

Universität - Gesamthochschule Paderborn
Fachbereich Wirtschaftswissenschaften

Fachgebiet: Statistik, Ökonometrie und Entscheidungstheorie

Prognosesysteme zur Optimierung der
Verlags-Grossisten-Einzelhändler-Beziehung:
Eine empirische Studie zum
Special Interest Zeitschriftenbereich

Dissertation zur Erlangung des Grades
eines Doktors der Wirtschaftswissenschaften

vorgelegt von

Markus Greitenevert
Waterbergstr. 28
81827 München

02. November 2000

1	Einleitung	5
2	Einführung in das deutsche Pressewesen	6
2.1	Die Vertriebswege des deutschen Pressewesens	6
2.2	Das deutsche Presse-Grosso	9
2.2.1	Die Geschichte des Presse-Grosso	9
2.2.2	Die Besonderheiten der Vertriebsform Presse-Grosso	10
2.3	Verfahren der Bezugsregulierung im Presse-Grosso	16
2.3.1	MBR - Marktorientierte Bezugsregulierung	16
2.3.1.1	Grundüberlegungen zur MBR	17
2.3.1.2	Das MBR-Grundmodell	19
2.3.2	BKO - Bezugsregulierung für klein- und mittelauftragige Objekte	23
2.3.3	Kritische Anmerkungen zu den Verfahren der Bezugsregulierung	23
2.3.4	Weiterentwicklung der MBR	24
2.4	Ausgangssituation und Problemstellung	26
3	Beschreibung und Identifikation von Zeitreihen	28
3.1	Visuelle Beschreibung der Daten	29
3.2	Beschreibung stationärer Prozesse	39
3.2.1	Beschreibende Momente von empirischen Zeitreihen	41
3.2.2	Definition stationärer Prozesse	42
3.2.2.1	Schwache Stationarität oder Stationarität zweiter Ordnung	42
3.2.2.2	Strenge Stationarität oder Stationarität erster Ordnung	43
3.2.3	Zwei wichtige stochastische Prozesse	44
3.3	Beschreibung und Identifikation der Verkaufsdaten am Beispiel des Gros- sisten Lütkemeyer Münster	45
3.3.1	Überprüfung der Autokorrelation und partiellen Autokorrelation	45
3.3.1.1	Autokorrelation (AC) und Korrelogramm	46
3.3.1.2	Partielle Autokorrelation (PAC)	49
3.3.2	Einheitswurzeltests	51
3.3.2.1	Dickey-Fuller-Test (DF)	52
3.3.2.2	Augmented-Dickey-Fuller-Test (ADF)	53
3.3.2.3	Durchführung Augmented-Dickey-Fuller-Test (Lütkemeyer Münster)	55

3.3.3	Tests auf Normalverteilung	60
3.3.3.1	Tests auf Schiefe und Wölbung	61
3.3.3.2	Jarque-Bera-Test	62
3.3.3.3	Kolmogorov-Smirnov-Test	63
3.3.3.4	Studentized-Range-Test	64
3.3.3.5	Durchführung der Normalverteilungstests (Lütkemeyer Münster)	65
3.3.4	Tests auf Unabhängigkeit	67
3.3.4.1	Portmanteau-Test	67
3.3.4.2	Box-Ljung- und Box-Pierce-Test	68
3.3.4.3	Turning-Point-Test	69
3.3.4.4	Runs-Test	70
3.3.4.5	Rank-Version of the von Neumann-Ratio-Test	71
3.3.4.6	Durchführung der Unabhängigkeitstests (Lütkemeyer Münster)	72
3.3.5	Tests auf Nichtlinearität	76
3.3.5.1	Asymmetrietest von Neftci	76
3.3.5.2	Durchführung des Asymmetrietests von Neftci (Lütkemeyer Münster)	78
4	Theoretische Aspekte der Modellentwicklung	79
4.1	Methoden der Zeitreihenzerlegung	79
4.2	Der Trend in der Zeitreihenanalyse	84
4.3	Saisonkomponente	88
4.4	Theoretische Erläuterungen von ARIMA-Prozessen	91
4.4.1	Der Moving-Average-Prozess (MA)	91
4.4.2	Der Autoregressive-Prozess (AR)	93
4.4.3	Gemischte ARIMA(p, d, q)-Modelle	96
4.5	Vorgehensweise bei der ARIMA-Analyse	98
4.5.1	Spezifikation des Modells	98
4.5.2	Modellschätzung	100
4.5.3	Diagnose des geschätzten Modells	102
4.5.3.1	Koeffiziententests	107
4.5.3.2	Residuen-Tests	108
4.5.3.3	Spezifikations- und Stabilitätstests	110
4.6	Regressionsansatz mit ARMA-Term zur Beschreibung der Störgröße	114
4.7	Analyse saisonaler Zeitreihen	117
4.7.1	Einführung in die saisonale Zeitreihenanalyse	117
4.7.2	Saisonale Anpassung und SARIMA-Modelle	118
4.7.3	Stationarität von saisonalen Zeitreihen	123

5	Modellentwicklung	132
5.1	Beschreibung und Identifikation des gesamten Datensatzes	132
5.2	Durchführung der Modellentwicklung	135
5.2.1	Klasse 1 - Einfacher Zufallsprozess	137
5.2.2	Klasse 2 - Vermutlich einfacher Zufallsprozess, nur einzelne lags der ACF oder PACF besitzen signifikante Ausschläge	151
5.2.3	Klasse 3 - Signifikante Ausschläge der ACF und PACF auf lag 1	175
5.2.4	Klasse 4 - Trendverlauf, ACF läuft mit zunehmender lag Länge aus	202
5.2.5	Klasse 5 - Ausgeprägte Saisonfigur, ACF mit wellenförmigen Verlauf	220
5.2.6	Klasse 6 - Saisonverlauf, signifikante Ausschläge der ACF und PACF auf den ersten lags und auf lag 12	229
5.2.7	Klasse 7 - Saisonverlauf, signifikante Ausschläge der ACF und PACF auf lag 12	242
6	Abschließende Bemerkungen	254
	Anhang	258
	Anhang 1: Graphen der Verkaufszahlen, ACF und PACF für ausgewählte Grossisten	259
	Anhang 2: Kritische Grenzen Durbin-Watson-Test	273
	Literatur	275

1 Einleitung

Die vorliegende Arbeit befasst sich mit der Entwicklung von Verkaufsprognosen im Zeitschriftenbereich zur Optimierung der Verlags-Grossisten-Einzelhändler-Beziehung. Zur Optimierung dieser komplexen Beziehung ist es notwendig, die Vertriebswege und den wechselseitigen Fluss von vertriebsrelevanten Daten und Informationen näher zu erläutern.

Die Problematik der Identifikation, Entwicklung und Kontrolle von Prognosesystemen wird exemplarisch an den realisierten Verkaufszahlen einer im Markt etablierten Special Interest Zeitschrift erörtert. Die methodische Vorgehensweise bei der Entwicklung von Verkaufsprognosemodellen lässt sich auf andere Zeitschriften aus dem Segment der Special Interest Zeitschriften übertragen.

Für die ersten Analyseschritte standen lediglich die Daten von drei Grossisten zur Verfügung, nämlich Carlsen Kiel, Lütkemeyer Münster und SüdWest Vertrieb Friedrichshafen. Erst zum späteren Zeitpunkt wurden die Daten der übrigen Grossisten zur Entwicklung der Verkaufsprognosemodelle bereitgestellt. Auf die Analyse der Verkaufswerte für die Grossisten aus den neuen Bundesländern wurde verzichtet, da die betrachtete Zeitschrift in den neuen Bundesländern ausgesprochen geringe Verkaufszahlen aufwies.

Begonnen wird im Kapitel 2 mit einer thematischen Einführung in die Vertriebsstruktur des deutschen Pressewesens, wobei der Schwerpunkt auf dem Vertriebsweg über das Presse-Grosso liegt. Dem schließen sich im Kapitel 3 Verfahren zur Identifikation von Zeitreihen an. Neben graphischen Verfahren zur ersten Erkennung von Strukturen, wie funktionale Zusammenhänge, Ausreißer, Struktursprünge und Wendepunkte, werden verschiedene Testverfahren zur Identifikation von Zeitreihen vorgestellt.

Ein kurzer Abriss der theoretischen Grundlagen der Zeitreihenanalyse erfolgt im Kapitel 4. Ein Schwerpunkt liegt auf der Vorstellung der SARIMA-Modelle, die für viele der untersuchten Zeitreihen zur Modellbildung verwendet wurden.

Die Modellentwicklung im Kapitel 5 lässt sich in drei Arbeitsschritte unterteilen. Zuerst werden die Zeitreihen klassifiziert, daran schließen sich die Identifikationstests an und zum Schluss erfolgt die Modellentwicklung inklusive Diagnose und Prognose.

Als Zeitreihenanalysetool wurde hauptsächlich das Programm EViews 2.0 verwendet. Einige Tests, über die das Programm EViews 2.0 nicht verfügt, sind mit dem Programm SPSS/PC berechnet worden.

2 Einführung in das deutsche Pressewesen

Eine zentrale Rolle innerhalb des deutschen Pressewesens spielt das Presse-Grosso. Seine historische Entstehung und all seine gewachsenen Besonderheiten werden daher kurz vorgestellt.¹ Danach erfolgt eine Einführung in die Verfahren zur bedarfsgerechten Verteilung von Zeitschriften und Zeitungen auf die Einzelhändler (MBR: Marktorientierte Bezugsregulierung). Zum Schluss wird dem Leser das Konfliktpotential marktorientierter Bezugsregulierung versus Verlagsprognose vorgestellt.

2.1 Die Vertriebswege des deutschen Pressewesens

In Deutschland gelangen die Presseerzeugnisse über eine Reihe unterschiedlicher Vertriebswege zum Leser. Die beiden wichtigsten Absatzwege sind das Abonnement und der Einzelheftverkauf. Je nach Gattung der Zeitung oder Zeitschrift ergeben sich unterschiedliche Vertriebschwerpunkte. Zum Beispiel werden 64% der Publikumszeitschriften im Einzelverkauf vertrieben. Fachzeitschriften hingegen werden zu 90% im Abonnement verkauft.²

Der Einzelheftverkauf teilt sich in die Absatzwege Bahnhofsbuchhandel, werbender Buch- und Zeitschriftenhandel und den allgemeinen Einzelhandel auf. Die drei ersten Absatzwege werden direkt durch die Verlage beliefert. Die Belieferung des allgemeinen Einzelhandels hingegen erfolgt durch die zwischengeschalteten Großhändler, die Presse-Grossisten.

Neben dem Einzelheftverkauf und dem Abonnement werden aber noch andere Vertriebsformen, wie zum Beispiel die Lesezirkel, die Bordexemplare in Flugzeugen und die Sonderverkäufe genutzt. Sonderverkäufe werden in der Regel über zwischengeschaltete Vertriebsgesellschaften abgewickelt und ermöglichen es den Verlagen, ihre Kooperationspartner zu besonders günstigen Abnahmepreisen zu beliefern.

Zurück zum allgemeinen Einzelhandel, er umfasst die Palette Kaufhaus, Supermarkt, Zeitschriftenfachgeschäft, Tankstelle, Kiosk, Spezialzeitschriftenverkaufsstellen usw. Eine genaue Unterteilung findet man in den Strukturanalysen (EHASTRA) über den Zeitschriften- und Zeitungen-Einzelhandel in der Bundesrepublik Deutschland.³

Die Verteilung der Zeitschriften auf die Großhändler kann direkt durch die Vertriebsabteilung des Verlages erfolgen oder aber über einen zwischengeschalteten Vertriebsser-

¹ Vgl. Greitenevert/Kelemen-Rehm 1992, 4-12.

² VDZ Zeitschriftenpresse in Zahlen 1996, 6.

³ VDZ Mini-Ehastra 1996.

vice, wie ihn zum Beispiel die Großverlage anbieten. In Ausnahmefällen werden Einzelhandelsgeschäfte auch direkt vom Verlag beliefert.⁴

Zusammenfassend ergeben sich die folgenden Vertriebswege für den Verkauf von Zeitungen oder Zeitschriften:⁵

- 1) Verlag ⇒ Presse-Großhandel ⇒ Einzelhandel ⇒ Leser
- 2) Verlag ⇒ Bahnhofsbuchhandel ⇒ Leser
- 3) Verlag ⇒ Einzelhandel ⇒ Leser
- 4) Verlag ⇒ Werbender Buch- und Zeitschriftenhandel ⇒ Leser
- 5) Verlag ⇒ Lesezirkel ⇒ Leser
- 6) Verlag ⇒ Vertriebsgesellschaft ⇒ Kooperationspartner ⇒ Leser
- 7) Verlag ⇒ Abonnement ⇒ Leser

Die wichtigste Vertriebsschiene für Publikumszeitschriften stellt zweifellos der Weg „Verlag ⇒ Presse-Großhandel ⇒ Einzelhandel ⇒ Leser“ dar.

Die meisten Unternehmen des selbständigen Presse-Großhandels sind im Verband Deutscher Buch-, Zeitungs- und Zeitschriftengrossisten e.V. (Grosso-Verband) organisiert. Dieser Verband definiert Grossisten als „Unternehmen, die überwiegend Zeitungen und Zeitschriften kaufen und wieder verkaufen, Wiederverkäufer nicht am Gewinn beteiligen, nicht als Zeitungs- und Zeitschriften-Verleger oder überwiegend als Lieferanten des Zeitungs- und Zeitschriften-Großhandels auftreten oder weder direkt noch über eine Teilhaberschaft mit Verlagen oder Lieferanten verbunden sind“.⁶

In der Bundesrepublik gibt es, Stand 31.12.1998, 92 Presse-Großhandelsunternehmen, von denen 76 dem Presse-Grosso, dem Bundesverband Deutscher Buch-, Zeitungs- und Zeitschriften-Grossisten e.V. angeschlossen sind.⁷

Das deutsche Presse-Grosso teilt sich in 109 Vertriebsräume auf, 91 in den alten und 18 in den neuen Bundesländern. In den alten Bundesländern gibt es fünf Vertriebsräume, in denen jeweils zwei Grossisten mit einer eindeutigen Aufteilung nach Objekten tätig sind. Dies sind die Vertriebsräume Berlin-West, Saarbrücken, Darmstadt, Dortmund und Hamburg.⁸

Der Bestand an Presse-Einzelhändlern, die durch das Presse-Grosso beliefert werden, umfasste zum 31.12.1998 im gesamten Bundesgebiet 119.995 Verkaufsstellen. Auf die

⁴ Brummund 1985, 25.

⁵ Fürstner 1985, 139.

⁶ Brummund 1985, 25.

⁷ Presse-Grosso Homepage 1999.

⁸ VDZ Zeitschriftenpresse in Zahlen 1996, 8.

alten Bundesländer entfielen dabei 97.781 Verkaufsstellen und auf die neuen Bundesländer 22.214.

