpunkt ($n+2$) erweitert und dieser Vorgang wird solange wiederholt, bis man am Ende des out-of-sample Datensatzes angekommen ist.

Da die out-of-sample Periode 25 Wochen bzw. 175 Tage umfasst, erhalten wir auf diese Art und Weise am Ende 169 Prognosefehler für jeden einzelnen der sieben step-ahead Vorhersageschritte.

Die einzelnen Prognosefehler werden nun dazu verwendet, um von jedem der sieben Schritte den Root Mean Square Error (RMSE) und den Mean Absolut Error (MAE) zu errechnen. Mit deren Hilfe sollen die Prognoseeigenschaften der verschiedenen Modelle verglichen werden.

$$RMSE_p = \sqrt{\frac{1}{169} \cdot \sum_{t=n+p}^{n+p+168} (\hat{y}_{t|t-p} - y_t)^2} \quad (6.1)$$

$$MAE_p = \frac{1}{169} \cdot \sum_{t=n+p}^{n+p+168} |\hat{y}_{t|t-p} - y_t| \quad (6.2)$$

$\hat{y}_{t|t-p}$ bezieht sich auf den Prognosewert des Zeitpunkts t , gegeben, dass nur jene Preise bis zum Zeitpunkt $t-p$ bekannt sind. p ist die Schrittweite der Prognose und n ist die Größe der in-sample Periode. In unserem Fall ist $n = 1813$. Für die 1-step-ahead Prognose erhalten wir somit Prognosewerte vom 1814. bis zum 1982. Tag. Die erste 7-step-ahead Prognose liefert uns eine Vorhersage für den 1820. Tag. Und die restlichen 168 Erweiterungen des Samples bringen uns zum letzten Tag der gesamten Zeitreihe, die 1988 Werte umfasst. Die Informationsmenge jeder Prognose hängt von der Schrittweite ab. Demnach ist bei dynamischen Vorhersagen zu erwarten, dass die Fehler bei längeren Prognoseschritten auch größer werden. Bei statischen Vorhersagen wird nur eine Reihe von 1-step-ahead Prognosen durchgeführt, ohne eine Anpassung der Informationsmenge durchzuführen, abhängig von der Prognoseweite.

Bezüglich Vorhersagen von ARMA Modellen siehe unter anderem Clements & Hendry (1998) und (1999), Franses (1998) und Brockwell & Davis (2002). Bezüglich Vorhersagen mit periodischen Modellen siehe auch Franses (1996) und Franses & Paap (2004).

6.2. Out-of-sample Prognose

6.2.1. ARMA Modelle

Die in Kapitel 5.1 angeführten 21 ARMA Modelle werden nun auf ihre Prognoseeigenschaften untersucht. In Tabelle 6.1 und 6.2 sind die jeweiligen Statistiken für alle 21 Modelle und alle sieben step-ahead Schritte wiedergegeben. Kleinere Werte sind natürlich besser und wurden Fett herausgehoben.

Auffällig ist, dass fast alle restringierten Modelle durchgehend schlechtere Vorhersagen liefern. Das einfache Modell mit Intercept bildet hierbei eine Ausnahme, genauso wie das signifikante Modell mit deterministischem Trend, Wochen- und Jahressaison. Je länger der Prognosehorizont wurde, desto eher verschoben sich die Werte zugunsten dieser signifikanten Modelle. Für die step-ahead Schritte 3-7 sind RMSE und MAE für das restringierte Modell mit Trend, Wochen-, Monats- und Jahresdummys auch kleiner.

Die Ergebnisse laut RMSE und MAE scheinen aber klar ersichtlich zu sein. Das unrestringierte beste Modell laut AIC liefert anfangs kurz die besten Prognoseeigenschaften. Danach sind die BIC Modelle mit linearem Trend überlegen. Vor allem das unrestringierte Modell mit Trend, Wochen- und Monatsdummys dominiert über längere Sicht.

Grobe Unterschiede der Ergebnisse zwischen RMSE und MAE sind nicht ersichtlich. Nur für die Schritte 2 und 4 stellten sich unterschiedliche Modelle als das Beste heraus.

Abbildung 6.1 zeigt die 1-step-ahead Prognosewerte für das AIC Modell gemeinsam mit der Zeitreihe bEXAbase. Abbildung 6.2 verdeutlicht die 7-step-ahead Werte für das beste BIC Modell laut RMSE und MAE.

Tabelle 6.1.: RMSE ARMA Modelle

RMSE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
c	6,9788	8,9281	9,2894	9,5230	9,8257	10,1940	10,7229
c, sig.	6,8783	8,7167	8,9748	9,1123	9,3195	9,6275	10,1236
t, sig.	6,8948	8,6823	8,9637	9,0939	9,3063	9,5850	10,0699
W	6,8691	8,7337	9,0586	9,3549	9,7406	10,1712	10,7229
W, sig.	6,8906	8,7937	9,1390	9,4350	9,8278	10,2628	10,8271
t, W	6,7858	8,5342	8,7690	8,9744	9,2739	9,6384	10,1085
t, W, sig.	6,7999	8,5790	8,8279	9,0168	9,3099	9,6734	10,1503
W, M, J	6,6860	8,3573	8,5119	8,6329	8,8627	9,1868	9,5938
W, M, J, sig.	6,8587	8,6847	8,9650	9,1875	9,5281	9,9376	10,4805
W, M	6,7335	8,4675	8,6603	8,8122	9,0724	9,4230	9,8676
W, M, sig.	6,8233	8,5945	8,8304	9,0040	9,3020	9,6847	10,1923
W, J	6,8400	8,6606	8,9541	9,2215	9,5756	9,9708	10,4794
W, J, sig.	6,9351	8,9051	9,3032	9,6561	10,0989	10,5681	11,1750
t, W, M, J	6,6053	8,2680	8,4570	8,5847	8,7973	9,0710	9,4533
t, W, M, J, sig.	6,6574	8,3070	8,4407	8,5014	8,7044	9,0166	9,4291
t, W, M	6,6652	8,3057	8,4262	8,5046	8,6917	8,9922	9,3706
t, W, M, sig.	6,7458	8,4111	8,5642	8,6438	8,8559	9,1846	9,6220
t, W, J	6,7731	8,5015	8,7217	8,9162	9,2034	9,5527	10,0022
t, W, J, sig.	6,7460	8,4490	8,6399	8,7636	8,9948	9,3158	9,7382
AIC, t, W, M, J	6,5977	8,2606	8,4650	8,5946	8,7837	9,0215	9,3994
AIC, t, W, M, J, sig.	6,6033	8,3286	8,5460	8,6469	8,8115	9,0582	9,4418

c = Intercept; sig = restringierte Modelle; W = Wochendummyvariablen;
t = linearer Trend; M = Monatsdummyvariablen; J = Jahresdummyvariablen.

Als Vergleich wurde zusätzlich der jeweilige Vorhersagewert des relativ einfachen ARMA(8,9) Prozesses mit Intercept abgebildet. Dieser beinhaltet überhaupt keine Dummyvariablen und liefert insgesamt laut RMSE und MAE eher schlechte Ergebnisse. Nur die restringierten ARMA Modelle ohne Trend aber mit den Dummyvariablen für die Jahre liefern teilweise sogar schlechtere Prognosen.