In der Bundesrepublik Deutschland kamen 1998 auf eine Presseverkaufsstelle durchschnittlich 685 Einwohner.⁹

Die Titelanzahl im Ordersortiment eines Presse-Grossisten umfasst ca. 3700 Titel, die von ca. 150 Verlagen und nationalen Vertriebsfirmen geliefert werden.¹⁰

Die vorliegende Arbeit beschäftigt sich ausschließlich mit den Einzelheftverkäufen einer Special Interest Zeitschrift über die Vertriebschiene Verlag-Grossist-Einzelhandel-Leser. Im Gegensatz zum Abo-Geschäft können die Einzelheftverkäufe von Ausgabe zu Ausgabe eines Titels starken Schwankungen unterliegen. Bei jeder Ausgabe trifft der potentielle Leser eine erneute Kaufentscheidung. Man spricht in diesem Zusammenhang auch von der „täglichen Abstimmung am Kiosk“.¹¹

Zusätzlich zu diesen Verkaufsschwankungen muss auch die sogenannte vagabundierende Nachfrage berücksichtigt werden. Der Leser kauft seine Zeitung oder Zeitschrift nicht immer in derselben Verkaufsstelle. Die optimale Erfassung und Vorhersage der Nachfrageschwankungen ist die wohl schwierigste Aufgabe im Bereich des Pressevertriebs.

⁹ Presse-Grosso Homepage 1999.

¹⁰ Brummund 1985, 239.

¹¹ Brummund 1985, 29.

2.2 Das deutsche Presse-Grosso

Das Presse-Grosso ist für die meisten Verlage die entscheidende Vertriebsform zum Absatz ihrer Zeitungen und Zeitschriften. Seine besondere Stellung erklärt sich einerseits aus seiner geschichtlichen Entstehung, andererseits aus den wirtschaftlichen Interessen der Marktpartner Verlag, Großhandel und Einzelhandel.

2.2.1 Die Geschichte des Presse-Grosso

Die heutige Form des Presse-Grosso entwickelte sich erst nach dem zweiten Weltkrieg. Schon vor dem ersten Weltkrieg entstanden in Leipzig und Stuttgart Buchhandelskommissionäre auf der Großhandelsstufe. Da sich die Kommissionäre weigerten, andere Einzelhandelsgeschäfte als den traditionellen Buchhandel zu beliefern, gründeten sich die Leipziger Grossisten, die neben dem Buchhandel auch den Papier- und Zeitschriftenhandel belieferten.

Diese zentrale Belieferungsform war sehr zeitintensiv und inflexibel. Aus diesen Überlegungen heraus bauten die bedeutendsten Verlage ein eigenes Absatznetz für den Vertrieb ihrer Objekte auf. Diese sogenannten Ortsgrossisten waren in mehr als 100 großen deutschen Städten vertreten. Die Belieferung der ländlichen Regionen erfolgte weiterhin durch den zentralen Buch- und Zeitschriftenhandel oder direkt über den Postweg.¹²

Während der nationalsozialistischen Gewaltherrschaft erlitt das deutsche Pressewesen einen starken Einschnitt. Gründe waren Pressezensur, Zerschlagung der Verlagshäuser, die sich im jüdischen Besitz befanden, und die Beschränkung des Pressevertriebs durch Berufschutzanordnungen und Geschäftsgrundsätze für den gesamten Zeitungs- und Zeitschriftenhandel. Der völlige Zusammenbruch erfolgte zum Ende des zweiten Weltkriegs.¹³

Unmittelbar nach Kriegsende verhängten die alliierten Besatzungsmächte zunächst ein Verbot für den Vertrieb von Presseerzeugnissen. Im Herbst 1945 erhielten die ersten Verleger und Grossisten die Möglichkeit, Lizenzen und Vertriebsgenehmigungen zu bekommen. Dabei spielte die fachliche Qualifikation der Bewerber eine untergeordnete Rolle, viel wichtiger war deren politische Eignung.

Die ersten Jahre nach dem zweiten Weltkrieg waren von Papierknappheit und einer enormen Nachfrage nach Presseerzeugnissen gekennzeichnet. Einen nochmaligen Boom erlebte der Pressemarkt nach der Währungsreform. Um die Nachfrage decken zu

¹² Brummund 1985, 205.

¹³ Brummund 1985, 206.

können, wurden viele Einzelhändler von mehreren Grossisten gleichzeitig beliefert, deren Sortimente sich vielfach überschneiden.

In den fünfziger Jahren trat die erste Marktsättigung ein. Damit tauchte ein zuvor nicht gekanntes Problem auf, die Remission. Der Einzelhandel war nicht in der Lage, die Remittenden richtig auf die verschiedenen Grossisten, von denen er die Ware erhalten hatte, zu verteilen. Der auftretende Konkurrenzdruck, die mangelnde Kapitalausstattung und die oft desolate Organisation der Grossisten führten zu einer Pleitewelle.

In dieser Phase erhielten die leistungsstärksten Grossisten von den großen Verlagen ein Alleinauslieferungsrecht innerhalb klar abgegrenzter Regionen. Im Zuge von Rationalisierungen, Kooperationen und Fusionen reduzierte sich die Zahl der Grossisten immer weiter. Die Funktionsweise des heutigen Grosso-Systems ruht auf zwei Grundpfeilern, dem Alleinauslieferungsrecht innerhalb und dem Belieferungsverbot außerhalb der Vertragsgrenzen.¹⁴

2.2.2 Die Besonderheiten der Vertriebsform Presse-Grosso

Das deutsche Presse-Grosso nimmt eine Sonderstellung im Vergleich zu den übrigen Großhandelsbranchen ein. Hinsichtlich seines Servicecharakters lässt es sich lediglich mit den Dienstleistern der Grundversorgung mit Elektrizität, Gas und Wasser vergleichen, die ebenfalls Gebietsmonopole besitzen. Der Elektrizitätsbereich ist seit 1999 zu Gunsten eines liberalisierten europäischen Energiemarktes im Umbruch.

Unterschiede zwischen Presse-Grosso und Dienstleistern der Grundversorgung bestehen aber in der gesetzlichen Stellung. Die kartellrechtliche Erklärung zur Bereichsausnahme für die Grundversorger ist im § 103 GWB (Gesetz gegen Wettbewerbsbeschränkungen) geregelt. Eine solche gesetzliche Regelung existiert für das Presse-Grosso nicht.¹⁵

Vielmehr beruht die Alleinstellung der Grossisten innerhalb bestimmter Gebietsgrenzen „letztlich auf ihrer Duldung kraft Nicht-Beanstandung“ durch das Bundeskartellamt.¹⁶

Die „Duldung“ durch das Bundeskartellamt wird noch heute mit den Besonderheiten des Pressemarktes begründet.

¹⁴ Brummund 1985, 209-211.

¹⁵ Ipsen 1980, 69.

¹⁶ Ipsen 1980, 77.

Das historisch gewachsene Alleinauslieferungsrecht der Grossisten bringt die Verpflichtung zur *Neutralität* gegenüber allen Verlagen und Titeln mit sich. Auf der Mitgliederversammlung 1976 hat sich der Grosso-Verband per Beschluss ausdrücklich zur Neutralität verpflichtet. Es darf keine Diskriminierung von Zeitschriften- und Zeitungstiteln aus „politischen, weltanschaulichen oder welchen Gründen auch immer“ geben.¹⁷

Diese Verpflichtung des Zeitschriften- und Zeitungshandels besitzt laut Bundesverfassungsgericht verfassungsrechtliche Bedeutung. Nur durch die Neutralitätspflicht kann in der bestehenden Grossovertriebsstruktur das Recht auf Informationsfreiheit (§ 5 Grundgesetz) gewährleistet werden.¹⁸

Eine Einschränkung der Neutralitätspflicht kann nur per Gesetz erfolgen, zum Beispiel aus Gründen des Jugendschutzes, des Verbotes zur Verbreitung rechts- oder linksradikalen Gedankenguts.

Das *Diskriminierungsverbot* gewährleistet einen freien Marktzutritt für neue Zeitungs- und Zeitschriftentitel und für neue Unternehmen des Presse-Einzelhandels (vergl.: § 26 Abs. 2 GWB).¹⁹

Ist absehbar, dass ein neues Objekt so gut wie keine Marktchancen besitzt, „hat der Grossist das Recht, die Aufnahme des Objektes in sein Sortiment zu verweigern“.²⁰

Die Aufrechterhaltung von Pressefreiheit und -vielfalt erfordert es, dass die Grossisten auch solche Objekte im Sortiment führen, bei denen die Kosten deutlich über den Erlösen liegen. Diese vertriebliche Besonderheit bezeichnet man als *Alimentierung*. Der Vertrieb ertragschwacher Titel wird durch großauflagige und gewinnbringende Titel finanziert. Lediglich 20% aller Titel sind für die Grossisten wirtschaftlich. 80% aller Titel sind hingegen unwirtschaftlich und müssen daher alimentiert werden.²¹

Neben der Alimentierung der Titel gibt es laut Kaiser auch eine Alimentierung der Einzelhändler. Lediglich 28% der Presseverkaufsstellen weisen Verkaufszahlen auf, bei denen der Erlös des Grossisten die Kosten überschreitet, bei 8% der Einzelhändler werden die Kosten des Grossisten gerade gedeckt und 64% der Presseverkaufsstellen weisen eine Kostenunterdeckung auf, die Kosten der Grossisten sind größer als die Erlöse.²²

¹⁷ Kaiser 1979, 91.

¹⁸ Kaiser 1979, 47-48.

¹⁹ Kaiser 1979, 50.

²⁰ Greitenevert/Kelemen-Rehm 1992, 9 und vgl. Kaiser 1979, 47.

²¹ Kaiser 1979, 92.

²² Kaiser 1979, 97.

Brummund hingegen bezweifelt die Daten der Alimentierung von Objekten und Einzelhändlern, da solche Zahlen nur durch eine objekt- und stellenspezifische Kosten- und Erlösrechnung zu erzielen sind, über die die Grossisten nicht verfügen.²³

Eine weitere Besonderheit des Pressevertriebs ist die *vertikale Preisbindung*. Im Rahmen der vertikalen Preisbindung bestimmen die Verlage nicht nur den Abgabepreis, sondern auch die Preise, die der Groß- und Einzelhandel für den weiteren Verkauf an die Leser zu berechnen hat. Eines der wichtigsten Instrumente zur Regulierung des Absatzes obliegt somit den Verlagen und nicht den nachgelagerten Marktstufen. Der Handel ist somit nur noch Absatzmittler. Die vertikale Preisbindung wurde schon 1887 vom Börsenverein des deutschen Buchhandels durchgesetzt und beruht auf zweiseitigen, privatrechtlichen Verträgen zwischen Verlagen und Grossisten und nicht auf einseitigen Weisungen der Verlage. Die Ergebnisse der Verhandlungen über die Festschreibung der vertikalen Preisbindung zwischen Verlag und Grossist hängen in erster Linie von der Stärke der Positionen der jeweiligen Verhandlungspartner ab. Verlage, die sich der vertikalen Preisbindung bedienen, müssen sie allen Händlern auferlegen. Ausnahmen sind nicht zulässig.

Auch der Gesetzgeber betrachtet die vertikale Preisbindung im Zeitungs- und Zeitschriftenbereich mehr unter kulturpolitischen als unter ökonomischen Gesichtspunkten. Das Hauptargument für die vertikale Preisbindung ist der Erhalt der Titelvielfalt. Dürfte der Pressegroß- und Presseeinzelhandel selbst die Preise festsetzen, so würden nur noch hochauflagige Titel in das Sortiment gelangen. Vertikale Preisbindung dient somit dem Erhalt der Pressefreiheit und -vielfalt.²⁴

Preisbindung bedeutet aber auch immer ein Außerkraftsetzen des Marktmechanismus. „Festpreise treten in der Regel dann auf, wenn der Verkaufspreis“ oberhalb „des Gleichgewichtspreises liegt, der sich auf dem Markt durch Angebot und Nachfrage ergeben würde“.²⁵ Das Argument, Festpreise seien für den Verbraucher vorteilhaft, da sie dem Erhalt der Titelvielfalt dienen, trifft sicherlich bis zu einem gewissen Grad für den Konsumenten im Pressemarkt zu. Vergessen sollte man aber nicht, dass die Preisbindung auch immer für diejenigen vorteilhaft ist, die sie durchgesetzt haben.

Neben der vertikalen Preisbindung spielt die *Erstverkaufstagsregelung* eine sehr wichtige Rolle. Erstverkaufstagsregelung bedeutet, dass die Exemplare der Ausgabe eines Objektes immer ab einem bestimmten Wochentag bundesweit im Einzelhandel zu erhalten sind. Zum Teil wurde die Erstverkaufstagsregelung auf die Gesamtheit aller Objekte einer Objektgruppe (z. B. Fernsehzeitschriften, Illustrierte, Wochenpresse usw.)

²³ Brummund 1985, 313.

²⁴ Brummund 1985, 153-159.

²⁵ Greitenevert/Kelemen-Rehm 1992, 13 und vgl. Weise/Brandes/Eger/Kraft 1991, 136-146.

ausgedehnt. Kein Objekt einer Objektgruppe kann sich somit einen zeitlichen Wettbewerbsvorteil verschaffen.²⁶

Neben dem Verkaufsbeginn wird auch die Angebotsdauer der jeweiligen Presseobjekte geregelt. Die Absatzmittler werden von den Verlagen zur Einhaltung des Verkaufsbeginns und der Angebotsdauer verpflichtet. Lesezirkel und Abonnements sind der Erstverkaufstagsregel nicht unterworfen. Vielfach erhalten die Abonnenten ihr Exemplar schon ein bis zwei Tage vor dem Verkaufsbeginn im Einzelhandel.

Die wohl wichtigste Besonderheit des Pressevertriebs ist das *Remissionsrecht* der nachgelagerten Handelsstufe.

Im Pressehandel ist es üblich, dass die nachgelagerten Handelsstufen die nicht verkauften Exemplare von Zeitungen und Zeitschriften innerhalb bestimmter Fristen an die Verlage zurückgeben können. Der Einkaufspreis wird ihnen zurückerstattet. Dieser im Pressehandel übliche Vorgang beruht auf dem Remissionsrecht der nachgelagerten Handelsstufe. Die Remission ist eine Bringschuld des Einzelhandels, sie kann erst nach Beendigung der Angebotszeit und innerhalb eines festgelegten Zeitraumes erfolgen.

Zur Erleichterung der Remissionsabwicklung holen die Grossisten die angefallenen Remittenden an festgelegten Stichtagen aus den Einzelhandelsgeschäften ab.

Zu unterscheiden sind dabei zwei Arten der Remission, die körperliche und die körperlose Remission. Die körperliche Remission findet zwischen Einzelhandel und Grossist statt.

Zwischen Grossist und Verlag kann die körperliche Remission als Kopf-, Fußleisten- oder Titelseitenremission erfolgen. Besteht der Verlag aber auf kompletter Zusendung der remittierten Exemplare, so hat er die dafür anfallenden Versandkosten selbst zu tragen.

In den siebziger Jahren entwickelten Grossisten und Verlage ein computergestütztes Verfahren zur körperlosen Ermittlung der Remission. Dieses Verfahren wurde von der IVW (Informationsgemeinschaft zur Feststellung der Verbreitung von Werbeträgern e.V.) genehmigt. Die Grossisten werden vertraglich zum Nachweis der körperlosen Remission verpflichtet. Dazu ist ein bestimmter Verfahrensablauf einzuhalten, der alle Warenbewegungen lückenlos erfasst und protokolliert. Das Protokoll wird den Verlagen wöchentlich zugesandt.

Die Remission zwischen Einzelhandel und Grossist muss aber weiterhin körperlich erfolgen, nur so lässt sich eine mögliche unzulässige Verwertung der nicht verkauften Objekte verhindern.

Remission ist das Ergebnis einer vagabundierenden Nachfrage. Sie lässt sich nicht vermeiden, sondern lediglich auf ein akzeptables Maß reduzieren. Ihre Ursachen sind sehr

²⁶ Greitenevert/Kelemen-Rehm 1992, 12.

vielschichtig, sie reichen von Käufern, die das Objekt nicht mehr kaufen, bis hin zu saisonalen Einflüssen.

Die Verlage sind daran interessiert, dass ihre Presseobjekte flächendeckend in ausreichender Menge zur Verfügung stehen. Ohne Remissionsrecht würde der Groß- und Einzelhandel von vornherein eine geringere Menge an Objekten ordern, um sein Warenrisiko zu minimieren. Die Folge wäre ein fast vollständiges Verschwinden von kleinauflagigen Objekten und eine starke Reduzierung der Verkaufschancen neuer Objekte.

Liegt das Warenrisiko aber bei den Verlagen, so sind die Grossisten und Einzelhändler bereit, kleinauflagige und auch neue Objekte in ihr Sortiment aufzunehmen.²⁷

Das *originäre Dispositionsrecht* der Verlage gegenüber den Grossisten ist neben dem Remissionsrecht eine der wichtigsten Besonderheiten im Presse-Grosso. Aufgrund des Wegfalls des Warenrisikos behalten sich die Verlage das Recht vor, die Höhe der Liefermenge, die der Grossist erhält, selbst zu bestimmen.

Wie stark ein Verlag das originäre Dispositionsrecht für sich beanspruchen kann, hängt von seiner Machtposition gegenüber den Grossisten ab. Großverlage können ihr Dispositionsrecht ohne Probleme gegenüber den Grossisten durchsetzen. Anders sieht es bei Kleinverlagen aus. Aufgrund ihrer ökonomischen Position sind sie vielfach nicht in der Lage, ihr Dispositionsrecht gegenüber den Grossisten durchzusetzen. Erwarten die Grossisten eine hohe Remission, so behalten sie sich das Recht vor, die Liefermenge an die vermutliche Absatzmenge anzupassen.

Aus dem originären Dispositionsrecht leiten die Grossisten das *derivate Dispositionsrecht* gegenüber dem Einzelhandel ab. Der Grossist bestimmt neben Menge auch die Zusammensetzung des Portfolios der Objekte, mit denen der Einzelhändler beliefert wird. Auch hier beruht die Durchsetzung des Dispositionsrechts in erster Linie auf der ökonomischen Macht des Grossisten gegenüber den Einzelhändlern.²⁸

Dispositions- und Remissionsrecht stehen in enger Beziehung zueinander. Auf das Dispositionsrecht können und werden die großen Verlage auf keinen Fall verzichten, da sie dadurch ihre wirtschaftlichen Interessen nachhaltig gegenüber dem Groß- und Einzelhandel durchsetzen können. Im Gegenzug müssen sie den nachgelagerten Handelsstufen aber das Remissionsrecht einräumen, denn ohne Remissionsrecht wären die Grossisten und Einzelhändler den Verlagen vollständig ausgeliefert. Kein Grossist oder Einzelhändler würde unter solchen Rahmenbedingungen weiterhin als Absatzmittler zur Verfügung stehen.

²⁷ Brummund 1985, 126-136 und Kaiser 1979, 146.

²⁸ Brummund 1985, 136-143.

Dispositions- und Remissionsrecht sind aus den ökonomischen Interessen der Marktpartner im Pressevertrieb erwachsen, als Nebeneffekt sichern sie die Pressevielfalt und Informationsfreiheit in der Bundesrepublik Deutschland. Gerade diesem Nebeneffekt verdankt es das Pressewesen, dass der Gesetzgeber und die Gerichte die vertrieblichen Besonderheiten dulden und bis heute keinerlei Eingriffe vorgenommen haben.

2.3 Verfahren der Bezugsregulierung im Presse-Grosso

Eine der zentralen Aufgaben im Pressevertrieb ist die marktgerechte Verteilung eines Objektes auf die Einzelhändler durch den jeweiligen Grossisten. Neben der Festlegung der Belieferungsmenge pro Einzelhändler muss der Grossist auch die Frage klären, welche Einzelhändler er mit welchen Objekten beliefern will.

Mit dem aufkommenden Einsatz der EDV Anfang der siebziger Jahre entstand auf Seiten der Grossisten und Verlage der Wunsch, automatisierte Verfahren zur Bezugsregulierung auf breiter Front einzusetzen. Die Grossisten gründeten den Arbeitskreis MBR (Marktorientierte Bezugsregulierung) des Grossoverbandes und die Verlage die Projektgruppe MBR mit dem Ziel, eine Vereinheitlichung der unterschiedlichen Verfahren der Bezugsregulierung zu erreichen.

Neben den MBR-Verfahren, die in erster Linie für die Bezugsregulierung von Titeln mit größerer Auflage gedacht waren, entstand eine reduziertere Version für mittel- und kleinauflagige Titel, das BKO-Verfahren (Bezugsregulierung für klein- und mittelauftragige Objekte).²⁹

2.3.1 MBR - Marktorientierte Bezugsregulierung

Die MBR ist ein Verfahren, das die Grossisten zur bedarfsgerechten Verteilung von Zeitungen und Zeitschriften auf die Einzelhändler einsetzen. Der Broschüre „Marktorientierte Bezugsregulierung MBR“, herausgegeben vom Verband Deutscher Zeitschriftenverleger e. V., kann man folgende Definition entnehmen:

„Unter MBR versteht man die nummernweise Einsteuerung der Einzelhandelsbezüge von periodisch erscheinenden Zeitungen und Zeitschriften nach bestimmten Regeln der EDV durch den Presse-Großhandel.“³⁰

²⁹ VDZ MBR-Broschüre 1981, 1-2.

³⁰ VDZ MBR-Broschüre 1981, 3.

2.3.1.1 Grundüberlegungen zur MBR

Modelltheoretisch basiert das Verfahren der MBR auf einem vereinfachten Lagerhaltungsmodell. Der zukünftige Bedarf eines Einzelhändlers für ein bestimmtes Objekt wird aus den Vergangenheitsdaten bestimmt. Verkaufsbeeinflussende Faktoren, wie Trendentwicklung, Saisonverläufe, Hefteffekte usw. werden in der klassischen MBR nicht berücksichtigt.

Die Anwendung des MBR erfordert verschiedene Voraussetzungen, wie Nummernremission pro Einzelhändler und Objekt, feste Erstverkaufstage und Angebotszeiten sowie bestimmte Anforderungen an die Datenqualität.

Pro Einzelhändler und Titel müssen die gesamte Liefer- oder Bezugsmenge sowie die Remission genau ermittelt und gespeichert werden. Aus der Differenz von Bezugsmenge und Remission errechnet sich der Verkauf pro Einzelhändler und Titel. Die Höhe der Verkäufe stellt die Basis für die zu leistenden monetären Zahlungsströme zwischen Verlag, Grossist und Einzelhändler dar.

Die MBR eignet sich nur für periodisch erscheinende Objekte mit konstanten Angebotszeiträumen und festen Erstverkaufstagen.

Hinsichtlich der Datenqualität muss eine fehlerlose Erfassung und Verarbeitung der Datenbasis, insbesondere von Liefermenge und Remission, gewährleistet sein.³¹

Parallel zur Bezugsregulierung durch die Grossisten, führen die Verlage eine vertriebsorientierte Verkaufsprognose pro Objekt und Ausgabe durch. Bei der Bestimmung der Verlagsprognose ist die Frage nach der marktgerechten Auslieferungsmenge und der erwarteten Verkaufs- bzw. Bezugsmenge zu beantworten. Die Methoden der Prognosen variieren von Verlag zu Verlag. Sie werden in erster Linie „von den unterschiedlichen Unternehmenszielen und der daraus resultierenden Vertriebspolitik bestimmt.“³²

Die Vertriebspolitik ihrerseits hängt unmittelbar von den Zielen im Anzeigengeschäft ab. In diesem Kontext unterscheidet man zwei Objekttypen, anzeigenerlösorientierte Objekte und vertriebserlösorientierte Objekte.

Für vertriebserlösorientierte Objekte besitzt das Anzeigengeschäft eine untergeordnete Rolle. Qualität und Heftumfang werden so gestaltet, dass die Herstellungskosten recht gering ausfallen. Das reine Vertriebsgeschäft (ohne Anzeigengeschäft) führt schon zu einem positiven Deckungsbeitrag.³³

³¹ VDZ MBR-Broschüre 1981, 61-63.

³² VDZ MBR-Broschüre 1981, 8.

³³ Brummund 1985, 147 und VDZ MBR-Broschüre 1981, 9.

Bei den anzeigenerlöorientierten Objekten wird der größte Teil der Einnahmen durch das Anzeigengeschäft erzielt. Redaktionell und qualitativ sind diese Objekte sehr aufwendig gestaltet. Dies führt zu hohen Herstellungskosten. Das reine Vertriebsgeschäft (ohne Anzeigengeschäft) weist in der Regel einen negativen Deckungsbeitrag auf.

Vertriebliches Ziel ist es, die Auflagenhöhe und die Auflagenstruktur so zu steuern, dass die Menge und die Qualität der Leserschaft einen Anzeigengewinn in einer bestimmten Höhe ermöglicht.

Eine Auflagensteigerung wird nur dann durchgeführt, wenn sich das Verhältnis aus auflagenabhängigen Vertriebs- und Anzeigenerlösen gegenüber den Vertriebs- und Anzeigenkosten vergrößern lässt. Die Höhe der zusätzlichen Belieferung wird nur solange betrieben, wie die Grenzerlöse die Grenzkosten noch übersteigen.

Hinsichtlich der Vertriebskosten stehen die Verlage bei anzeigenerlöorientierten Objekten besonders unter Druck, da die Stückkosten pro Zeitschrift gegenüber vertriebserlöorientierten Objekten um ein vielfaches höher sind. Die Remission sollte daher bei guter Ausschöpfung des Marktpotentials so gering wie möglich gehalten werden.³⁴

Schon 1981 wurde vom VDZ in einer Broschüre auf die Bedeutung der Entwicklung von Prognosesystemen der Verlage zur Schätzung der Verkaufsmenge hingewiesen. Parallel dazu sollten unter Berücksichtigung der Ausverkaufspolitik, die Liefermenge, die Remissionsmenge und die damit verbundene Höhe der gesamten Druckauflage geschätzt werden. Als Methode wird allgemein die Zeitreihenanalyse mit den Komponenten Trend, Saison und Zufallseinflüsse vorgeschlagen. Die wichtigsten Zufallseinflüsse sind neben Hefteffekten und Wetter, die vagebundierende Nachfrage der Leser. Für jede Ausgabe eines Objektes ist eine Prognose der oben genannten Variablen erforderlich.

Eine getrennte Prognose für jeden einzelnen Grossisten pro Ausgabe und Objekt wurde dabei nicht in Erwägung gezogen. Vielmehr ging es um die Entwicklung eines Gesamtprognosemodells für ein Objekt über alle Grossisten.

Zwischen Grossisten und Verlagen sollte eine Abstimmung zwischen den durch die Grossisten berechneten marktorientierten Bezugsmengen und den letztendlich durch die Verlage ausgelieferten Bezugsmengen stattfinden. Dabei sind Diskrepanzen und Spannungen aufgrund unterschiedlicher Zahlen und Erwartungen keine Seltenheit.

³⁴ Brummund 1985, 147-148 und VDZ MBR-Broschüre 1981, 8-9.

2.3.1.2 Das MBR-Grundmodell

Das MBR-Grundmodell besteht aus den vier Komponenten: Verkaufsvorhersage, Zuschlagsmenge, Berücksichtigung von Sondereinflüssen und Mengenanpassung.

Zur Berechnung der Verkaufsvorhersage eines Objektes pro Ausgabe und Einzelhändler hat sich das Verfahren der einfachen exponentiellen Glättung durchgesetzt.³⁵

Verkaufsvorhersage mit exponentieller Glättung erster Ordnung:

$$VH_{\text{neu}} = \alpha V_{\text{neu}} + (1 - \alpha) VH_{\text{alt}}$$

α : Glättungskoeffizient

VH_{neu} : erwarteter Verkauf neu

VH_{alt} : erwarteter Verkauf alt

V_{neu} : tatsächlicher Verkauf der letzten ausremittierten Nummer

Neben den aktuell ermittelten Verkäufen gehen die erwarteten alten Verkäufe in die Prognose mit ein. Die Gewichtung zwischen aktuellen und alten Werten hängt von der Wahl des Glättungskoeffizienten α ab, der Werte zwischen 0 und 1 annehmen kann.

Exponentielle Modelle höherer Ordnung als eins haben in der MBR-Praxis keinen Einzug gefunden, da sie angeblich mathematisch zu komplex seien. Ebenfalls unberücksichtigt bleiben Komponenten wie Trend und Saison.

Aufgrund der vagabundierenden Nachfrage und der mangelnden Händlertreue der Kunden ist die Einbeziehung von Zuschlägen oder Verkaufsreserven notwendig, um eine mögliche Nachfrageunterdeckung bei den Einzelhändlern zu vermeiden. Der gesamte Bezug eines Einzelhändlers mit einem bestimmten Objekt ergibt sich somit als Summe aus Verkaufsvorhersage und -reserve.

Zur Bestimmung der Verkaufsreserve existieren diverse Verfahren wie das Wurzelwertverfahren, das Verfahren der Objekt-Zuschlagswerte und das Verfahren der mittleren absoluten Abweichung. Das von den meisten Grossisten verwendete Verfahren ist das Verfahren der mittleren absoluten Abweichungen (MAD).

³⁵ VDZ MBR-Broschüre 1981, 14-20.

Die erwartete MAD wird ebenfalls mit Hilfe der exponentiellen Glättung ermittelt.³⁶

Zuschlagsvorhersage mit exponentieller Glättung erster Ordnung:

$$MAD_{\text{neu}} = \beta |VH - V| + (1 - \beta) MAD_{\text{alt}}$$

β : Glättungskoeffizient

MAD_{neu} : erwartete gewichtete Abweichung neu

MAD_{alt} : erwartete gewichtete Abweichung alt

VH: erwarteter Verkauf

V: tatsächlicher Verkauf

Bei der Vertriebsarbeit treten eine Reihe von Ausnahmefällen auf, die sich in objektspezifische und einzelhandelsspezifische Sonderfälle unterscheiden lassen und die vielfach eine manuelle Korrektur des Bezuges nach sich ziehen.

Einzelhandelsspezifische Sonderfälle:³⁷

- Erstbelieferung einer Angebotsstelle oder Belieferung mit einem neuen Titel.
- Festbezüge in begründeten Ausnahmefällen (z. B. Buchhandlungen, Redaktionen, Behörden etc.).
- Ausreißer aufgrund von fehlerhaften Daten oder atypischer Verkaufsentwicklung eines Einzelhändlers.
- Vorübergehende Geschäftsschließung wegen Urlaub, Umbau etc.
- Bedarfssteigerung bei Umkreishändlern. Umkreishändler sind jene Händler, deren Bedarf durch Schließung eines benachbarten Händlers vermutlich steigen wird.

³⁶ VDZ MBR-Broschüre 1981, 22-28.

³⁷ VDZ MBR-Broschüre 1981, 29-34.