Tabelle 6.2.: MAE ARMA Modelle

MAE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
c	5,3164	7,0491	7,1640	7,3180	7,4680	7,7740	8,1208
c, sig.	5,2252	6,8361	6,8613	6,9309	7,1066	7,3521	7,6703
t, sig.	5,2384	6,7859	6,8388	6,9177	7,0711	7,3112	7,6064
W	5,2198	6,8759	6,9411	7,2166	7,5403	7,9205	8,2662
W, sig.	5,2505	6,9152	7,0002	7,2845	7,6491	8,0326	8,4004
t, W	5,1408	6,6684	6,6221	6,8273	7,0673	7,3842	7,7148
t, W, sig.	5,1586	6,6861	6,6646	6,8615	7,1076	7,4335	7,7732
W, M, J	5,1516	6,6416	6,5963	6,7182	6,8765	7,1626	7,3131
W, M, J, sig.	5,2762	6,8755	6,9331	7,1864	7,4940	7,8447	8,1274
W, M	5,1755	6,7178	6,7012	6,8678	7,0391	7,3426	7,5279
W, M, sig.	5,2381	6,7813	6,7785	6,9888	7,2489	7,5775	7,8668
W, J	5,1983	6,8200	6,8629	7,1098	7,4091	7,7583	8,0968
W, J, sig.	5,2983	7,0376	7,1857	7,5246	7,9318	8,3645	8,7406
t, W, M, J	5,0813	6,5539	6,5881	6,6674	6,7955	7,1070	7,2156
t, W, M, J, sig.	5,1491	6,5835	6,5582	6,6101	6,7347	7,0459	7,2149
t, W, M	5,1197	6,5409	6,4619	6,5588	6,6546	6,9387	7,0942
t, W, M, sig.	5,1551	6,5995	6,4954	6,5984	6,7520	7,0857	7,3680
t, W, J	5,1370	6,6609	6,6090	6,8053	7,0349	7,3476	7,6416
t, W, J, sig.	5,1052	6,5180	6,4963	6,6163	6,7820	7,0838	7,3705
AIC, t, W, M, J	5,0520	6,5569	6,5916	6,6653	6,7627	7,0498	7,2006
AIC, t, W, M, J, sig.	5,0845	6,6308	6,6374	6,7295	6,8165	7,0980	7,1873

c = Intercept; sig = restringierte Modelle; W = Wochendummyvariablen;
t = linearer Trend; M = Monatsdummyvariablen; J = Jahresdummyvariablen.




Abbildung 6.1.: 1-step-ahead Prognose AIC




Abbildung 6.2.: 7-step-ahead Prognose BIC

6.2.2. Separate ARMA Modelle

Hier werden die aus Kapitel 5.2 angeführten Modelle auf ihre Prognoseeigenschaften untersucht. Ebenfalls beziehen wir diverse andere ARMA Prozesse für die separaten Zeitreihen in die Untersuchung mit ein. Darunter auch jene Modelle, deren Laglänge p und q mit dem AIC ausgewählt wurden. Ebenfalls werden für alle Zeitreihen neben AR(3) Modellen auch andere Prozesse angeführt, die sich laut den ersten Ergebnissen der Vorhersage als scheinbar sinnvoll herausgestellt haben. Dadurch sollen die sieben Zeitreihen besser vergleichbar sein.

Dabei behandeln wir bei der Prognose die einzelnen Zeitreihen getrennt. Dadurch kann man die Eigenschaften der separaten Modelle einzeln betrachten. Die Methode der Vorhersage ist praktisch identisch wie in Kapitel 6.1 beschrieben. Nur muss man die spezielle Bedeutung der separaten Zeitreihen erörtern. Denn durch die Aufteilung der Datensätze beschreibt jede einzelne Zeitreihe einen Wochentag einzeln für sich. Somit bedarf es nur einer Vorhersage eines Schrittes, um eine Woche im Voraus einen Prognosewert zu erhalten.

Es wird demnach eine dynamische 1-step-ahead Prognose berechnet für jede der einzelnen sieben Zeitreihen separat. Dabei nehmen wir an, dass wir uns immer an einem Montag befinden. Somit wird die 1-step ahead Prognose am Montag durch die Gleichung des Dienstages berechnet. Um die 2-step-ahead Vorhersagen am Montag zu erhalten, benützen wir die Regressionen der Mittwochsdaten und die 7-step-ahead Prognose wird letztendlich von der Montagszeitreihe beschrieben. Die Prognosefehler werden einzeln gespeichert und die in-sample Periode, die zu Beginn 259 Datenpunkte aufwies, wird um einen Wert erhöht. Nun werden die neuen Koeffizienten der Modelle dazu verwendet, um wieder eine 1-step-ahead Vorhersage für alle Zeitreihen zu berechnen. Diese Prozedur wird wie in Kapitel 6.1 erläutert so lange fortgesetzt, bis man am Ende des Datensatzes angelangt ist.

Die einzelnen Prognosefehler wurden dazu verwendet, um von jedem der sieben Wochentage den Root Mean Square Error und den Mean Absolut Error zu errechnen. Diese sind in den Tabellen 6.3 und 6.4 für alle verwendeten Modelle wiedergegeben.

Die Werte in Klammer beziehen sich auf die jeweiligen ARMA(p,q) Prozesse, die laut BIC bzw. AIC am besten waren. Es ist auch hier wie bei der Modellspezifikation sehr gut erkennbar, dass sich für Samstag und Sonntag bei weitem bessere Ergebnisse herausstellen, im Vergleich zu den Werktagen. Dies gilt auch, wenn man die Werte von gleich spezifizierten ARMA Modellen miteinander vergleicht.

Das Hinzufügen eines deterministischen linearen Trends bewirkt so gut wie in allen Fällen eine Verbesserung vom RMSE und MAE. Es bleibt zu erwähnen, dass die derzeitigen Ergebnisse dieser Modellklasse deutlich schlechter sind als jene der chronologischen Zeitreihe.

Der Vorteil dieses Modellierungsansatzes liegt in der variablen Auswahl verschiedener Prozesse, abhängig vom Wochentag. Die Modelle, die nun im Nachhinein die kleinsten Werte für RMSE und MAE aufweisen, sind in Tabelle 6.5 noch einmal zu begutachten. Diese unterscheiden sich teilweise stark von den anfangs vermuteten

besten Modellen, die von den Informationskriterien ausgewählt wurden. Vor allem hat das AIC bei weitem zu große Modelle spezifiziert, die sich beim Vergleichen der Prognoseeigenschaften als unvorteilhaft herausgestellt haben. Ebenfalls hat das BIC, welches von vornherein sparsame Modelle bevorzugt, für gewisse Tage zu große Lagordnungen gewählt.

Insgesamt wird laut Tabelle 6.5 nur einmal ein Modell ohne Trend gewählt, nämlich für den Mittwoch. Laut MAE ist der ARMA(4,9) Prozess für diese Zeitreihe ohne Trend minimal besser als mit.

Periodische Modelle stellen für die Vorhersageevaluierung die letzte Modellklasse dar. Diese werden im nächsten Kapitel untersucht.

Tabelle 6.3.: RMSE separate ARMA Modelle

RMSE	TUE 1-step	WED 2-step	THU 3-step	FRI 4-step	SAT 5-step	SUN 6-step	MON 7-step
c (BIC)	13,5477 (3,0)	13,1719 (3,4)	11,0583 (1,2)	9,7987 (4,4)	6,0197 (1,2)	6,4112 (1,2)	12,0886 (1,2)
c t (BIC)	12,3960 (3,0)	11,7411 (3,4)	10,5104 (1,2)	9,8816 (3,4)	6,8978 (5,3)	6,2882 (1,2)	11,7344 (4,6)
c (AIC)	14,6809 (9,10)	13,1719 (3,4)	13,3635 (7,6)	11,1846 (6,7)	7,0807 (7,10)	6,7044 (7,7)	12,7253 (7,8)
c t (AIC)	11,4116 (4,9)	11,7411 (3,4)	13,4575 (6,7)	9,4453 (4,4)	6,8978 (5,3)	6,3392 (3,6)	11,7344 (4,6)
ar(3) c	13,5477	12,5914	12,1097	9,8076	6,2787	6,5639	12,4509
ar(3) c t	12,3960	11,6564	10,6960	8,7083	6,0133	6,4046	11,7032
arma(1,2) c	13,3201	12,1770	11,0583	8,9564	6,0197	6,4112	12,0886
arma(1,2) c t	12,6233	11,6876	10,5104	8,3964	5,8480	6,2882	11,6158
arma(4,4) c	13,2908	12,8167	11,3223	9,7987	6,9352	6,5568	12,4423
arma(4,4) c t	12,7488	11,6137	11,4567	9,4453	6,5538	6,4548	11,8302
arma(4,9) c	14,0235	11,5031	11,2596	9,9557	6,4004	6,5873	12,2488
arma(4,9) c t	11,4116	11,4715	11,4624	8,8943	6,2363	6,3522	11,9423

c = Intercept; t = linearer Trend;

Tabelle 6.4.: MAE separate ARMA Modelle

	TUE	WED	THU	FRI	SAT	SUN	MON
MAE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
c (BIC)	10,9591 (3,0)	9,2098 (3,4)	8,1344 (1,2)	8,2287 (4,4)	5,0280 (1,2)	5,2278 (1,2)	8,8460 (1,2)
c t (BIC)	9,9992 (3,0)	8,7483 (3,4)	7,3949 (1,2)	7,7051 (3,4)	6,0224 (5,3)	5,1151 (1,2)	9,0933 (4,6)
c (AIC)	11,9058 (9,10)	9,2098 (3,4)	9,9885 (7,6)	9,0554 (6,7)	6,1034 (7,10)	5,4688 (7,7)	9,7496 (7,8)
c t (AIC)	8,7736 (4,9)	8,7483 (3,4)	10,5450 (6,7)	7,6450 (4,4)	6,0224 (5,3)	5,0172 (3,6)	9,0933 (4,6)
ar(3) c	10,9591	9,6454	9,4010	8,2717	5,3131	5,4257	8,9960
ar(3) c t	9,9992	8,8605	7,6711	7,0266	5,1132	5,2411	8,7642
arma(1,2) c	10,7957	9,1373	8,1344	7,3721	5,0280	5,2278	8,8460
arma(1,2) c t	10,1863	8,6633	7,3949	6,7917	4,8664	5,1151	8,6804
arma(4,4) c	10,9504	9,8168	8,2189	8,2287	5,9997	5,2895	9,1318
arma(4,4) c t	10,4505	8,7168	7,8093	7,6450	5,6122	5,1615	9,2530
arma(4,9) c	11,5914	8,3940	8,4444	7,9301	5,4458	5,3674	9,0145
arma(4,9) c t	8,7736	8,4807	8,4531	6,8793	5,3184	5,1443	8,8486

c = Intercept; t = linearer Trend;

Tabelle 6.5.: beste Modelle für separate ARMA Prozesse

	TUE	WED	THU	FRI	SAT	SUN	MON
RMSE	11,4116 (4,9) t	11,4715 (4,9) t	10,5104 (1,2) t	8,3964 (1,2) t	5,8480 (1,2) t	6,2882 (1,2) t	11,6158 (1,2) t
MAE	8,7736 (4,9) t	8,3940 (4,9)	7,3949 (1,2) t	6,7917 (1,2) t	4,8664 (1,2) t	5,0172 (3,6) t	8,6804 (1,2) t

6.2.3. PAR Modelle

Als letzte Modellklasse untersuchen wir die Prognoseeigenschaften der periodischen autoregressiven Modelle. Die laut AIC und BIC gewählten Modelle werden hier sowohl mit, als auch ohne einen saisonalen Trend in Betracht gezogen. Die Tabellen 6.6 und 6.7 zeigen die Ergebnisse von RMSE und MAE für jeden der sieben Prognoseschritte. Ebenfalls wurden zusätzlich PAR(7), PAR(14), PAR(21) und PAR(28) Prozesse berechnet, um einen Vergleich zu haben. Dabei ist die Lagordnung p für diese vier Modelle identisch für jede Saison.

Tabelle 6.6.: RMSE PAR Modelle

RMSE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
PAR(AIC)	7,2162	8,5710	8,8754	9,2597	9,4233	9,5417	9,7160
PAR(AIC) sT	7,1955	8,5842	8,9260	9,3262	9,5036	9,6001	9,7258
PAR(BIC)	7,3346	8,7362	8,9958	9,2852	9,4392	9,8000	10,2468
PAR(BIC) sT	7,4179	8,8072	9,0023	9,3051	9,5576	9,8078	10,1761
PAR(7)	7,2236	8,6391	8,9755	9,4378	9,6304	9,9398	10,2482
PAR(14)	7,2889	8,7233	9,0860	9,6078	9,7897	9,9897	10,3175
PAR(21)	7,0355	8,3530	8,6474	9,0524	9,1992	9,3278	9,5002
PAR(28)	7,4233	8,6677	8,8951	9,2358	9,3226	9,3673	9,3477
PAR(3)	7,6845	9,7188	9,9906	10,5241	11,1799	11,8482	12,6832
PAR(Correlogram)	7,0526	8,3495	8,4801	8,8364	9,0899	9,5563	10,0137
PAR(best) sT	6,4281	7,9410	8,0341	8,2283	8,4207	8,7112	9,0795

sT = saisonaler Trend.

Als weitere Modellspezifikation beziehen wir uns auf ein interessantes Auswahlkriterium. Die Lagordnungen wurden dabei optisch aufgrund der PACF der Wochenzeitreihen bestimmt, siehe Abbildungen 5.3 und A.18 - A.23. Dabei wurde sowohl ein PAR(3) Modell für alle Saisonen, sowie teilweise größere Lagordnungen ausgewählt. Aufgrund der PACF kann für Dienstag, Mittwoch und Montag ein PAR(3) Prozess als angemessen erachtet werden. Für die anderen Tage wurden

größere Modelle spezifiziert. Für Mittwoch wurde ein PAR(5) in Betracht gezogen. Für Freitag und Samstag schien eine Lagordnung von 7 angemessen, während für Sonntag nur ein PAR(6) Modell berechnet wurde. Das Gesamtmodell wurde als PAR(Correlogram) in den Tabellen benannt, da es ungleich dem PAR(7) Modell ist.

Tabelle 6.7.: MAE PAR Modelle

MAE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
PAR(AIC)	5,4776	6,5809	6,5908	7,1160	7,2961	7,3151	7,3786
PAR(AIC) sT	5,4784	6,6046	6,6269	7,1467	7,3276	7,4043	7,3740
PAR(BIC)	5,5773	6,8186	6,7151	7,1022	7,0986	7,2327	7,6439
PAR(BIC) sT	5,5883	6,7701	6,6755	7,0684	7,1370	7,2443	7,4666
PAR(7)	5,4513	6,7032	6,8402	7,1347	7,2119	7,5066	7,7172
PAR(14)	5,4532	6,7525	6,7845	7,2485	7,5468	7,6810	7,9485
PAR(21)	5,4391	6,5468	6,7343	7,2282	7,2736	7,4055	7,2196
PAR(28)	5,6087	6,8324	6,9366	7,2798	7,2900	7,4903	7,1702
PAR(3)	6,0239	7,9820	8,1157	8,6668	9,0192	9,4987	10,2541
PAR(Correlogram)	5,3354	6,5300	6,5021	6,7751	6,8181	7,1763	7,4196
PAR(best) sT	4,7374	6,1584	6,2495	6,4444	6,6180	6,8143	6,9454

sT = saisonaler Trend.

Die Ergebnisse liefern auf den ersten Blick bessere Werte als die separaten ARMA Modelle. Die Prozesse mit saisonalem Trend ergeben keine definitiv besseren Resultate. Abhängig von den Prognoseschritten sind RMSE und MAE für Modelle mit saisonalem Trend zumeist schlechter. Ebenfalls bemerkenswert ist die Tatsache, dass die von AIC und BIC ausgewählten Modelle für keinen der Prognoseschritte den besten Wert für RMSE und MAE für sich beanspruchen können. Stattdessen dominiert vor allem jenes Modell, welches aufgrund der optischen Auswahl der Lagordnungen gewählt wurde. Das PAR(28) Modell hingegen bietet die besten Prognoseeigenschaften für die 7-step-ahead Vorhersage.

Nun nachdem die Prognose für diese Modellklasse abgeschlossen ist, möchte ich im Nachhinein alle möglichen Kombinationen der PAR Modelle analysieren. Die maximale Laglänge wird mit $p = 28$ festgelegt. Dadurch soll untersucht werden, wie akkurat die bis jetzt bestimmten Lagordnungen der einzelnen Saisonen waren.

Dazu betrachten wir alle Wochentage einzeln und berechnen eine 1-step-ahead Prognose, wie sie im Kapitel 6.2.2 beschrieben wurde. Die resultierenden Werte für RMSE und MAE aller 28 PAR Modelle jeder Saison sind im Appendix unter Tabelle A.1 - A.4 einzeln abgebildet. Hierbei wurden sowohl Modelle mit Trend als auch ohne betrachtet. Die besten Werte für RMSE und MAE wurden fett herausgehoben und sind in Tabelle 6.8 noch einmal ersichtlich. Die für RMSE und MAE identischen Ergebnisse liefern zumeist Modelle mit Trend. Die einzige Ausnahme bildet der Donnerstag mit einem PAR(21) Prozess.