Objektspezifische Sonderfälle.³⁸

- Treten außergewöhnliche Ereignisse ein, so sollte die Verkaufsvorhersage entsprechend korrigiert werden (z.B. Preisänderungen, Sonderteile, regionale Schwerpunktthemen, Werbeaktionen etc.).
- Für Titel, die starken saisonalen Schwankungen unterworfen sind, sollten diese berücksichtigt werden. Wichtig ist die Unterscheidung zwischen regionalen und überregionalen Saisonschwankungen. Die MBR in der heutigen Form berücksichtigt keine saisonalen Einflüsse.
- Festlegung von Regeln für die weitere Vorgehensweise bei Einzelhändlern, die für ein Objekt keine Verkäufe realisieren konnten (Nullverkäufe), wie zum Beispiel:
 - 1) Ein Einzelhändler hat dreimal hintereinander kein Exemplar eines Titels verkauft, so erfolgt keine weitere Belieferung mit dem Titel.
 - 2) Wenn ein Einzelhändler in einem Angebotszeitraum von fünf aufeinanderfolgenden Ausgaben eines Objektes bei mindestens drei Ausgaben keinen Verkauf realisieren konnte (Nullverkäufe).
 - 3) Wenn der Verkaufsdurchschnitt (VD) in einem bestimmten Zeitraum unter einen festgelegten Schwellenwert fällt.

$$VD = \frac{\sum_{j=1}^t x_j}{t-j}$$

Zum Beispiel kann für einen monatlich erscheinenden Titel die Belieferung des Einzelhändlers eingestellt werden, wenn der VD für die letzten sechs Ausgaben unter einem Wert von 0,4 liegt. Je nach Titel kann der Grossist den betrachteten Zeitraum und den Schwellenwert auswählen.

- Ausverkauf: Vertriebllich ist es von entscheidender Bedeutung, wann der Ausverkauf erfolgte, ob am Ende der Angebotszeit oder schon recht früh nach Angebotsbeginn. Im letzteren Fall ist anzunehmen, dass die Nachfrage größer als das Angebot war. Leider berücksichtigen die MBR-Verfahren nicht den Zeitpunkt des Ausverkaufs. Daher unterstellt man bei Ausverkauf, dass die Nachfrage nicht vollständig abgedeckt wurde.
Analog zu der Handhabung von Einzelhändlern mit Nullverkäufen sind auch hier Entscheidungsregeln denkbar, mit deren Hilfe eine Erhöhung der Belieferungsmenge einzuleiten ist.

Der gesamte Auslieferungsbedarf eines Grossisten für ein bestimmtes Objekt ergibt sich aus der Addition aller Bezüge der Einzelhändler.

Die gesamte Bedarfsmenge, die der Grossist ermittelt hat, weicht vielfach von der Liefermenge des Verlages ab. Da das Dispositionsrecht bei den Verlagen liegt, muss der

³⁸ VDZ MBR-Broschüre 1981, 48-55.

Grossist seine Belieferungspläne korrigieren. Dazu haben sich in der Praxis zwei Verfahren bewährt, das Verfahren der gleitenden Faktoren und das Kombinationsverfahren.

Beim Verfahren der gleitenden Faktoren wird für alle Einzelhändler der ermittelte vorläufige MBR-Bezug mit einem konstanten Faktor gewichtet. Dieser Faktor wird für jedes Grossgebiet aus dem Verhältnis Gesamtliefermenge des Verlages zu Gesamtbedarf des Grossisten laut MBR berechnet.

Beim Kombinationsverfahren werden zwei Methoden miteinander kombiniert. Zum einen, ein konstanter prozentualer Zuschlag (genannt Prozentualverteilung) und zum anderen ein konstanter absoluter Zuschlag (genannt Gleichverteilung) über alle zur Belieferung vorgesehenen Einzelhändler.³⁹

Kombinationsverfahren zur Korrektur der Belieferungsmenge:

$$AB = B_{\text{MBR}} + \vartheta PV + (1 - \vartheta) GV$$

AB: Angepasster Bezug des Einzelhändlers

B_{MBR} : Bezug des Einzelhändlers laut MBR vor der Mengenanpassung

GV: Anteil je Einzelhändler aus der Gleichverteilung

PV: Anteil je Einzelhändler aus der Prozentualverteilung

ϑ : Gewichtungsfaktor ($0 \leq \vartheta \leq 1$)

³⁹ VDZ MBR-Broschüre 1981, 35-40.

2.3.2 BKO - Bezugsregulierung für klein- und mittelauftragige Objekte

Im Gegensatz zur MBR wird die Regulierung mit dem BKO-Verfahren für klein- und mittelauftragige Objekte in größeren zeitlichen Abständen für kumulierte Liefer- und Remissionswerte durchgeführt.⁴⁰

Für den zurückliegenden Zeitraum (Sammelzeitraum) werden die durchschnittlichen Verkäufe pro Ausgabe für jeden belieferten Einzelhändler ermittelt.

Die Verkaufsvorhersagen berechnen sich aus den aktuellen Durchschnittsverkäufen und den alten Verkaufsvorhersagen mittels exponentieller Glättung erster Ordnung.

Ähnlich dem MBR-Verfahren werden die Verkaufsvorhersagen mit einer Zuschlagsmenge versehen. Die Berücksichtigung von Sonderfällen sowie die Mengenanpassung erfolgt analog dem MBR-Verfahren.

2.3.3 Kritische Anmerkungen zu den Verfahren der Bezugsregulierung

Die stärksten Kritiker der MBR findet man in den Reihen der Einzelhändler. Sie wehren sich gegen das Dispositionsrecht der Grossisten. Ihr Hauptargument: Die vorgegebenen Liefermengen seien bei umsatzstarken Titeln zu klein und bei umsatzschwachen Titeln zu groß.

Teile des Einzelhandels fordern die Dispositionsfreiheit des Einzelhandels. Brummund bezeichnet diese Forderung als naiv und von „fachlichem Unverstand“ geprägt. Der Einzelhandel sei niemals in der Lage, die eigene Disposition von ca. 1500 Pressetiteln zu übernehmen. Der administrative Aufwand wäre von keinem Einzelhändler nur annähernd zu bewältigen.

Laut Brummund liegt die Hauptquelle für die teilweise falsche Steuerung durch das MBR beim Einzelhandel selbst. Der größte Teil der Einzelhändler sei nicht in der Lage, die Remittendensendungen und -scheine fehlerfrei zu bearbeiten.⁴¹

Probleme haben die MBR-Verfahren mit der Steuerung von kleinauflagigen Titeln. Als Verfahrensmangel kann man dies aber nicht bezeichnen. Ein Titel mit einem geringen Verkaufsdurchschnitt (VD) pro Einzelhändler ist wesentlich schwieriger zu steuern als ein Titel mit einem hohen Verkaufsdurchschnitt. Bei einem Titel mit einem VD von zum Beispiel 2 Heften pro Verkaufsstelle führt eine Verkaufsänderung von plus minus einem Heft zu wesentlich größeren Schwankungen in der Remission, als bei einem Titel mit einem VD von 20 Heften.

⁴⁰ VDZ MBR-Broschüre 1981, 64-69.

⁴¹ Brummund 1985, 236.

Die wichtigsten Daten, die sich aus dem Einzelheftverkauf ergeben, sind die Remission und die realisierte Verkaufsmenge, berechnet aus der Differenz von Bezug minus Remission.

Beide Daten werden über alle eingeschalteten Verkaufsstellen eines Grossgebietes aggregiert und stellen die Datenbasis für die Verlagsprognose dar. Die Abstimmung zwischen Verlag und Grossist sollte Liefermenge, erwarteten Verkauf und geplante Remission enthalten. Diese Werte wiederum bilden die Grundlage für die Steuerung der MBR.

Die MBR-Verfahren berücksichtigen aber keinerlei verkaufsbeeinflussende Faktoren wie Trendentwicklung, Saisonverläufe, Hefteffekte usw. Aus diesem Grund ist die MBR auch nicht als Substitut der Verkaufsprognose der Verlage denkbar. Vielmehr muss auf beiden Seiten, Verlage und Grossisten, eine Verbesserung der wechselseitigen Abstimmung zwischen MBR und Verkaufsprognose erfolgen und parallel die Weiterentwicklung der Verfahren betrieben werden.

2.3.4 Weiterentwicklung der MBR

Die Nachteile der klassischen MBR wurden im vorherigen Abschnitt schon ausführlich erörtert. Aus Sicht der Verlage liegen die Hauptmankos der klassischen MBR in der Nicht-Berücksichtigung von Trend- und Saisoneinflüssen und in der mangelnden Prognosefähigkeit.

In Anbetracht dieser Nachteile wird von verschiedenen Seiten an der Verbesserung der MBR gearbeitet. Bei allen Ansätzen spielen Verfahren der Zeitreihenanalyse eine entscheidende Rolle. Nur so lassen sich mögliche Einflussfaktoren wie Saison, Trend, Werbung, Feiertage, Schulferien etc. berücksichtigen.

Dabei kommen die unterschiedlichsten statistischen und mathematischen Verfahren zur Anwendung. Neben speziellen Programmen für Tageszeitungen gibt es auch allgemeine Ansätze, die die gesamte Zeitungs- und Zeitschriftenpalette umfassen. In einem Artikel von Udo Steinmetz werden vier Verfahren vorgestellt.⁴² Das erste Verfahren ist ein Tageszeitungs-Regulierungsprogramm, welches Trend- und Saisonkomponenten berücksichtigt. Ein weiteres Verfahren wurde vom Axel Springer Verlag speziell zur Regulierung der Tageszeitung „Bild“ entwickelt. Die systematischen Vergangenheitsstrukturen werden dabei mit Hilfe neuronaler Netze aufgedeckt und zur Verkaufsprognose verwandt.

⁴² Steinmetz 1997.

Ein weiterer Ansatz wurde von Dillmann, der Vertriebsabteilung des Bauer Verlages und dem Grossisten Probst Wuppertal entwickelt und zur Zeit erprobt. Dieses Verfahren basiert auf der klassischen MBR-Methode und verwendet Verlagsprognose und Richtremission getrennt für die Berechnung der Verkaufsvorhersage und der Reservemenge. Dabei bedient man sich einer ex post Simulation zur Berechnung des Reserverisikos mit Hilfe Bayes'scher Wahrscheinlichkeitsmodelle.

Ein weiteres Bezugsregulierungsverfahren wird zur Zeit von IBM entwickelt. Wobei es bisher nur zu Zwecken der Verlagsprognose verwendet werden kann. Die Prognose erfolgt mit Hilfe von Markov-Prozessen.

Neben diesen Verfahren, die mehr oder weniger von einzelnen Verlagen oder Grossisten entwickelt wurden, beschäftigten sich die MBR-Kommission des Presse-Grossos und die MBR-Kommission des Verbandes der Zeitschriften-Verleger mit der Problematik der Optimierung des Bezugsregulierungssystems und der Verkaufsprognose. Jeder Verband hat zur Zeit eine eigene Testversion eingeführt. Die beiden Verfahren werden hinsichtlich Prognosequalität, entgangener Verkauf, Remissionsquote, Ausverkaufsquote und Marktausschöpfungsgrad miteinander verglichen.

Ziel dieser ganzen Anstrengung ist die weitere Optimierung der Marktversorgung der Leser mit Zeitungen und Zeitschriften, unter der Nebenbedingung, dass die Grenzkosten die Grenzerlöse nicht übersteigen.

2.4 Ausgangssituation und Problemstellung

In den letzten Jahren ist das bestehende Grosssystem von Seiten der Verlage und des Einzelhandels immer mehr unter Druck geraten.

Durch die zunehmende Konzentration im Einzelhandel hat sich dessen Marktmacht gegenüber den Grossisten deutlich geändert. Der Einzelhandel verlangt besseren Service von den Grossisten und eine deutlichere Konzentration auf die rentablen Titel.

Parallel zur Konzentrationsentwicklung im Einzelhandel stagnierte in den letzten Jahren der Umsatz von Presseerzeugnissen über die Vertriebschiene Presse-Grosso. Trotz verstärkter Anstrengungen durch die Grossisten, zum Beispiel durch Steigerung der Anzahl von Verkaufsstellen, durch Aufbau eines Fachhandelskonzeptes mit zum Teil einheitlichen Marktauftritt und Aufbau eines Kundenservices, konnten keine Umsatzsteigerungen erzielt werden. Im Gegenteil, einige Grossisten hatten sogar deutliche Umsatzrückgänge zu verzeichnen.

Auch die Verlage und da besonders die Großverlage setzen ihre Marktmacht gegenüber den Grossisten immer stärker ein, indem sie zum Beispiel bei vielen ihrer Titel die Grossisten zur Abnahme deutlich größerer Bezugsmengen verpflichten, durch Preissenkungen die Handelsspannen für den Grossisten deutlich zurückfahren oder sich auf andere Absatzkanäle, wie Abonnement, Sonderverkäufe, Lesezirkel, Bordexemplare usw. konzentrieren. Das latent vorhandene Spannungsfeld zwischen den Interessen von Einzelhändlern, Grossisten und Verlagen hat zur deutlichen Verschärfung in den Konflikten der Marktteilnehmer im Pressevertrieb geführt.

Ein erster Schritt zur Reduzierung des Konfliktpotentials könnte durch die Verlage erreicht werden.

Bei der Wahl ihrer Mittel sollten sich die Verlage weniger von ihrem formalen Recht (wie Dispositionsrecht) leiten lassen, als vielmehr vom partnerschaftlichen Miteinander. Eine wichtige Maßnahme wäre die Förderung der Transparenz in der Steuerung der geplanten mittelfristigen Bezugsmenge.

Basis für eine Steuerung sollte die getrennte Prognose der Verkäufe für jeden einzelnen Grossisten pro Ausgabe und Titel sein. Denn die inhomogenen Strukturen der einzelnen Grossgebiete und damit verbunden das unterschiedliche Kaufverhalten, finden bei einer Gesamtverkaufsprognose über alle Grossisten keine Berücksichtigung. Jeder Grossist sollte individuell behandelt werden. Je genauer die Kennzahlen sind, die ihm vom Verlag zur Verfügung gestellt werden, desto besser kann er im Sinne des Verlages die Verteilung der Bezugsmenge und den Verkaufsprozess steuern.

Die vorliegende Arbeit beschäftigt sich mit der Entwicklung der oben erwähnten Verlagsmodelle zur individuellen Prognose der Verkäufe eines Titels für jeden einzelnen

Grossisten. Die Prognoseergebnisse dienen den Vertriebsdisponenten in den Verlagen als Hilfsmittel zur Optimierung der Bezugsmengen.

Dabei wird ein mittelfristiger Zeitraum von mehreren Ausgaben betrachtet. Der Disponent ist damit in der Lage, nicht nur die nächste Ausgabe, sondern schon weitere zukünftige Ausgaben zu planen.

3 Beschreibung und Identifikation von Zeitreihen

Im ersten Schritt erfolgt die Bestandsaufnahme der Daten. Es handelt sich dabei um die Verkaufsmeldung der Grossisten an die Verlage. Der größte Teil dieser Daten ist lediglich in schriftlicher Form und nicht auf Datenträger verfügbar, da der Verlag, der seine Daten zum Zwecke der Analyse zur Verfügung stellte, die Verkaufsmeldungen nur auszugsweise langfristig speicherte.

Zum Zeitpunkt des Datenabzuges erhielten die Verlage zwei bis drei Wochen nach Beendigung des Angebotszeitraums aus den Grossgebieten die folgenden Verkaufsmeldungen für jedes ihrer Objekte:

1. Gesamte Liefermenge (Bezug), unterteilt in tatsächlich ausgelieferte Menge und einem Lagerrest
2. Gesamtremission (Verlagsremission), unterteilt in Einzelhändlerremission und Lagerremission
3. Anzahl der eingeschalteten Einzelhändler
4. Ausverkäufe, gegliedert nach der Anzahl der Einzelhändler, die zum erstenmal, zweitenmal, drittenmal oder sogar zum viertenmal hintereinander ausverkauft waren.
5. Nullverkäufe
6. Gesamtbezugsmenge der Einzelhändler mit Nullverkäufen
7. Verkaufsdurchschnitt der belieferten Einzelhändler

Neben den aktuellen Daten enthält der Computerausschnitt auch einige Daten des Vorjahres. Dies sind Verlagsremission des Vorjahres, gesamter Verkauf, gesamte Bezugsmenge und Anteil der Remittenden am gesamten Bezug (in %).

Aus dem oben genannten Satz von Variablen werden die Variablen Verkauf und Bezug herausgegriffen und näher untersucht.

Beispielhaft wird die Vorgehensweise bei der Beschreibung und Identifikation von Zeitreihen an den drei Grossisten SüdWest Vertrieb Friedrichshafen, Carlsen Kiel und Lütkemeyer Münster erörtert.

3.1 Visuelle Beschreibung der Daten

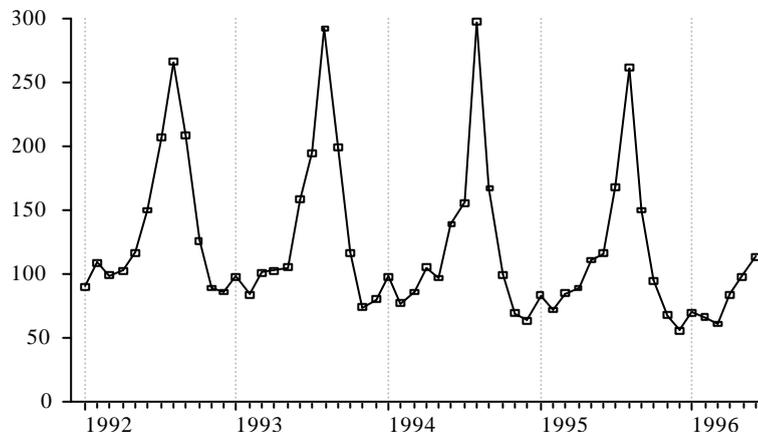
Die graphische Darstellung ermöglicht einen ersten Überblick über die Zeitreihendaten. Trend- und Saisonverläufe lassen sich erkennen. Zusätzlich erhält man Hinweise über den möglichen funktionalen Zusammenhang, über Ausreißer, Strukturbrüche und Wendepunkte.

All diese Hinweise sind für die spätere Modellentwicklung und -implementierung von entscheidender Bedeutung.

Die graphische Darstellung der Zeitreihenwerte bietet aber noch einen weiteren Vorteil. Anhand der Graphiken lässt sich gut erkennen, ob eine Transformation der Daten notwendig ist oder nicht.⁴³ Zeitreihen, die zum Beispiel einen exponentiellen Wachstumsverlauf besitzen, lassen sich durch Logarithmieren in Zeitreihen mit einfacher linearer Trendentwicklung transformieren.

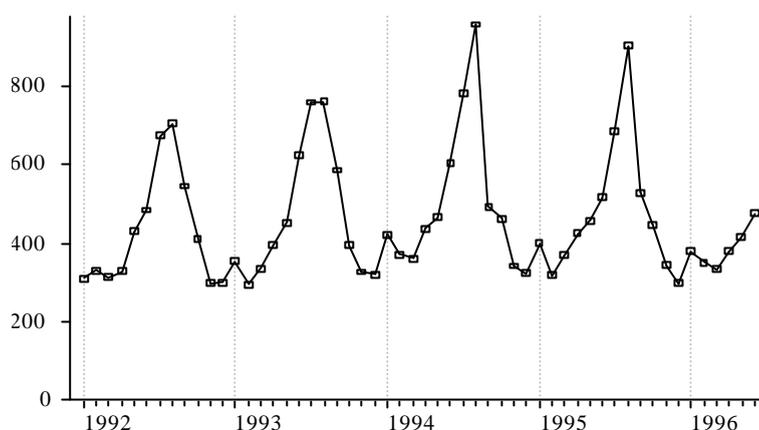
Die folgenden drei Graphiken stellen die absoluten Verkaufszahlen der untersuchten Special Interest Zeitschrift für den Zeitraum 1/92 bis 6/96 für die drei Grossisten SüdWest Vertrieb Friedrichshafen, Carlsen Kiel und Lütkemeyer Münster dar:

Verkauf SüdWest Vertrieb Friedrichshafen

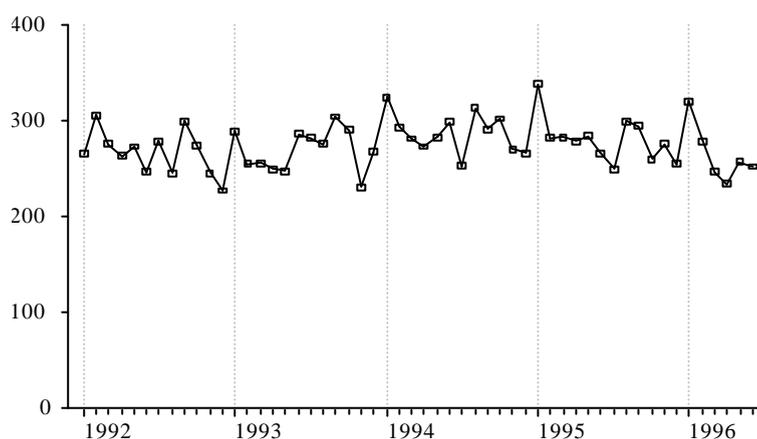


⁴³ Chatfield 1985, 7.

Verkauf Carlsen Kiel



Verkauf Lütkemeyer Münster



(EViews 2.0)

Bei den Grossisten SWV Friedrichshafen und Carlsen Kiel fällt der Saisonverlauf mit den Spitzen in den Sommermonaten Juli und August sofort ins Auge. Er scheint bis auf einzelne Ausnahmen recht stabil zu sein. Beide Grossgebiete liegen in Regionen mit hervorragenden Freizeitmöglichkeiten und profitieren offensichtlich von der Ferienzeit im Sommer.

Zur Beschreibung der stabilen Saisonverläufe bietet sich als einfaches Modell ein additives Saisonmodell an. Eine genauere Prüfung der Modellstruktur erfolgt im Kapitel 5. Wendepunkte, Strukturbrüche und Ausreißer lassen sich nicht in den Graphen der Grossisten SWV Friedrichshafen und Carlsen Kiel erkennen.

Die visuelle Überprüfung der Verkaufsdaten des Grossisten Lütkemeyer Münster zeigt keinen Saisoneinfluss. Faktoren wie Ferienzeit scheinen keinen Einfluss auf die Verkaufszahlen zu haben. Wendepunkte, Strukturbrüche oder Ausreißer sind ebenfalls nicht erkennbar.

Die Trendentwicklung der Verkaufsdaten spielt in allen drei Grossgebieten eine untergeordnete Rolle. Auch auf diesen Aspekt gehen wir zu einem späteren Zeitpunkt noch einmal näher ein.

Neben den Verkaufszahlen wird die gesamte Bezugsmenge (Liefermenge), die der Grossist pro Ausgabe und Titel vom Verlag erhält, betrachtet. Verkauf und gesamte Bezugsmenge stehen in einer Wechselbeziehung zueinander.

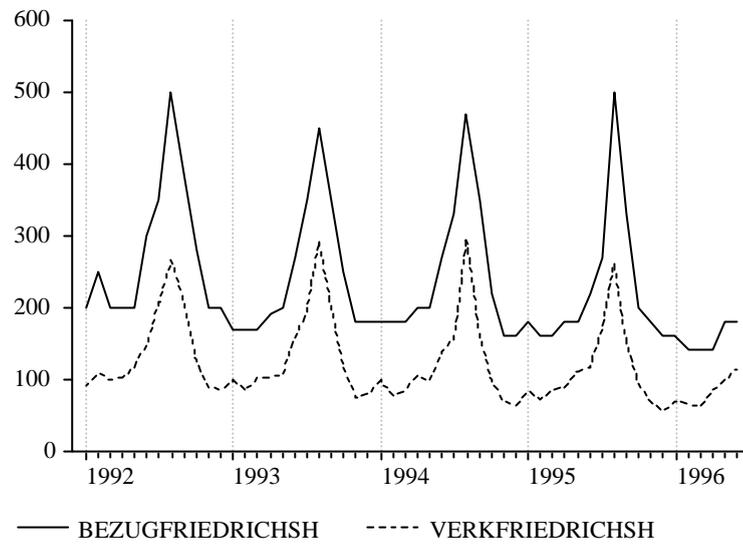
Die Bezugsmenge der Grossisten stellt die jeweilige Obergrenze des Verkaufs dar. Diese Obergrenze lässt sich praktisch nicht erreichen, da die Verteilung der Bezugsmenge auf die Einzelhändler durch die stark vagabundierende Nachfrage niemals optimal zu lösen ist.⁴⁴

Das Verhältnis zwischen Verkauf und Bezug sollte aber einigermaßen stabil sein und keinen starken Schwankungen unterliegen. Die Planung der Verkaufs- und Bezugsmenge sollte simultan mit dem Ziel erfolgen, die Nachfrage flächendeckend zu befriedigen bei gleichzeitiger Stabilisierung der Remission auf einem möglichst niedrigen Niveau. Die Identifizierung der Verkaufsschwankungen, resultierend aus Saison, mehrjährigen zyklischen Schwankungen oder Einzelereignissen stellen dabei eine notwendige Voraussetzung dar.⁴⁵

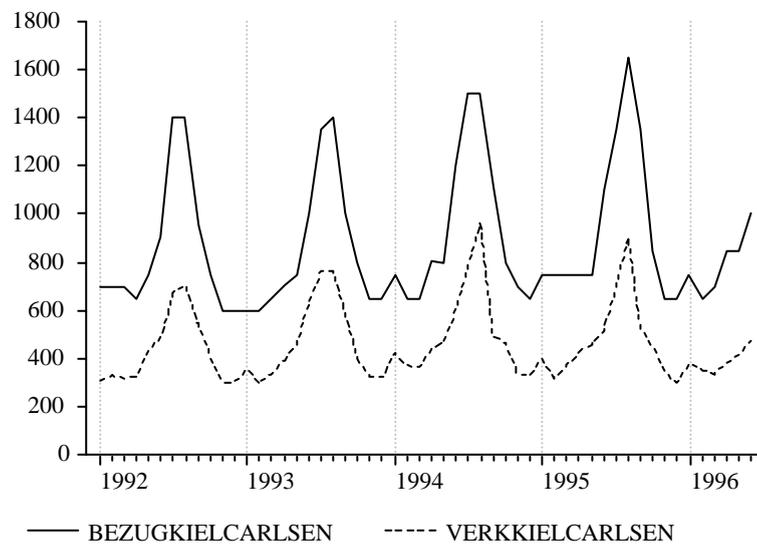
⁴⁴ Brummund 1985, 135-136.

⁴⁵ VDZ, BDZV und Presse-Grosso 1993, 14-15.

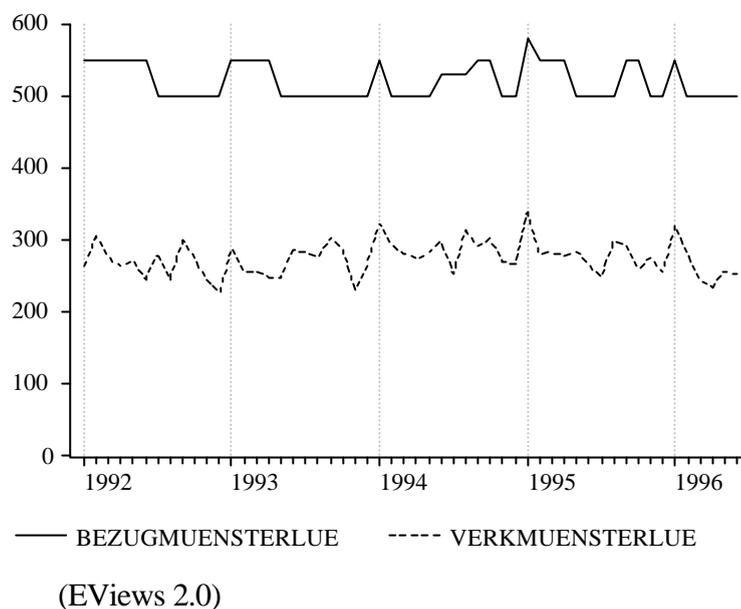
Bezug und Verkauf SüdWest Friedrichshafen



Bezug und Verkauf Carlsen Kiel



Bezug und Verkauf Lütkemeyer Münster



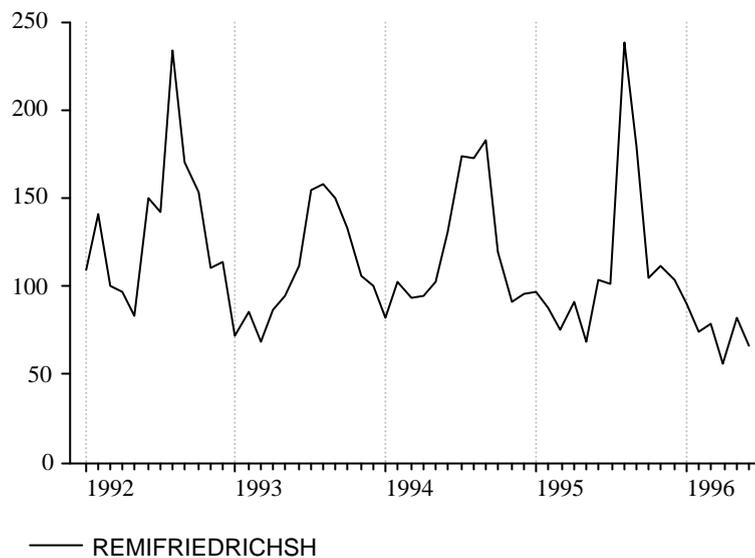
In den Grossgebieten Carlsen Kiel und SWV Friedrichshafen, in denen ein systematischer Verlauf der Daten erkennbar ist, ist die Abstimmung zwischen Bezugs- und Verkaufsmenge recht gut ausgefallen. Der Korrelationskoeffizient r nach Bravais-Pearson⁴⁶ liegt für beide Grossisten nahe bei 1. Für Kiel beträgt $r = 0,931$ und für Friedrichshafen $r = 0,964$.

Anders sieht es beim Grossisten Lütkemeyer Münster aus. Hier lassen sich kaum systematische Strukturen zwischen Verkaufsdaten und Bezugsmenge erkennen. Leichte Veränderungen der Bezugsmenge scheinen keine erkennbaren Auswirkungen auf die Verkaufszahlen zu haben. Mit einem Wert von $r = 0,331$ fällt die Korrelation zwischen Bezug und Verkauf recht gering aus.