Tabelle 6.8.: beste Ergebnisse laut RMSE, MAE

	TUE	WED	THU	FRI	SAT	SUN	MON
RMSE	7,9089 PAR(20) t	5,0996 PAR(1) t	7,1598 PAR(21)	5,2561 PAR(8) t	5,3910 PAR(17) t	3,8729 PAR(15)	8,6711 PAR(4) t
MAE	6,2828 PAR(20) t	3,8936 PAR(1)	5,3337 PAR(21)	3,6673 PAR(8) t	4,3887 PAR(17) t	2,9788 PAR(13) t	6,4098 PAR(7) t

Für die Mittwochszeitreihe erhalten wir sehr überraschend ein einfaches PAR(1) Modell. Jedoch ist laut RMSE ein Trend zu empfehlen. Für den MAE liefert das PAR(1) mit Trend hingegen größere Prognosefehler. Für Sonntag ist laut RMSE ein PAR(15) ohne Trend zu empfehlen. Den kleinsten Wert für den MAE erhalten wir aber für ein PAR(13) Modell mit Trend. Da man stets bemüht sein sollte das kleinste Modell zu finden, ist die Auswahl des PAR(13) Prozesses vorzuziehen. Für Montag erhalten wir eine ähnliche Konstellation. Hier gilt ebenfalls die Überlegung des kleinsten Modells, weswegen wir bei der Auswahl des besten Modells für Montag dem RMSE vertrauen werden.

Die Entscheidung für den Mittwoch werden wir aufgrund eines anderen Kriteriums fällen. Es soll die interessante Frage geklärt werden, wie viele der insgesamt 196 Modelle sich für einen Trend, und wie viele sich dagegen äußern.

Laut RMSE sind für Dienstag alle 28 PAR Modelle mit Trend besser als jene ohne Trend. Für Mittwoch sind es nur zwei, nämlich PAR(1) und PAR(2). Die Ergebnisse für die weiteren Tage und den MAE können in der Tabelle 6.9 abgelesen werden. Donnerstag und Sonntag, aber auch Freitag liefern etwas andere Ergebnisse, abhängig von der Wahl des Prognosefehlers. Für den Sonntag lässt sich dies einfach erklären, weil die Unterschiede zwischen Modellen mit oder ohne Trend nur geringe Auswirkungen auf die Prognosefehler haben. Deshalb bewirken RMSE und MAE relativ einfach unterschiedliche Empfehlungen für einen deterministischen Trend.

Jene Wochentage, die ebenfalls einen linearen Trend mit einbeziehen laut den oben bestimmten besten Modellen (siehe Tabelle 6.8), haben durchgehend über alle 28 PAR Modelle einen großen Anteil an Prozessen, die einen Trend vorziehen. Mittwoch und Donnerstag haben hingegen als einziges gemein, dass mehr als die

Hälfte aller Prozesse gegen einen Trend sprechen. Beim Mittwoch sind es sogar alle bis auf drei. Deswegen entscheiden wir uns letztendlich bei diesem Wochentag für das PAR(1) Modell ohne Trend.

Tabelle 6.9.: Anzahl Modelle, die mit Trend bessere Ergebnisse liefern

	TUE	WED	THU	FRI	SAT	SUN	MON
RMSE	28	2	11	13	28	11	26
MAE	28	1	4	18	28	21	26

In den folgenden Abbildungen wollen wir noch einmal die Unterschiede der Prognosefehler unter den einzelnen Saisonen für alle 28 PAR Modelle verdeutlichen. Die Graphiken für die Prognosefehler der Modelle ohne Trend verlaufen sehr ähnlich und sind im Appendix unter Abbildung A.24 und A.25 zu finden. In den Abbildungen 6.3 und 6.4 ist ersichtlich, dass für den Donnerstag, aber vor allem auch für den Sonntag, über alle Lagordnungen nur geringe Unterschiede auftreten. Ebenfalls ist die Besonderheit der Mittwochszeitreihe ersichtlich. Als einzige Saison scheinen diese Daten am besten durch sehr einfache PAR Modelle modellierbar zu sein. Andererseits ergeben zu einfache PAR Modelle für die Montagspreise weit schlechtere Resultate.




Abbildung 6.3.: RMSE für alle 28 PAR Modelle mit Trend




Abbildung 6.4.: MAE für alle 28 PAR Modelle mit Trend

Tabelle 6.10 zeigt letztendlich noch einmal die besten Lagordnungen je nach Saison, die aufgrund der 1-step-ahead Prognose für die einzelnen Zeitreihen ausgewählt wurden. Jene Prognosefehler, die fett hervorgehoben sind, verdeutlichen noch einmal, dass es sich um die besten Werte der jeweiligen 48 PAR Modelle einer jeden Saison handelt. Zusätzlich wurde aufgrund dieser Lagordnungen und der Wahl des Trends eine dynamische 7-step-ahead Prognose durchgeführt. Die Ergebnisse dieses Modells sind in den Tabellen 6.6 und 6.7 als PAR(best) gekennzeichnet. Man sieht, dass man mit dem Wissen über die womöglich wahren Lagordnungen bei weitem bessere Ergebnisse hätte erzielen können. Das BIC lag bei der Auswahl von p stärker daneben. Das AIC konnte zumindest für die Saisonen von Donnerstag bis Samstag annähernd die gleiche Lagordnung wählen, wie für das scheinbar beste Modell.

Tabelle 6.10.: bestes PAR Modell

	TUE PAR(20) t	WED PAR(1)	THU PAR(21)	FRI PAR(8) t	SAT PAR(17) t	SUN PAR(13) t	MON PAR(4) t
RMSE	7,9089	5,1705	7,1598	5,2561	5,3910	3,9358	8,6711
MAE	6,2828	3,8936	5,3337	3,6673	4,3887	2,9788	6,4815

6.3. Ergebnisse

In diesem Abschnitt sollen nun letztendlich die Bewertungen der besten Modelle gemeinsam herangezogen und verglichen werden. Um ein Vergleichen der verschiedenen Prognosehorizonte zu vereinfachen, werden wir die Ergebnisse der einzelnen Prognoseschritte von RMSE und MAE zusammenfassen. Im Falle des MAE wird einfach über die sieben Prognosefehler der Durchschnitt gebildet. Beim RMSE werden die sieben einzelnen Werte der multi-step-ahead Vorhersage zuerst quadriert. Nach dem Bilden des Durchschnittswertes wird erneut die Wurzel gezogen. Diese Prozedur führen wir für alle angegebenen Modelle der normalen ARMA Prozesse durch. Ebenfalls wird die beste Kombination der separaten ARMA Modelle, wie sie in Tabelle 6.5 wiedergegeben wurde, in den Vergleich mit einbezogen. Als letzte Modellklasse werden ebenfalls die verschiedenen Varianten der PAR Modelle angeführt. Die Tabellen 6.11 und 6.12 zeigen alle wichtigen Ergebnisse für die zusammengefassten RMSE und MAE.

Obwohl wir für das separate ARMA Modell abhängig von RMSE und MAE unterschiedliche Lagordnungen je nach Saison verwendet haben um die Ergebnisse zu optimieren, ist diese Modellklasse bei weitem am schlechtesten. Der RMSE ist sogar größer als von jenem ARMA Modell, welches überhaupt keine Dummyvariablen mit einbezieht.

Ein linearer Trend verbessert die Ergebnisse für die ARMA Prozesse der chronologischen Zeitreihe. Modelle, welche neben einer Wochensaison zusätzliche andere deterministische Saisonen berücksichtigen, liefern zumeist kleinere Prognosefehler. Die restringierten Modelle liefern größtenteils schlechtere Ergebnisse. Eine Ausnahme bildet das einfachste Modell mit Intercept.

Bestes ARMA Modell ist jenes mit insignifikanten Koeffizienten, linearem Trend sowie mit Wochen- und Monatsdummyvariablen. Die beiden Nachbarmodelle, die auch einen deterministischen Trend beinhalten, bilden ebenfalls eine Ausnahme, wo die restringierten Modelle bessere Ergebnisse liefern. Das restringierte ARMA Modell, welches aufgrund von AIC ausgewählt wurde, weist ebenfalls ansprechende Resultate auf.

Die periodischen Modelle zeigen, dass jene durch AIC und BIC gewählten Varianten schlechtere Werte für RMSE aufweisen. Ein saisonaler Trend zeigt zumeist keine Verbesserung der Ergebnisse. Der MAE des durch AIC gewählten PAR Modells wird nur von dem PAR Modell, welches aufgrund des Correlograms ausgewählt wurde, übertroffen. Dieses optisch ausgewählte Modell ist auch das einzige, welches absolut für beide Prognosefehler, bessere Resultate liefert, als ARMA Modelle, die nur eine deterministische Wochensaison berücksichtigen. ARMA Modelle mit weiteren Dummyvariablen weisen aber bessere Prognoseeigenschaften auf.

Das im Nachhinein gewählte PAR Modell, welches eine scheinbar optimale Lagordnung wählt, weist kleinere Prognosefehler auf, als alle anderen hier angeführten Modelle. Beim Vergleich der ARMA Modelle ohne Monats- oder Jahresdummyvariablen, können die periodischen Modelle, welche durch AIC und BIC

ausgewählt wurden, keine besseren Ergebnisse erzielen. Nur das eher zufällig gewählte periodische Modell laut Correlogram ist den vergleichbaren ARMA Modellen überlegen.

Tabelle 6.11.: Ergebnisse ARMA und separate ARMA Modelle

	RMSE	MAE
c	9,4176	7,1729
c, sig.	9,0151	6,8546
t, sig.	8,9909	6,8242
W	9,3070	7,1400
W, sig.	9,3845	7,2189
t, W	8,9235	6,7750
t, W, sig.	8,9630	6,8122
W, M, J	8,5900	6,6371
W, M, J, sig.	9,1545	7,1053
W, M	8,7682	6,7674
W, M, sig.	8,9736	6,9257
W, J	9,1646	7,0365
W, J, sig.	9,6046	7,4404
t, W, M, J	8,5042	6,5727
t, W, M, J, sig.	8,4753	6,5566
t, W, M	8,4596	6,4813
t, W, M, sig.	8,6163	6,5792
t, W, J	8,8618	6,7480
t, W, J, sig.	8,7085	6,5675
AIC, t, W, M, J	8,4868	6,5541
AIC, t, W, M, J, sig.	8,5324	6,5977
separates ARMA Modell	9,6470	7,1312

c = Intercept; sig = restringierte Modelle;
t = linearer Trend; W = Wochendummyvariablen;
M = Monatsdummyvariablen; J = Jahresdummyvariablen.

Tabelle 6.12.: Ergebnisse PAR Modelle

	RMSE	MAE
PAR(AIC)	8,9785	6,8222
PAR(AIC) sT	9,0173	6,8518
PAR(BIC)	9,1604	6,8841
PAR(BIC) sT	9,1909	6,8500
PAR(7)	9,2041	6,9379
PAR(14)	9,3057	7,0593
PAR(21)	8,7659	6,8353
PAR(28)	8,9178	6,9440
PAR(3)	10,6255	8,5086
PAR(Correlogram)	8,8129	6,6509
PAR(best) sT	8,1579	6,2811

sT = saisonaler Trend.

Somit scheinen einfache periodische autoregressive Modelle das Potenzial zu haben, ARMA Modelle zu schlagen, wenn man eine adäquate Lagordnung bestimmen kann. Andernfalls sind die Ergebnisse der PAR Modelle eher enttäuschend.

Die separaten ARMA Modelle erweisen sich hingegen als deutlich unzureichend, um gute Vorhersagen zu liefern. Es ist essentiell, die benachbarten Wochentage in die Berechnungen mit einzubeziehen.

Für Stundenpreise war in den Arbeiten von Ramanathan et al. (1997) und Crespo Cuaresma et al. (2004) ein multiples Regressionsmodell von Vorteil. Die Preisbildung der separaten Stundenpreise findet zur gleichen Zeit statt. Alle für die Agenten verfügbaren Informationen sind für alle 24 Datensätze gleich. Die täglichen Preise für die einzelnen Wochentage kommen aber natürlich zu unterschiedlichen Zeitpunkten zustande. Demnach ist an jedem Tag mit einer unterschiedlichen Informationsmenge zu rechnen. Nur die separaten Zeitreihen eines Wochentages zu untersuchen, kommt scheinbar einem Informationsverlust nahe. Alle innerhalb der Woche stattfindenden marktrelevanten Ereignisse würden ignoriert werden, wenn man die anderen Tage nicht auch mitberücksichtigt.

Die Tatsache, dass wir für die PAR Prozesse, abhängig von der Saison, relativ unterschiedliche Lagordnungen erhalten, spricht für eine eventuell schlechte Spezifikationsmöglichkeit normaler ARMA Modelle. Vor allem das scheinbar beste PAR Modell zeigt starke Variationen in Abhängigkeit von der betrachteten Wochensaison. Zu verabsäumen, diese zu modellieren, birgt womöglich das Risiko, schlechtere Ergebnisse zu erhalten.

7. Schlussfolgerungen

Das Verhalten von Spotstrompreisen hat im Zuge der Energiemarktliberalisierung eine große wirtschaftliche Bedeutung gewonnen. Immerhin werden dadurch auch letztendlich die Endverbraucherpreise beeinflusst. Dementsprechend sollte die Entwicklung ökonometrischer Modelle von hoher Priorität sein, welche die Dynamiken auf den Energiebörsen gut beschreiben bzw. vorhersagen können.

Unter Verwendung der täglichen Spotstrompreise der österreichischen Energiebörse wurden drei lineare, univariate Modellklassen auf ihre Prognoseeigenschaften untersucht. Eine separate Behandlung der Wochentage erwies sich als nur bedingt vorteilhaft. Die Vorhersagen zeigen, dass es essentiell ist, auch die benachbarten Wochentage mit einzubeziehen.

Die Informationskriterien stellten sich als ungeeignet heraus, um für periodische autoregressive Modelle eine optimale Lagordnung herauszufiltern. Eine optische Analyse erwies sich a priori als das beste Auswahlkriterium. Eine genaue Analyse im Nachhinein zeigt, dass je nach Wochensaison eine unterschiedliche Lagordnung von Nöten ist, um scheinbar optimale Vorhersagen zu erhalten. Da klassische autoregressive moving average Modelle diese Spezifikationsmöglichkeit vernachlässigen, kann deren Anwendung für diesen Datensatz als suboptimal angesehen werden.

Volatility Clustering, Preisspitzen, Wettereinflüsse und eventuelle Nicht-Linearitäten wurden in dieser Studie wenig Beachtung geschenkt. Diese Aspekte könnten aber im Zusammenhang mit periodischen Modellen für zukünftige Forschungen von Interesse sein, da sie wahrscheinlich die Vorhersagen verbessern würden. Jedoch erschweren Nicht-Lineare Modelle das Durchführen von Vorhersagen beträchtlich. Ebenfalls ist die Miteinbeziehung von Wetterfaktoren mit Vorsicht zu genießen. Spotstrompreise werden meist einheitlich für große Gebiete bestimmt. Da Wetterbedingungen regional oft unterschiedliche Ausmaße annehmen können, ist die örtliche Auswahl der Datenquelle bzw. die optimale Gewichtung mehrerer regionaler Wetterinformationen zu beachten.

Das Miteinbeziehen von Feiertagen in die Modelle könnte von Vorteil sein, sowie die Modellierung von Fenstertagen und verlängerten Wochenenden, an denen ebenfalls mit einem unterschiedlichen Konsumverhalten zu rechnen ist. Es wäre ebenfalls zu klären, inwieweit sich Informationskriterien eignen, für periodische autoregressive Modelle optimale Lagordnungen zu bestimmen. Diese Fragen liegen aber außerhalb des Rahmens dieser Arbeit und werden zukünftigen Forschungen überlassen.