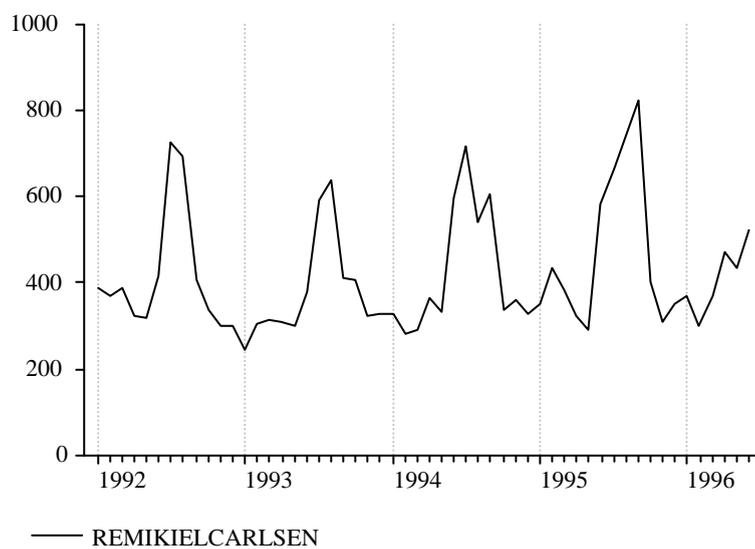
Eine weitere wichtige Größe, die als Maßstab für die Qualität der Verkaufssteuerung verwendet wird, ist die Remission. Sie ist als Differenz zwischen Bezugs- und Verkaufsmenge definiert. Für die drei Grossisten werden die Remissionswerte graphisch aufbereitet.

⁴⁶ Bamberg/Baur 1998, 36-38.

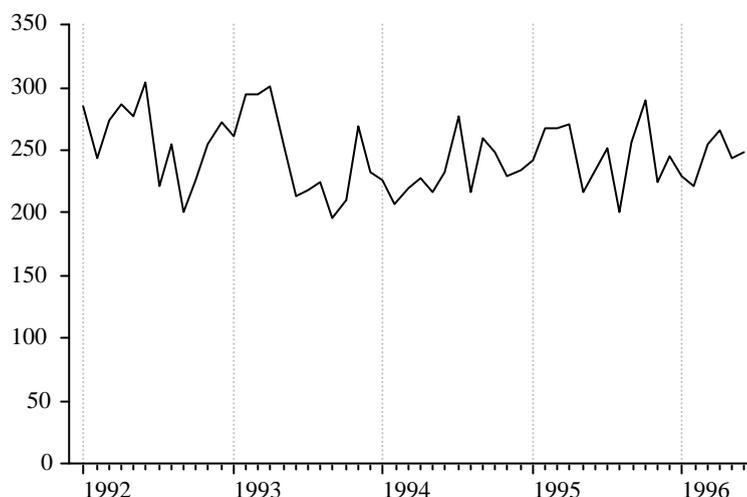
Remission SüdWest Friedrichshafen



Remission Carlsen Kiel



Remission Lütkemeyer Münster



— REMIMUENSTERLUE

(EViews 2.0)

Die graphischen Darstellungen der absoluten Remissionswerte liefern keine zusätzlichen Erkenntnisse. Die Saisonverläufe für die Grossisten Carlsen und SWV finden sich auch bei den Darstellungen der Remissionswerte wieder. Der Verlauf der Remissionskurve des Grossisten Lütkemeyer liefert hingegen keinerlei Erkenntnisse über mögliche systematische Strukturen in den Daten.

Um unabhängig vom Niveau der absoluten Remissions- und Bezugswerten zu werden, bietet sich die Berechnung der Remissionsquote an. Die Remissionsquote ist definiert als das Verhältnis aus Remission zu Bezug. Dieses Verhältnis kann in Anteilswerten oder Prozentwerten angegeben werden. Ziel des Vertriebes ist es, dieses Verhältnis einigermaßen stabil zu halten. Dabei geht man von dem funktionalen Zusammenhang aus, dass bei steigenden Verkäufen und gleichbleibender Einzelhändler-Einschaltquote die Remissionsquote leicht sinkt.

Grosso und Verlage haben dazu die Tabelle der Remissions-Richtwerte aufgestellt, die den Zusammenhang zwischen Verkaufsdurchschnitt pro Einzelhändler und durchschnittlicher Remissionsquote darstellt.

Tabelle der Remissions-Richtwerte:⁴⁷

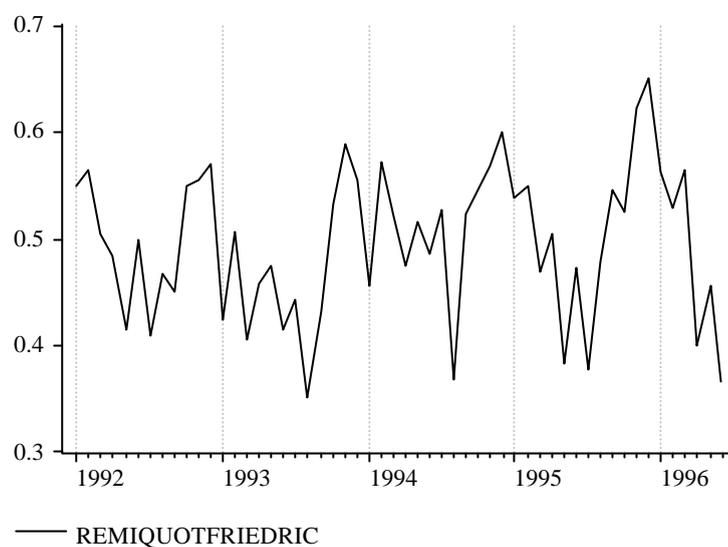
Verkaufsdurchschnitt *	Remissionsquote in %
1,0	50
1,5	46
2,0	42
2,5	39
3,0	37
3,5	35
4,0	33
4,5	31
5,0	29
6,0	27
7,0	25
9,0	24
10,0	23
12,5	22
15,0	21
20,0	20

(Die Tabelle gilt nur für EH-regulierte Titel)

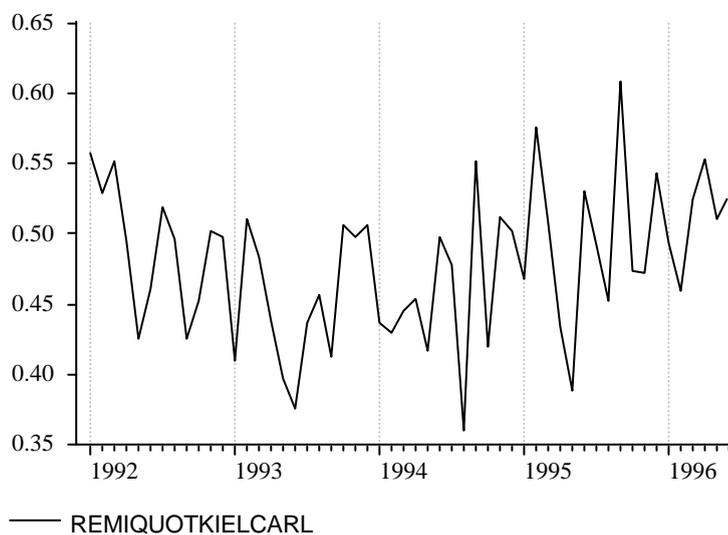
* Der Verkaufsdurchschnitt (VD) errechnet sich gebietsindividuell aus dem Gesamtverkauf eines Titels dividiert durch die Anzahl der belieferten EH.

⁴⁷ VDZ, BDZV und Presse-Grosso 1993, 27 ff.

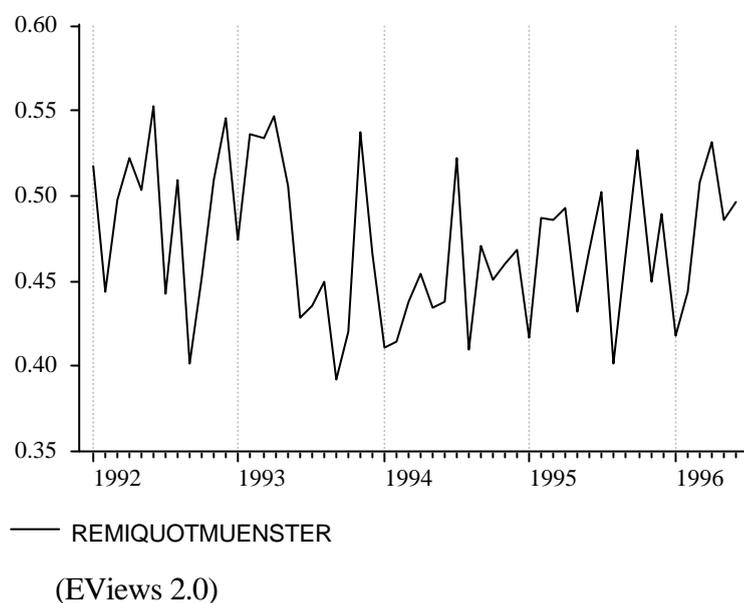
Remissionsquote SüdWest Friedrichshafen



Remissionsquote Carlsen Kiel



Remissionsquote Lütkemeyer Münster



Bei allen drei Grossisten ist das Verhältnis Remission / Bezug recht instabil. Die Höhe der Remissionsquoten scheint unabhängig von der verkauften Menge starken Schwankungen unterworfen zu sein. Der Verdacht liegt nahe, dass überhöhte Bezüge in den Markt gebracht wurden, die jedoch nur zu einem geringen Anstieg der verkauften Menge im Grossgebiet geführt haben.

Die Gründe könnten in der zu groben Vorhersage der Bezugs- und Verkaufsmengen liegen oder in den zufälligen Nachfrageschwankungen zu suchen sein.

Resümee der visuellen Beschreibung:

1. Sind systematische Einflüsse in den Graphiken erkennbar, so handelt es sich um saisonale Trends, Ausreißer, Strukturbrüche usw. lassen sich nicht erkennen.
2. Die Schwankungen der absoluten Remissionszahlen decken sich nur teilweise mit den Verkaufsschwankungen.
3. Die Remissionsquote (Remission / Bezug) unterliegt sehr starken Schwankungen, die keine Systematik erkennen lassen.

3.2 Beschreibung stationärer Prozesse

Nach der graphischen Darstellung der Zeitreihen erfolgt die Beschreibung derselben durch geeignete Maßzahlen. Zur Berechnung der Momente einer Zeitreihe, aber auch für die Anwendung der meisten Methoden der Zeitreihenanalyse ist eine stationäre Reihe erforderlich. Ausgehend von der visuellen Betrachtung bedeutet stationär, dass keine regelmäßigen (systematischen) Strukturen zu erkennen sind.⁴⁸

Eine knappe und sehr schöne verbale Erläuterung der Stationarität findet man bei Chatfield.⁴⁹

„Broadly speaking a time series is said to be stationary if there is no systematic change in mean (no trend), if there is no systematic change in variance, and if strictly periodic variations have been removed.“

Eine vielfach angewandte Methode zur Erzielung der Stationarität stellt die Bereinigung der beobachteten Zeitreihe um die vorhandenen systematischen Teile, wie Trend, Zyklus und/oder Saison dar. Recht einfach gestaltet sich die Beschreibung der Zeitreihe, wenn die nach der Bereinigung übrig gebliebene irreguläre Komponente den Bedingungen eines White-Noise-Prozesses genügt. Auf Seite 44 findet man die Definition eines White-Noise-Prozesses.

Zum Verständnis der Stationarität einer Zeitreihe ist die theoretische Betrachtung von stochastischen Prozessen von großer Bedeutung. Neben den deterministischen Zeitreihenmodellen, bei denen lediglich der Störterm als stochastischer Prozess betrachtet wird, spielt die Klasse der Zeitreihenmodelle, die sich komplett aus stochastischen Prozessen zusammensetzen, eine wichtige Rolle.

Box und Jenkins stellen in ihrem Klassiker „Time Series Analysis“ heraus, dass es in der Zeitreihenanalyse kaum möglich ist, ein zeitabhängiges Phänomen exakt mit einem deterministischen Modell zu beschreiben und genaue Kalkulationen für die Zukunft zu erhalten. Als ein Beispiel nennen Box und Jenkins die monatlichen Verkaufszahlen einer Zeitschrift. Unbekannte Faktoren treten in den meisten zeitabhängigen Phänomenen auf. Modelle, die diese Unsicherheiten berücksichtigen, nennt man stochastische Modelle.⁵⁰

⁴⁸ Schlittgen/Streitberg 1989, 3.

⁴⁹ Chatfield 1985, 14.

⁵⁰ Box/Jenkins 1970, 7.

Ein stochastischer Prozess in der Zeit unterliegt den Axiomen und Regeln der Wahrscheinlichkeitsrechnung. Wie alle Zufallsvorgänge⁵¹, so lassen sich auch die stochastischen Prozesse in der Zeit durch Zufallsvariablen beschreiben. Eine Zufallsvariable ist eine „Abbildung $X: \Omega \rightarrow \mathbf{R}$, die jedem Elementarereignis ω aus Ω genau eine reelle Zahl $x \in \mathbf{R}$ zuordnet“.⁵²

Ein stochastischer Prozess in der Zeit lässt sich als Folge von Zufallsvariablen auffassen, wobei jedem Zeitpunkt t eine Zufallsvariable X_t zugeordnet wird. Bei stochastischen Prozessen in der Zeit sind in der Regel die einzelnen Zufallsvariablen X_t abhängig voneinander. Gerade diese Abhängigkeitsstruktur soll mit geeigneten Modellen ausreichend beschrieben und erklärt werden.⁵³

Bei Vorlage einer konkreten Zeitreihe ist jeder Beobachtungswert x_t als Realisation der entsprechenden Zufallsvariable X_t zu verstehen. Die gesamten ermittelten Verkaufsdaten eines Grossgebietes sind lediglich eine mögliche Realisation des stochastischen Prozesses. Man unterscheidet dabei zwischen stochastischen Prozessen in diskreter oder stetiger Zeit.⁵⁴

Die Realisationen der Verkaufszahlen liegen als diskrete Werte vor und werden auch als solche analysiert. Beim eigentlichen Verkaufsprozess handelt es sich aber um einen stetigen Prozess. Betrachtet man den Angebotszeitraum, so müsste die Verteilung der Verkaufszahlen als stark linkssteil dargestellt werden. Aufgrund langjähriger Erfahrungen des Verlages wird nämlich der Großteil des Verkaufs in den ersten Angebotstagen getätigt.

Die Zeitreihenanalyse beschäftigt sich mit den Eigenschaften des Wahrscheinlichkeitsmodells, das den konkreten Realisationen einer Zeitreihe zugrunde liegt.

Ein stochastischer Prozess lässt sich eindeutig über seine endlich-dimensionale Verteilungsfunktion definieren. Voraussetzung ist nur, dass die Verteilungsfunktion bekannt ist. Dies ist die Kernaussage des Konsistenztheorems von Kolmogorov. In der praktischen Anwendung interessiert man sich aber vielmehr für die Momente des stochastischen Prozesses und da besonders für die Momente erster und zweiter Ordnung.⁵⁵

Die Momente eines stochastischen Prozesses X_t $\{t \in T$; mit T definiert auf \mathbf{Z} } in diskreter Zeit sind Erwartungswert $\mu(t)$, Varianz $\sigma(t)$, Autokovarianz $\gamma(t)$. Durch Normierung lässt sich aus der Autokovarianz die Autokorrelation $\rho(t)$ bestimmen.

⁵¹ Kraft/Landes 1996, 41.

⁵² Kraft/Landes 1996, 47.

⁵³ Schlittgen/Streitberg 1989, 76.

⁵⁴ Chatfield 1985, 33.