A. Appendix




Abbildung A.1.: in-sample Datensatz bEXAbase (11.02.2003 - 28.01.2008)




Abbildung A.2.: out-of-sample Datensatz bEXAbase (29.01.2008 - 21.07.2008)





Abbildung A.3-A.8.: bEXAbase 2003-2008 (erweitertes Sample)



[http://www.exaa.at/static/cms/sites/exaa.at/media/downloads/annual_reports.html/anual_report_2007_dt.pdf.pdf]

Abbildung A.9.: Volatilität verschiedener Energiebörsen 2007




Abbildung A.10.: Koeffizienten der Testregression (verschiedene Perioden)




Abbildung A.11-A.17.: Zeitreihe TUE-MON (gesamter Datensatz)




Abbildung A.18.: Correlogram der Zeitreihe WED (in-sample Periode)




Abbildung A.19.: Correlogram der Zeitreihe THU (in-sample Periode)




Abbildung A.20.: Correlogramm der Zeitreihe FRI (in-sample Periode)




Abbildung A.21.: Correlogramm der Zeitreihe SAT (in-sample Periode)




Abbildung A.22.: Correlogram der Zeitreihe SUN (in-sample Periode)




Abbildung A.23.: Correlogram der Zeitreihe MON (in-sample Periode)

Tabelle A.1.: RMSE, PAR(1)-PAR(14)

RMSE	TUE 1-step	WED 2-step	THU 3-step	FRI 4-step	SAT 5-step	SUN 6-step	MON 7-step
par(1) c	10,7845	5,1705	7,7857	7,2501	9,8458	4,0658	12,3066
par(1) c t	10,0723	5,0996	7,6335	6,3947	7,9354	4,0695	12,1672
par(2) c	10,2571	5,6788	7,8863	7,1014	9,4568	4,0784	12,8255
par(2) c t	9,9105	5,5916	7,6071	6,3167	7,5730	4,0838	12,3384
par(3) c	9,3049	5,8959	7,8980	6,4915	9,3237	3,9979	9,0768
par(3) c t	9,1973	6,0672	7,6769	5,8888	7,4565	4,0027	8,7782
par(4) c	9,3228	5,9360	7,6109	6,3967	9,0652	4,0038	8,9132
par(4) c t	9,2131	6,0988	7,6133	5,8165	7,2997	4,0088	8,6711
par(5) c	9,1896	6,3679	7,6596	5,5847	9,1212	3,9922	8,9138
par(5) c t	9,1040	6,5449	7,6666	5,5156	7,4246	3,9974	8,6777
par(6) c	9,1750	7,1524	7,6675	5,3935	6,4979	3,9668	8,9840
par(6) c t	9,0845	7,2364	7,6990	5,3615	6,0504	3,9722	8,7316
par(7) c	9,1728	7,5731	7,5845	5,2900	6,1728	4,1191	9,0370
par(7) c t	9,0746	7,6673	7,6282	5,2633	5,8349	4,0983	8,7890
par(8) c	9,1590	7,5626	7,6321	5,2771	6,2283	3,9597	9,3375
par(8) c t	9,0693	7,6580	7,6572	5,2561	5,9057	3,9564	9,3276
par(9) c	9,1100	7,5586	7,7062	5,3995	6,4331	3,9761	9,2793
par(9) c t	9,0579	7,6640	7,7325	5,3705	6,1140	3,9725	9,2833
par(10) c	9,0742	7,8295	8,0194	5,4000	6,4480	3,9358	9,4151
par(10) c t	9,0344	7,9465	7,9954	5,3721	6,1295	3,9338	9,4074
par(11) c	8,8283	7,8326	7,8413	5,3974	6,4218	3,9429	9,3382
par(11) c t	8,7696	7,9711	7,7072	5,3766	6,1108	3,9408	9,3259
par(12) c	8,8642	8,0868	8,0632	5,4240	6,4544	3,9417	9,3705
par(12) c t	8,8037	8,2015	7,9905	5,4141	6,1415	3,9394	9,3579
par(13) c	8,9159	8,0451	7,7023	5,5995	5,6585	3,9368	9,4150
par(13) c t	8,8596	8,1654	7,5960	5,5924	5,4787	3,9358	9,3982
par(14) c	8,8548	8,0268	7,7178	5,5446	5,6973	3,9548	9,4224
par(14) c t	8,8027	8,1500	7,5979	5,5474	5,5139	3,9504	9,3952

Tabelle A.2.: RMSE, PAR(15)-PAR(28)

	TUE	WED	THU	FRI	SAT	SUN	MON
RMSE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
par(15) c	8,8822	8,1098	7,7413	5,3782	5,8275	3,8729	9,0492
par(15) c t	8,7942	8,2286	7,6609	5,3891	5,6492	3,8744	9,0533
par(16) c	8,8685	8,1270	7,9712	5,3205	5,7502	3,8888	8,8754
par(16) c t	8,7925	8,2428	7,9056	5,3301	5,5835	3,8892	8,8260
par(17) c	8,4332	8,0750	7,7372	5,3215	5,5650	3,8957	8,7589
par(17) c t	8,3969	8,1768	7,7236	5,3312	5,3910	3,8959	8,6963
par(18) c	8,3784	8,6376	7,7018	5,3229	5,5758	3,9324	8,7381
par(18) c t	8,3348	8,6712	7,7211	5,3277	5,4036	3,9322	8,6797
par(19) c	8,1785	8,5722	7,4618	5,3727	5,6993	3,9362	8,9115
par(19) c t	8,1574	8,6083	7,4870	5,3787	5,5255	3,9361	8,8613
par(20) c	7,9407	8,5234	7,4515	5,3898	5,8146	3,9358	8,8764
par(20) c t	7,9089	8,5610	7,4814	5,4015	5,6647	3,9349	8,8248
par(21) c	7,9523	8,3549	7,1598	5,3843	5,8330	3,9378	8,9469
par(21) c t	7,9177	8,3878	7,2073	5,3922	5,6904	3,9396	8,8779
par(22) c	8,4952	8,2711	7,2982	5,4897	5,8434	3,9248	9,0233
par(22) c t	8,4511	8,3002	7,3633	5,4938	5,7047	3,9277	8,9389
par(23) c	8,7711	8,3855	7,3100	5,4840	5,8674	3,9225	9,3058
par(23) c t	8,7070	8,4136	7,3813	5,4869	5,7204	3,9250	9,2483
par(24) c	8,7667	8,2790	7,2942	5,4897	5,8728	3,9033	9,5430
par(24) c t	8,6894	8,3111	7,3575	5,4927	5,7282	3,9051	9,4644
par(25) c	8,8723	8,4536	7,3025	5,6366	5,8882	3,9216	9,5608
par(25) c t	8,7818	8,4733	7,3728	5,6434	5,7423	3,9240	9,4809
par(26) c	8,9248	8,3648	7,4547	5,5786	5,9080	3,9237	9,7430
par(26) c t	8,8455	8,3848	7,4728	5,5879	5,7559	3,9261	9,6707
par(27) c	8,8751	8,7417	7,4082	5,5777	5,7293	3,9299	9,4007
par(27) c t	8,7982	8,7766	7,4370	5,5888	5,6040	3,9323	9,3301
par(28) c	8,8299	8,7074	7,3816	5,6050	5,7227	3,9453	9,6082
par(28) c t	8,7533	8,7383	7,4029	5,6161	5,6061	3,9481	9,5250

Tabelle A.3.: MAE, PAR(1)-PAR(14)

MAE	TUE 1-step	WED 2-step	THU 3-step	FRI 4-step	SAT 5-step	SUN 6-step	MON 7-step
par(1) c	8,3049	3,8936	5,8389	6,2252	9,1272	3,3672	9,1700
par(1) c t	7,7031	4,1797	5,8262	5,2348	7,1809	3,3615	9,0198
par(2) c	7,8604	4,5117	6,0043	6,0118	8,6690	3,3747	10,0880
par(2) c t	7,5816	4,7857	5,8805	5,1721	6,7083	3,3720	9,5567
par(3) c	7,3519	4,9214	6,0460	5,3494	8,5149	3,3094	6,8899
par(3) c t	7,2905	5,1055	6,0209	4,7600	6,5743	3,3086	6,5845
par(4) c	7,3385	5,0015	5,8635	5,3184	8,2012	3,3333	6,7260
par(4) c t	7,2610	5,1372	5,9658	4,6371	6,3602	3,3287	6,4815
par(5) c	7,3906	5,5944	5,9509	4,2293	8,3588	3,3151	6,5531
par(5) c t	7,3257	5,6760	6,0274	4,1453	6,5942	3,3104	6,4185
par(6) c	7,2641	6,2386	5,9207	3,9819	5,4206	3,3045	6,6139
par(6) c t	7,1950	6,2922	6,0322	3,9418	5,0483	3,3010	6,4353
par(7) c	7,2452	6,5376	5,7980	3,7187	5,1004	3,1452	6,5953
par(7) c t	7,1707	6,6262	5,9014	3,6673	4,8308	3,1228	6,4098
par(8) c	7,2570	6,5275	5,7699	3,7094	5,0741	3,0072	7,0829
par(8) c t	7,1874	6,6350	5,8929	3,6673	4,7882	3,0030	7,0815
par(9) c	6,8943	6,5247	5,8001	4,0493	5,1961	3,0198	7,0540
par(9) c t	6,8658	6,6356	5,9156	3,9808	4,9160	3,0155	7,0591
par(10) c	6,8633	6,6212	6,0882	4,0353	5,2119	2,9825	7,1713
par(10) c t	6,8421	6,6814	6,1975	3,9697	4,9322	2,9795	7,1706
par(11) c	6,7371	6,6072	5,7392	4,0375	5,1918	2,9870	7,1109
par(11) c t	6,6833	6,6680	5,6998	3,9846	4,9180	2,9840	7,1073
par(12) c	6,7563	6,6809	6,0858	3,9265	5,2108	2,9860	7,1098
par(12) c t	6,7026	6,7786	6,1209	3,9045	4,9311	2,9828	7,1077
par(13) c	6,7801	6,6695	5,7966	4,0132	4,5827	2,9807	7,1564
par(13) c t	6,7388	6,7893	5,8340	3,9895	4,4563	2,9788	7,1505
par(14) c	6,7349	6,6920	5,7200	4,0588	4,6121	3,0524	7,2812
par(14) c t	6,6970	6,8106	5,7654	4,0553	4,4894	3,0490	7,2757