⁵⁵ Schlittgen/Streitberg 1989, 74.

$$\mu(t) = E(X_t) \quad ; \quad \sigma^2(t) = \text{Var}(X_t) = \gamma(t, t)$$

$$\gamma(s, t) = \text{Cov}(X_s, X_t) = E[(X_s - \mu(s)][X_t - \mu(t)])$$

$$\rho(s, t) = \frac{\text{Cov}(X_s, X_t)}{\sqrt{\sigma^2(s) \sigma^2(t)}} \quad (\text{mit } s, t \in T)$$

Die aufgeführten ersten und zweiten Momente sind Grundgesamtheitsparameter. Im Rahmen der beschreibenden Statistik beschäftigen wir uns mit den Momenten der Zufallsstichprobe.

3.2.1 Beschreibende Momente von empirischen Zeitreihen

$$\text{Arithmetisches Mittel: } \bar{x} = \frac{1}{N} \sum_{t=1}^N x_t$$

$$\text{Varianz: } s^2 = \frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})^2$$

$$\text{Autokovarianzkoeffizient: } c_k = \frac{1}{N} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x}) \quad \text{für das lag } k$$

(mit $k = 0, 1, 2, \dots, N-1$)

$$\text{Autokorrelationskoeffizient: } r_k = \frac{\sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^N (x_t - \bar{x})^2} \quad \text{für das lag } k$$

$$\text{es gilt: } r_k = c_k / c_0$$

Höhere Momente eines stochastischen Prozesses können zwar gebildet werden, haben aber kaum praktische Bedeutung.⁵⁶

Die aufgeführten empirischen Momente sollten nicht unkritisch als Schätzer für die Grundgesamtheitsparameter einer Zeitreihe verwendet werden. Zum Beispiel ist der Schätzer c_k für den Autokovarianzkoeffizienten nur asymptotisch erwartungstreu. Eine Methode bei endlichen Stichproben die Verzerrung zu reduzieren, besteht zum Beispiel

⁵⁶ Chatfield 1985, 34-35.

in der Verwendung der „Jackknife“ Methode. Der Bias reduziert sich dabei von $1/N$ auf $1/N^2$. Die Zeitreihe wird dazu in zwei Teile geteilt. Neben der Schätzung c_k wird für jeden Teil eine separate Schätzung c_{k1} und c_{k2} durchgeführt. Die Verknüpfung erfolgt folgendermaßen: $\tilde{c}_k = 2 c_k - \frac{1}{2}(c_{k1} + c_{k2})$.

Die „Jackknife“ Methode lässt sich auch auf die Schätzung des Autokorrelationskoeffizient übertragen, dadurch wird ebenfalls eine Reduzierung des Bias erreicht.⁵⁷

3.2.2 Definition stationärer Prozesse

Für das weitere Verständnis, insbesondere der Identifikationstests, ist die genaue Definition eines stationären Prozesses unerlässlich. Zu unterscheiden ist dabei die schwache Stationarität (Stationarität zweiter Ordnung) von der strengen (Stationarität erster Ordnung).

Im vorherigen Teil wurde eine Zeitreihe als Folge von Zufallsvariablen vorgestellt. Jede Zufallsvariable X_t kann maximal eine einzige Realisierung x_t (mit $t = 1, 2, \dots, N$) aufweisen. Um eine solche Folge von N Zufallsvariablen allein mit Erwartungswerten und Varianzen zu beschreiben, müssten $2N$ Grundgesamtheitsparameter geschätzt werden, ein unmögliches Unterfangen. Aus diesem Grund müssen Restriktionen formuliert werden. Bei der Modellbildung können nur solche stochastischen Prozesse verwendet werden, die diese Restriktionen erfüllen.

3.2.2.1 Schwache Stationarität oder Stationarität zweiter Ordnung

Für die schwache Stationarität ist zu fordern, dass die Erwartungswerte und Varianzen im betrachteten Zeitraum konstant sind. Des weiteren dürfen die Kovarianzen nur noch von den Abständen zwischen den Zeitpunkten (vom lag k) abhängen und nicht von den einzelnen Zeitpunkten. „Ein schwach stationärer Prozess wird also, was seine Momente erster und zweiter Ordnung betrifft, das gleiche Verhaltensmuster zeigen, gleichgültig in welchem Zeitintervall wir den Prozeß beobachten.“⁵⁸

⁵⁷ Chatfield 1985, Kap. 4.1.

⁵⁸ Schlittgen/Streitberg 1989, 80.

Definition:

Ein stochastischer Prozess X_t (für $t = 1, 2, 3, \dots, N$) erfüllt die Bedingungen für die schwache Stationarität, wenn er:

1) mittelwertstationär ist: $E[X(t)] = \mathbf{m}$

2) varianzstationär ist: $Var[X(t)] = \mathbf{S}^2$

3) kovarianzstationär ist: $Cov[X(t), X(t+k)] = \gamma(k)$ (mit $k = 1, 2, \dots, N-1$)

(Bemerkung: Ein Prozess der kovarianzstationär ist, muss auch varianzstationär sein.)⁵⁹

3.2.2.2 Strenge Stationarität oder Stationarität erster Ordnung

Für die Definition der strengen Stationarität reicht im allgemeinen die Mittelwert-, Varianz- und Kovarianzstationarität nicht aus. Die Definition der strengen Stationarität erfolgt daher nicht über die Momente, sondern über die gemeinsame Verteilungsfunktion der Folge von Zufallsvariablen.

Definition:

Eine Zeitreihe wird als streng stationär bezeichnet, wenn die Zufallsvariablen $X(t_1), \dots, X(t_N)$, dieselbe gemeinsame Verteilungsfunktion besitzen wie die Zufallsvariablen $X(t_{1+k}), \dots, X(t_{N+k})$ für alle Werte von t_1, \dots, t_N, k . Die Verschiebung des Ursprungspunktes der Zeitreihe hat keinen Effekt auf die gemeinsame Verteilung. Diese Definition gilt für beliebige Stichprobenumfänge N .⁶⁰

Die Struktur von vielen Prozessen lässt sich ausreichend mit den ersten und zweiten Momenten beschreiben. Prozesse, deren Verteilung normalverteilt ist, haben dabei eine besonders nützliche Eigenschaft. Erfüllen die beiden ersten Momente des Prozesses die Definition der weichen Stationarität und ist der Prozess obendrein noch multivariat normalverteilt, so ist damit die Bedingung der strengen Stationarität erfüllt.

Bei nicht normalverteilten Prozessen reichen hingegen μ und $\gamma(k)$ nicht aus, um den Prozess ausreichend zu beschreiben.⁶¹

⁵⁹ Schlittgen/Streitberg 1989, 79.

⁶⁰ Chatfield 1985, 35 und Schlittgen/Streiberg 1989, 83.

⁶¹ Chatfield 1985, 35-37.

3.2.3 Zwei wichtige stochastische Prozesse

Zu Beginn dieses Abschnittes hatten wir schon die Idee des stochastischen Prozesses auf die Zeitreihenanalyse übertragen. Zum weiteren Verständnis ist es hilfreich, den White-Noise-Prozess und den Random-Walk-Prozess kurz vorzustellen.⁶²

1. White-Noise-Prozess (Einfacher Zufallsprozess)

Def.: Ein White-Noise-Prozess X_t liegt vor, wenn die Zufallsvariablen eines diskreten Prozesses in der Zeit voneinander unabhängig und identisch verteilt sind. Aus der Definition ergibt sich, dass die Erwartungswerte und die Varianzen eines White-Noise-Prozesses für alle Zufallsvariablen konstant sind und die Autokorrelationsfunktion (ACF) für alle „lags“ ($k = \pm 1, \pm 2, \pm 3, \dots$) Null ist.

$$\text{Für die ACF gilt: } \rho(k) = \begin{cases} 1 & k = 0 \\ 0 & k = \pm 1, \pm 2, \dots \end{cases}$$

White-Noise-Prozesse (einfache Zufallsprozesse) sind für sich betrachtet eher uninteressant. Interessant werden sie erst als Bestandteil von komplizierteren Prozessen, z.B. von Moving-Average-Prozessen. White-Noise-Prozesse erfüllen die Bedingung der strengen Stationarität, ihre gemeinsame Verteilungsfunktion verändert sich nicht durch Verschiebung auf der Zeitachse.

2. Random-Walk-Prozess

Ein Prozess X_t wird als Random-Walk bezeichnet, wenn gilt: $X_t = X_{t-1} + e_t$

Dabei ist e_t ein diskreter einfacher Zufallsprozess mit Erwartungswert μ und Varianz σ_e^2 . Für $t = 0$ startet der Prozess in der Regel mit dem Wert 0:

$$X_1 = e_1 \text{ und } X_t = \sum_{i=1}^t e_i$$

$$\text{Erwartungswert: } E(X_t) = t \mu \quad \text{Varianz: } \text{Var}(X_t) = t \sigma_e^2$$

Der Random-Walk-Prozess ist somit nicht stationär, da sich der Erwartungswert und die Varianz mit der Zeit verändern. Um einen Random-Walk-Prozess in eine stationäre Form umzuwandeln, bildet man die Differenzen erster Ordnung: $e_t = X_t - X_{t-1}$

⁶² Chatfield 1985, 39-41 und Schlittgen/Streitberg 1989, 71-73.

3.3 Beschreibung und Identifikation der Verkaufsdaten am Beispiel des Grossisten Lütkemeyer Münster

Die graphische Überprüfung der Verkaufszahlen des Grossisten Lütkemeyer lieferte keinerlei Anhaltspunkte für systematische Strukturen wie Trend, Zyklus oder Saison.

Aus dieser Erkenntnis heraus erfolgt eine weitere Identifikation der betrachteten Zeitreihe, die Überprüfung der Stationarität. Sie ist eine der fundamentalen Schritte in der Zeitreihenanalyse. Wie in vielen Bereichen der Statistik, so gibt es auch hier eine Reihe von möglichen Verfahren oder Tests, die je nach Datenlage mehr oder weniger geeignet sind.

Die weiteren zu prüfenden Eigenschaften sind die Normalverteilungsannahme, die Abhängigkeit oder Unabhängigkeit der Zeitreihenwerte voneinander und die Form der Abhängigkeit, linear oder nicht linear.

Die Erkenntnisse, die aus der Identifikation der Zeitreihe gewonnen werden, beeinflussen nachhaltig das weitere Vorgehen innerhalb der Zeitreihenanalyse.⁶³

3.3.1 Überprüfung der Autokorrelation und partiellen Autokorrelation

Die Überprüfung der Autokorrelation und der partiellen Autokorrelation liefert erste wichtige Hinweise über die Struktur der vorliegenden Daten und dem eventuell zugrunde liegenden Prozess. Besonders anschaulich sind dabei die Korrelogrammdarstellungen.

Anhand des Korrelogramms der Autokorrelationsfunktion lässt sich zum Beispiel feststellen, ob die empirische Zeitreihe den Bedingungen eines White-Noise-Prozesses genügt oder ob andere Prozesse wie Moving-Average- oder Autoregressive-Prozesse in Betracht kommen. Zeitreihen, die trendbehaftet sind, weisen zum Beispiel recht hohe positive Autokorrelationswerte auf, die mit zunehmenden lag k nur langsam abnehmen. Derartige Zeitreihen verletzen unter anderem die Bedingung der Mittelwertstationarität.

Bei Zeitreihen, die stark saisonbehaftet sind, finden sich dieselben Frequenzen im Korrelogramm wieder. Die Dominanz der Saison lässt in der Regel keinerlei weitere strukturelle Einflüsse erkennen. Erst nach einer Saisonbereinigung kann das Korrelogramm weitere wichtige Informationen liefern.

⁶³ Cromwell/Labys/Terraza 1994.

Alternierende Zeitreihen lassen sich ebenfalls recht gut mit Hilfe des Korrelogramms erkennen. Das Vorzeichen der Autokorrelationskoeffizienten wechselt dabei von Koeffizient zu Koeffizient.

3.3.1.1 Autokorrelation (AC) und Korrelogramm

Chatfield schlägt folgende vereinfachte empirische Autokorrelationsfunktion (ACF) vor.⁶⁴

Empirischer Autokorrelationskoeffizient für das lag k:	
$r_k = \frac{\sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^N (x_t - \bar{x})^2}$	<p>x_t: t - ter Wert der Zeitreihe mit $t = 1, 2, \dots, N$ \bar{x}: arithmetisches Mittel der beobachteten Zeitreihe k: k - te lag mit $k = 1, 2, \dots, m < N$</p>

Für die praktische Anwendung sollte man auf die Berechnung von r_k Werten mit zu großen lags verzichten. Als Faustregel kann gelten: $k \leq N/4$.

Die Berechnung des Autokorrelationskoeffizienten erfolgt in den Programmen EViews 2.0⁶⁵ und SPSS/PC 6.1.3⁶⁶ mit der angegebenen Berechnungsformel.

Für jedes lag k wird der Wert der Autokorrelationskoeffizienten berechnet und graphisch im Korrelogramm dargestellt.

Das Korrelogramm auf der nächsten Seite enthält die Autokorrelationswerte für die lags k mit $k = 1, \dots, 13$.

⁶⁴ Chatfield 1985, 24.

⁶⁵ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 142.

⁶⁶ Fieger/Toutenburg 1995, 97.

```

Autocorrelations:  VMUENSTE

      Auto- Stand.
Lag  Corr.  Err. -1  -.75  -.5  -.25  0  .25  .5  .75  1  Box-Ljung  Prob.
+-----+-----+
1  ,078  ,132          .  |**  .          ,343  ,558
2  -,062  ,131          .  *|  .          ,566  ,753
3  ,030  ,130          .  |*  .          ,620  ,892
4  ,194  ,129          .  |****. 2,889  ,577
5  ,184  ,127          .  |****. 4,971  ,419
6  -,061  ,126          .  *|  .          5,209  ,517
7  ,158  ,125          .  |***. 6,810  ,449
8  ,157  ,123          .  |***. 8,432  ,392
9  -,094  ,122          .  **|  .          9,025  ,435
10 -,158  ,121          .  ***|  .          10,743  ,378
11 ,094  ,119          .  |**  .          11,367  ,413
12 ,334  ,118          .  |****.** 19,383  ,080
13 -,131  ,116          .  ***|  .          20,653  ,080

Plot Symbols:      Autocorrelations *      Two Standard Error Limits .

Total cases:  54      Computable first lags:  53

Hi-Res Chart # 3: Acf für vmuenste

```

(SPSS/PC 6.1.3)

Die empirische Zeitreihe umfasst 54 Fälle. Je höher die Ordnung des berechneten lags, desto kleiner wird die Anzahl der Summanden im Zähler, der Nenner bleibt davon unberührt. Die erste Spalte enthält die lags von 1 bis 13. Die jeweiligen Autokorrelationskoeffizienten befinden sich in der zweiten Spalte. Die dritte Spalte enthält die zugehörigen Standardfehler. Unterstellt man hinsichtlich der theoretischen Autokorrelationsfunktion, dass ab einem endlichen k alle Autokorrelationskoeffizienten Null sind, so kann approximativ zur Bestimmung der Standardabweichung (Standardfehler) die Formel von Bartlett verwendet werden.⁶⁷

Standardfehler der r_k nach Bartlett:

$$SE(r_k) = \sqrt{\frac{1}{N} \left(1 + 2 \sum_{i=1}^k (r_i)^2 \right)}$$

⁶⁷ Box/Jenkins 1970, 34-36.

Geht man davon aus, dass der zugrunde liegende Prozess die Bedingungen eines White-Noise-Prozesses erfüllt, so vereinfacht sich die Berechnung des Standardfehlers für die r_k . Bei einem White-Noise-Prozess ist die Unabhängigkeit der einzelnen Zeitreihenwerte gegeben, das heißt, dass die Zeitreihe der Beobachtungswerte N rein zufällig verteilt ist.