Tabelle A.4.: MAE, PAR(15)-PAR(28)

	TUE	WED	THU	FRI	SAT	SUN	MON
MAE	1-step	2-step	3-step	4-step	5-step	6-step	7-step
par(15) c	6,6648	6,6911	5,7665	3,9126	4,6897	3,0427	7,1569
par(15) c t	6,6550	6,8261	5,8518	3,9224	4,5826	3,0437	7,1679
par(16) c	6,6705	6,6878	5,9747	3,8460	4,6055	3,0395	7,0751
par(16) c t	6,6689	6,8198	6,0130	3,8526	4,5048	3,0400	7,0467
par(17) c	6,5211	6,7283	5,8213	3,8515	4,5000	3,0458	6,9450
par(17) c t	6,4894	6,8464	5,9432	3,8581	4,3887	3,0460	6,9171
par(18) c	6,4971	7,0407	5,8366	3,8494	4,5074	3,0836	6,9132
par(18) c t	6,4554	7,0364	5,8627	3,8494	4,3958	3,0834	6,8896
par(19) c	6,3670	7,0477	5,4852	3,9219	4,6635	3,0859	7,1511
par(19) c t	6,3535	7,0551	5,5403	3,9227	4,5586	3,0858	7,1325
par(20) c	6,2990	6,9877	5,4258	3,9468	4,8231	3,0681	7,1642
par(20) c t	6,2828	6,9983	5,5149	3,9550	4,7194	3,0672	7,1463
par(21) c	6,3713	6,9648	5,3337	3,9989	4,8601	3,1318	7,2058
par(21) c t	6,3386	6,9823	5,4649	4,0034	4,7731	3,1318	7,1773
par(22) c	6,8243	6,8827	5,4662	3,9853	4,8720	3,0755	7,2189
par(22) c t	6,7740	6,8929	5,6108	3,9799	4,7858	3,0760	7,1804
par(23) c	6,8539	6,9366	5,4871	3,9572	4,8884	3,0657	7,4229
par(23) c t	6,7642	6,9519	5,6317	3,9517	4,7921	3,0662	7,4007
par(24) c	6,9686	6,9699	5,5033	3,9596	4,7709	3,0495	7,4471
par(24) c t	6,8868	6,9775	5,6556	3,9537	4,6841	3,0493	7,4094
par(25) c	7,1046	7,1343	5,5269	4,0952	4,7842	3,0644	7,4623
par(25) c t	7,0111	7,1397	5,6843	4,0926	4,6975	3,0644	7,4260
par(26) c	7,1969	6,9820	5,5719	4,0936	4,8256	3,0656	7,5925
par(26) c t	7,1148	6,9903	5,7074	4,0994	4,7351	3,0657	7,5598
par(27) c	7,2667	6,8834	5,5826	4,0584	4,7276	3,0873	7,3490
par(27) c t	7,2019	6,8910	5,6887	4,0667	4,6295	3,0870	7,3169
par(28) c	7,2105	6,6909	5,5762	4,0868	4,7185	3,1034	7,5933
par(28) c t	7,1324	6,7004	5,6343	4,0942	4,6280	3,1034	7,5432




Abbildung A.24.: RMSE für alle 28 PAR Modelle ohne Trend




Abbildung A.25.: MAE für alle 28 PAR Modelle ohne Trend

Literaturverzeichnis

- [1] Ackerman, G. (1985): "Short-term load prediction for electric-utility control of generating units", in: Bunn, D.W. & Farmer, E.D. (eds.), *Comparative Models for Electrical Load Forecasting*, Wiley, New York.
- [2] Akaike, Hirotugu (1973): "Information theory as an extension of the maximum likelihood principle", in: Petrov, B.N. & Csaki, F. (eds.), *Proceedings of the Second International Symposium on Information Theory*, Budapest, Akademiai Kiado, 267-281.
- [3] Akaike, Hirotugu (1974): "A New Look at Statistical Model Identification", *IEEE Transactions on Automatic Control*, 19:716-723.
- [4] Bera, Anil K. & Jarque, Carlos M. (1980): "Efficient tests for normality, homoscedasticity and serial independence of regression residuals", *Economics Letters*, 6(3):255-259.
- [5] Bera, Anil K. & Jarque, Carlos M. (1981): "Efficient tests for normality, homoscedasticity and serial independence of regression residuals: Monte Carlo evidence", *Economics Letters*, 7(4):313-318.
- [6] Bollerslev, Tim & Ghysels Eric (1994): "Periodic Autoregressive Conditional Heteroskedasticity"; *Cahiers de recherche 9408*, Universite de Montreal, Departement de sciences economiques.
- [7] Box, George E.P. & Jenkins, Gwilym M. (1976): "Time series analysis: forecasting and control", Prentice-Hall, Englewood Cliffs NJ.
- [8] Brockwell, Peter J. & Davis, Richard A. (2002): "Introduction to Time Series and Forecasting", 2nd ed., Springer Verlag, New York.
- [9] Clements, Michael P. & Hendry, David F. (1998): "Forecasting economic time series", Cambridge Univ. Press.
- [10] Clements, Michael P. & Hendry, David F. (1999): "Forecasting non-stationary economic time series", MIT Press, Cambridge.
- [11] Crespo Cuaresma, J. & Hlouskova, J. & Kossmeier, S. & Obersteiner, M. (2004): "Forecasting electricity spot-prices using linear univariate time-series models", *Applied Energy*, 77:87-106.

- [12] Diebold, Francis X. & Mariano, Roberts S. (1995): "Comparing predictive accuracy", *Journal of Business and Economic Statistics*, 13:253-263.
- [13] EEX (2008): $\langle$ URL: <http://www.eex.com/de/> $\rangle$ - Zugriff am 14.07.2008.
- [14] ELECPOOL (2008): $\langle$ URL: http://www.elecpool.com/about/about_f.html $\rangle$ - Zugriff am 05.12.2008.
- [15] Escribano, Álvaro & Peña, Juan Ignacio & Villaplana, Pablo (2002): "Modeling Electricity Prices: International Evidence", *Economics Working Papers we022708*, Universidad Carlos III, Departamento de Economía.
- [16] EViews (2004): "EViews 5 Command and Programming Reference", Quantitative Micro Software, LLC, Irvine CA.
- [17] EViews (2004): "EViews 5 Users's Guide", Quantitative Micro Software, LLC, Irvine CA.
- [18] EXAA (2008a): $\langle$ URL: <http://www.exaa.at/> $\rangle$ - Zugriff am 14.07.2008.
- [19] EXAA (2008b): $\langle$ URL: http://www.exaa.at/static/cms/sites/exaa.at/media/downloads/annual_reports.html/anual_report_2007_dt.pdf.pdf $\rangle$ - Zugriff am 27.11.2008.
- [20] EXAA (2008c): $\langle$ URL: http://www.exaa.at/static/cms/sites/exaa.at/media/downloads/EXAA_broschuere_dt_2.pdf $\rangle$ - Zugriff am 14.07.2008.
- [21] E-CONTROL (2008): $\langle$ URL: <http://www.e-control.at/> $\rangle$ - Zugriff am 27.11.2008.
- [22] Franses, Philip Hans (1996): "Periodicity and stochastic trends in economic time series", Oxford Univ. Press.
- [23] Franses, Philip Hans (1998): "Time series models for business and economic forecasting", Cambridge Univ. Press.
- [24] Franses, Philip Hans & Paap, Richard (2004): "Periodic time series models", Oxford Univ. Press.
- [25] Ghysels, Eric & Osborn, Denise R. & Rodrigues, Paulo M.M. (1999): "Seasonal Nonstationarity and Near-Nonstationarity", *CIRANO Working Papers 99s-05*, CIRANO.
- [26] Ghysels, Eric & Osborn, Denise R. (2001): "The econometric analysis of seasonal time series", Cambridge Univ. Press.

- [27] Greene, William H. (2000): "Econometric analysis", 4th ed., Prentice-Hall Internat., London.
- [28] Gupta, P.C. (1985): "Adaptive short-term forecasting of hourly loads using weather information", in: Bunn, D.W. & Farmer, E.D. (eds.), *Comparative Models for Electrical Load Forecasting*, Wiley, New York.
- [29] Hamilton, James D. (1994): "Time Series Analysis", Princeton Univ. Press.
- [30] Huurman, Christian & Ravazzolo, Francesco & Zhou, Chen (2007): "The Power of Weather: Some Empirical Evidence on Predicting Day-ahead Power Prices through Day-ahead Weather Forecasts", Tinbergen Institute Discussion Papers 07-036/4, Tinbergen Institute.
- [31] Koopman, Siem Jan & Ooms, Marius & Carnero, M. Angeles (2005): "Periodic Seasonal Reg-ARFIMA-GARCH Models for Daily Electricity Spot Prices", Tinbergen Institute Discussion Papers 05-091/4, Tinbergen Institute.
- [32] Kovac, Daniel (2008): Kommunikation per Email, Mitarbeiter der österreichischen Energiebörse EXAA.
- [33] Kratena, Kurt (2004): "Evaluierung der Liberalisierung des österreichischen Energiemarktes aus makroökonomischer Sicht", WIFO Monatsberichte, 77(11/2004):837-843.
- [34] Kunst, Robert M. (2005): "Angewandte Zeitreihenanalyse", Lehrveranstaltungsmitteilungen, Universität Wien.
- [35] Kunst, Robert M. (2006): "Ökonometrie der Saison", Lehrveranstaltungsmitteilungen, Universität Wien.
- [36] Ljung, G. & Box, G. (1979): "On a Measure of Lack of Fit in Time Series Models", *Biometrika*, 66:265-270.
- [37] NORDPOOL (2008): < URL: <http://www.nordpool.com/asa/> > - Zugriff am 27.11.2008.
- [38] Ramanathan, R. & Granger, C.W.J. & Engle, R. (1985): "two-step modelling for short-term Forecasting", in: Bunn, D.W. & Farmer, E.D. (eds.), *Comparative Models for Electrical Load Forecasting*, Wiley, New York.
- [39] Ramanathan, R. & Engle, R. & Granger, C.W.J. & Vahid-Araghi, F. & Brace, C. (1997): "Short-run forecasts of electricity loads and peaks", *International Journal of Forecasting*, 13:161-174.
- [40] Robinson, Terry A. (2000): "Electricity pool-prices: a case study in nonlinear time-series modelling", *Applied Economics*, 32:527-532.

- [41] Rothman, Philip (1999): "Nonlinear time series analysis of economic and financial data", Kluwer, Boston.
- [42] Rubia, Antonio (2001): "Testing For Weekly Seasonal Unit Roots In Daily Electricity Demand: Evidence From Deregulated Markets", Working Papers. Serie EC 2001-21, Instituto Valenciano de Investigaciones Económicas, S.A. (Ivie).
- [43] Schira, Josef (2003): "Statistische Methoden der VWL und BWL: Theorie und Praxis", Pearson Studium, München.
- [44] Schwarz, Gideon (1978): "Estimating the Dimension of a Model", Annals of Statistics, 6(2): 461-464.
- [45] Schweppe, Fred C. & Caraminis, Michael C. & Tabors, Richard D. & Bohn, Roger E. (1988): "Spot pricing of electricity", Kluwer, Boston.
- [46] TIWAG (2008): $\langle$ URL: <http://www.tiwag-netz.at/> $\rangle$ - Zugriff am 13.12.2008.
- [47] TRECERS (2008): $\langle$ URL: <http://www.trecers.net/de/concept.html> $\rangle$ - Zugriff am 14.07.2008.
- [48] VERBUND (2008): $\langle$ URL: http://www.verbund.at/cps/rde/xchg/internet/hs.xsl/197_230.htm $\rangle$ - Zugriff am 13.12.2008.
- [49] VKW (2008): $\langle$ URL: <http://www.vkw-netz.at/inhalt/at/> $\rangle$ - Zugriff am 13.12.2008.
- [50] Weron, Rafal & Misiorek, Adam (2005): "Forecasting Spot Electricity Prices With Time Series Models", Econometrics 0504001, EconWPA.

Zusammenfassung

Gegenstand dieser Arbeit ist der Vergleich von Prognoseeigenschaften einer Reihe linearer, univariater Modelle für die täglichen Spotstrompreise der österreichischen Energiebörse. Die verwendeten Spezifikationen inkludieren autoregressive moving average Modelle und periodische autoregressive Modelle. Ebenfalls wurde ein multiples Regressionsmodell untersucht. Dabei behandelten separate autoregressive moving average Modelle alle Wochentage einzeln. Diese Herangehensweise erwies sich als unzureichend. Es zeigte sich auch, dass periodische Modelle das Potenzial haben, bessere Vorhersageeigenschaften zu liefern, als klassische autoregressive moving average Modelle, wo saisonale Unterschiede in den Daten nur mit Dummyvariablen berücksichtigt wurden. Dies hängt jedoch stark von der gewählten Lagordnung ab, wobei Informationskriterien sich nur bedingt dazu eignen.

Abstract

Subject of this paper is the comparison of the forecasting abilities of a set of linear, univariate models for the daily electricity spot prices of the Austrian Energy Exchange. The applied specifications include autoregressive moving average models and periodic autoregressive models. Also a multiple regression model was investigated. Thereby separated autoregressive moving average models dealt with every weekday individually. This approach turned out to be insufficient. It also appeared that periodic models have the potential to deliver better forecasting abilities than classic autoregressive moving average models, where seasonal differences in the data were considered only by dummy variables. This depends however highly on the chosen lag order, whereas information criteria are not always reliable.

Curriculum Vitae

Persönliche Daten

Vorname / Nachname	Damir Zivkovic
Staatsbürgerschaft	Österreich
Geburtsdatum	01. Dezember 1982
Geschlecht	Männlich

Berufliche Erfahrung

Seit Juni 2008	Kontakter / Interviewer Sensor Marktforschung Mariahilferstraße 81/1/13, A-1060 Wien Organisation und Durchführung von Marktumfragen, Erstkontaktaufnahme mit Kunden und Feldarbeit
08/1996 - 09/2008	Gastronom Gasthaus Dorfbrunnen Arnbach 18, A-9920 Sillian zuständig für Gästebetreuung, Logistik und Finanzen im Familienbetrieb (nur in der Sommer- und Wintersaison)

Ausbildung

Seit Oktober 2006	Studium der Informatik (Data Engineering & Statistics) TECHNISCHE UNIVERSITÄT WIEN
10/2002 - 03/2009	Magisterstudium der Volkswirtschaftslehre UNIVERSITÄT WIEN
09/1997 - 06/2001	BUNDES-OBERSTUFENREALGYMNASIUM LIENZ Abschluss: Matura Ausbildungsschwerpunkt: Bildnerische Erziehung und Gestaltung
09/1993 - 06/1997	BUNDESREALGYMNASIUM WIEN ZIRKUSGASSE Ausbildungsschwerpunkt: Mathematik und Geometrisches Zeichnen
09/1989 - 07/1993	ÖFFENTLICHE VOLKSSCHULE WIEN NOVARAGASSE

Zusätzliche Angaben

Grundwehrdienst abgeleistet (07.01.2002 - 06.09.2002).

Wien, im März 2009