Standardfehler von r_k nach dem Unabhängigkeitsmodell:

$$SE(r_k) = \sqrt{\frac{1}{N}}$$

Für jeden Autokorrelationskoeffizient r_k enthält das Korrelogramm die kritischen Grenzen zur Überprüfung der Hypothese, dass der Koeffizient signifikant von Null verschieden ist.

Hypothesen: $H_0: r_k = 0$ $H_1: r_k \neq 0$

Für rein zufällige Zeitreihen genügt die Verteilung der Autokorrelationskoeffizienten approximativ der Normalverteilung.

Bei einer vorgegebenen Aussagesicherheit von gut 95% ergeben sich somit die Grenzen des Nicht-Ablehnungsbereichs der H_0 -Hypothese durch $\pm 2 SE(r_k) = \pm 2 \sqrt{\frac{1}{N}}$.⁶⁸

Das Korrelogramm von Lütkemeyer Münster weist lediglich für das lag 12 einen Wert auf, der bei einer Aussagesicherheit von 95% im Ablehnungsbereich der Nullhypothese liegt. Die übrigen Werte liegen alle im Nicht-Ablehnungsbereich der Nullhypothese.

Die signifikante Abweichung für das lag 12 lässt die Vermutung zu, dass die einzelnen monatlichen Ausgaben mit den entsprechenden Ausgaben des nachfolgenden Jahres leicht positiv korrelieren. In diesem Zusammenhang liefert die partielle Autokorrelationsfunktion (PACF) wichtige Erkenntnisse. Sie bereinigt den jeweiligen Autokorrelationskoeffizienten von den Einflüssen niedrigerer lags. Die PACF wird auf der folgenden Seite vorgestellt.

Neben dem Korrelogramm berechnet das Programm SPSS die Werte der Box-Ljung Q-Statistik mit den zugehörigen Wahrscheinlichkeiten für den α -Fehler. Die Box-Ljung Q-Statistik testet die Hypothese, dass keiner der Korrelationskoeffizienten von 1 bis zum lag k von Null verschieden ist. Die Alternativhypothese lautet dementsprechend, dass mindestens ein Koeffizient von Null verschieden ist. Für das lag der Ordnung 13 liegt die Wahrscheinlichkeit für den α -Fehler noch bei 8%. Unterstellt man einen α -Fehler von 5%, so ließe sich die Nullhypothese nicht verwerfen. Man bliebe bei der

⁶⁸ Mills 1990, 65.

Aussage, dass alle Koeffizienten, die kleiner gleich 13 sind, nicht signifikant von Null verschieden sind.

3.3.1.2 Partielle Autokorrelation (PAC)

Die Berechnung der partiellen Autokorrelation ist notwendig, um festzustellen, ob die Autokorrelation der Ordnung k in erster Linie auf das k -te lag zurückzuführen ist oder auf die Autokorrelationen der lags mit niedrigerer Ordnung als k ($i < k$, mit $i = 1, 2, \dots, k-1$).

Der partielle Autokorrelationskoeffizient für das lag k ist definiert als der partielle Regressionskoeffizient einer Autoregression der Ordnung k :

Autoregressionsgleichung:

$$x_t = \beta_{k1} x_{t-1} + \beta_{k2} x_{t-2} + \dots + \beta_{kk} x_{t-k} + e_t$$

β_{ki} : Regressionskoeffizienten mit $i = 1, 2, \dots, k$

e_t : t -ter Störterm

Die Autoregressionskoeffizienten lassen sich nur schätzen, real beobachtbar sind sie nicht. Die nachfolgend dargestellte partielle Autokorrelation enthält die Schätzung der Regressionskoeffizienten der Stichprobe (sample partial autocorrelation). Die Schätzung der Koeffizienten $\hat{\beta}_{kj}$ erfolgt rekursiv mit folgender Gleichung:

Partielle Autokorrelation der Stichprobe:

$$\hat{\beta}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \hat{\beta}_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\beta}_{k-1,j} r_j}$$

r_j : Autokorrelationskoeffizienten mit $j = 1, 2, \dots, k-1$

$\hat{\beta}$: Partielle Autokorrelationskoeffizienten

Unter der Annahme, dass die betrachtete Zeitreihe einem White-Noise-Prozess genügt, lässt sich die Varianz der partiellen Autokorrelationskoeffizienten durch folgende Approximation berechnen: $V(\hat{\beta}_{kk}) = \frac{1}{N}$.

Die Nullhypothese, dass die einzelnen partiellen Autokorrelationskoeffizienten Null betragen, besitzt bei einer Aussagesicherheit von 95% einen Nicht-Ablehnungsbereich von näherungsweise $\pm 2/\sqrt{N}$. Dabei wird unterstellt, dass die Verteilung der Zeitreihenwerte approximativ normalverteilt ist.⁶⁹

Partial Autocorrelations: VMUENSTE											
Lag	Pr-Aut-Corr.	Stand. Err.	-1	-.75	-.5	-.25	0	.25	.5	.75	1
1	,078	,136					.	**	.		
2	-,068	,136				.	*	.			
3	,041	,136				.	.	*	.		
4	,186	,136				.	.	.	****	.	
5	,165	,136				.	.	.	***	.	
6	-,066	,136				.	*	.	.		
7	,188	,136				.	.	.	****	.	
8	,094	,136				.	.	.	**	.	
9	-,166	,136				.	.	.	***	.	
10	-,162	,136				.	.	.	***	.	
11	,074	,136				*	.
12	,244	,136				*****	.
13	-,176	,136				****	.

Plot Symbols: Autocorrelations * Two Standard Error Limits .

Total cases: 54 Computable first lags: 53

(SPSS/PC 6.1.3)

Die Korrelogramme der Autokorrelationsfunktion und der partiellen Autokorrelationsfunktion weisen kaum Unterschiede auf. Das bedeutet, dass die einzelnen Korrelationen auf das jeweilige k-te lag zurückzuführen sind und nicht auf lags kleinerer Ordnung.

Für das lag 12 liegt der partielle Autokorrelationskoeffizient knapp im Nicht-Ablehnungsbereich der Nullhypothese.

Beide Korrelogramme sowie die Werte der Box-Ljung Q-Statistik lassen den Schluss zu, dass die Verkaufsdaten des Grossisten Lütkemeyer Münster einen geringen saisonalen Effekt aufweisen. Ansonsten unterscheiden sich die Verkaufsdaten kaum von einem Zufallsprozess und erfüllen aller Wahrscheinlichkeit die Bedingungen der schwachen Stationarität.

Man sollte sich aber nicht nur auf die Auswertung der Korrelogramme stützen, sondern zusätzlich geeignete Testverfahren zur Überprüfung der Stationarität betrachten.

⁶⁹ Fieger/Toutenburg 1995, 97 und Mills 1990, 78-81.

3.3.2 Einheitswurzeltests

Einheitswurzeltests (Unit-Root-Tests) spielen in der Zeitreihenanalyse eine sehr wichtige Rolle.⁷⁰

Mit ihnen lässt sich die Stationarität (bzw. der Integrationsgrad) einer Zeitreihe überprüfen. Besonders wichtig ist dieser Aspekt bei der Konstruktion von ARIMA-Modellen und der Kointegrationsanalyse.

Grundlage der Einheitswurzeltests bildet die Theorie der Random-Walk-Prozesse: $X_t = X_{t-1} + e_t$.

Ob tatsächlich ein Random-Walk-Prozess vorliegt, lässt sich mit der folgenden autoregressiven Gleichung überprüfen: $X_t = p X_{t-1} + e_t$

Für $|p| < 1$ handelt es sich beim Prozess X_t um einen stationären Prozess. Beträgt $p = 1$, so liegt ein Random-Walk-Prozess vor. Random-Walk-Prozesse sind nicht stationär, besitzen eine Einheitswurzel und den Integrationsgrad der Ordnung 1 $\{I(1)$ mit $\Delta X_t = X_t - X_{t-1}\}$. Zeitreihen dieses Typs lassen sich durch Bildung der Differenzen erster Ordnung in einen stationären Prozess transformieren.⁷¹

Das Vorhandensein einer Einheitswurzel impliziert, dass die Zeitreihe eine stochastische Trendkomponente enthält. Neben der stochastischen Trendkomponente können auch deterministische Trendkomponenten vorhanden sein. Wenn dies der Fall ist, dann lässt sich das Konzept der Differenzenbildung zur Erreichung der Stationarität des Prozesses X_t nicht anwenden.

Im Kapitel 4 wird das Einheitswurzelkonzept und die damit verbundene Differenzenbildung zur Erreichung der Stationarität noch ausführlich erörtert. Neben der Behandlung von Prozessen höherer Ordnung (höher integriert mit mehr als einer Einheitswurzel), wird auch auf das Problem der Überdifferenzierung eingegangen.

Einheitswurzeltests lassen sich sehr gut zur Überprüfung der Stationarität einer Zeitreihe verwenden. Besitzt die Zeitreihe mindestens eine Einheitswurzel, so kann sie nicht mehr stationär sein. Diese Eigenschaft macht man sich bei der Durchführung des Dickey-Fuller-Tests und des Augmented-Dickey-Fuller-Tests zu nutze.⁷²

⁷⁰ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 185-190.

⁷¹ Granger/Newbold 1986, 8-10.

⁷² Cromwell/Labys/Terraza 1994, 12-13.

3.3.2.1 Dickey-Fuller-Test (DF)

Die Prüfgröße des Dickey-Fuller-Tests baut auf der autoregressiven Gleichung eines Random-Walk-Prozesses auf $\{X_t = p X_{t-1} + e_t\}$. Für den Random-Walk-Prozess wird die Differenz der Ordnung 1 gebildet, dazu wird $p = 1 + \delta$ gesetzt. Die Schätzung des Regressionskoeffizienten δ erfolgt nach der Kleinst-Quadrate-Methode (ordinary least square (OLS)).

Regressionsgleichung (DF) der ersten Differenzen:

$$\Delta X_t = \delta X_{t-1} + e_t \quad \text{oder} \quad X_t = (1 + \delta)X_{t-1} + e_t \quad (\text{mit } \Delta X_t = X_t - X_{t-1})$$

δ : zu schätzender Regressionskoeffizient {Es gilt: $p = 1 + \delta$ }

e_t : Störvariable, unabhängiger u. stochastischer Prozess (White-Noise)

Handelt es sich beim Prozess X_t um einen Random-Walk-Prozess, so weicht der Regressionskoeffizient δ nicht signifikant von Null ab. Das zu testende Hypothesenpaar lautet somit:
 $H_0 : \delta = 0 \quad H_1 : \delta \neq 0$

Zur Durchführung des Tests wird die Verteilung der Prüfgröße benötigt, leider genügt die obige Gleichung keiner gewöhnlichen Student T-Statistik.

Die kritischen Werte wurden von Dickey/Fuller⁷³ sowie MacKinnon⁷⁴ mit Hilfe von Monte-Carlo-Simulationen ermittelt. Die simulierten Werte sind leider nicht verzerrungsfrei.

Die Nullhypothese wird verworfen, wenn der Wert der Student T-Statistik außerhalb der kritischen Grenzen liegt. Dabei ist zu beachten, dass die von Dickey/Fuller berechneten kritischen Grenzen jeweils einen Unschärfbereich besitzen. Realisationen von Prüfgrößen, die in den Unschärfbereich fallen, lassen keine Testentscheidung zu.

Eine Verwerfung der Nullhypothese bedeutet, dass der Prozess keine Einheitswurzel aufweist und somit kein Random-Walk-Prozess vorliegt.

Dabei lässt sich die Alternativhypothese in zwei Fälle unterteilen. Fällt die Realisation der Prüfgröße in den unteren (linken) Ablehnungsbereich der Nullhypothese, so schließt man darauf, dass der Koeffizient $\delta < 0$ ist und somit ein stationärer Prozess vorliegt, der einen Integrationsgrad von Null besitzt.

Fällt hingegen die Realisation der Prüfgröße in den oberen (rechten) Ablehnungsbereich der Nullhypothese, so schließt man darauf, dass der Koeffizient $\delta > 0$ ist und der Prozess ein explosives Verhalten aufweist. Ein solcher Prozess lässt sich durch Differenzenbildung nicht in einen stationären Prozess transformieren.

⁷³ Dickey/Fuller 1979.

⁷⁴ MacKinnon 1990.

Die im Programm EViews berechneten kritischen Grenzen gehen auf die Simulationen von MacKinnon⁷⁵ zurück. EViews gibt nur die kritischen unteren Grenzen ohne Unschärfbereich an, da hier lediglich die Hypothese getestet wird, ob der Prozess X_t stationär ist oder nicht. Die Aussagekraft des Tests hängt entscheidend von der Annahme über den Störterm ϵ_t ab. Die ϵ_t sollen den Bedingungen eines reinen Zufallsprozesses genügen.

Neben der Überprüfung eines Random-Walk-Prozesses lassen sich mit dem Dickey-Fuller-Test auch Random-Walks mit Drift (Bezeichnung in EViews: Intercept) testen $\{\Delta X_t = c + \delta X_{t-1} + \epsilon_t\}$. In der praktischen Anwendung ist es aber unklar, wann man den Dickey-Fuller-Test mit Drift und wann ohne Drift benutzen soll.

Besonders interessant ist die Erweiterung der Regressionsgleichung um eine lineare deterministische Trendkomponente $\{\Delta X_t = c + \beta t + \delta X_{t-1} + \epsilon_t\}$. Mit diesem Ansatz ist es möglich, das Fehlen eines stochastischen Trends ($\delta < 0$) und die Existenz eines deterministischen Trends ($\beta \neq 0$) simultan zu testen. Da die Nullhypothese mehr als einen Parameter enthält, bietet sich zur simultanen Überprüfung der Lagrange-Multiplier-Test an.

Bei beiden Erweiterungen mit Drift und/ohne deterministische Trendkomponente verändert sich die Verteilung der Prüfgröße und somit die kritischen Grenzen des Nicht-Ablehnungsbereichs der Nullhypothese.⁷⁶

3.3.2.2 Augmented-Dickey-Fuller-Test (ADF)

Mit der Erweiterung des Dickey-Fuller-Tests lässt sich eine seiner Schwächen beseitigen. Der Dickey-Fuller-Test kann die vielfach im Störprozess ϵ_t auftretende Autokorrelation nicht erfassen. Dadurch wird die Unabhängigkeitsannahme des Störprozesses verletzt. Die Kleinst-Quadrat-Schätzung führt zu ineffizienten Ergebnissen. Um die Korrelationen höherer Ordnung zwischen den Störgrößen im Zeitverlauf erfassen zu können, wird die Regressionsgleichung im rechten Teil um eine verzögerte abhängige Variable erweitert.

⁷⁵ MacKinnon 1990.

⁷⁶ Cromwell/Labys/Terraza 1994, 14-15, Charemza/Deadman 1993, 130-135 und Dickey/Fuller 1979.

Regressionsgleichung (ADF) der ersten Differenzen:

$$\Delta X_t = \delta X_{t-1} + \sum_{j=1}^k \delta_j \Delta X_{t-j} + e_t$$

δ : Zu schätzender Regressionskoeffizient

δ_j : Zu schätzende Regressionskoeffizienten der verzögerten Differenzen der Ordnung $j = 1, 2, \dots, k$

e_t : Störvariable, unabhängiger u. stochastischer Prozess

ΔX_{t-j} : Verzögerte Differenz der X_t -Werte der Ordnung $j = 1, 2, \dots, k$

Wie zuvor beim Dickey-Fuller-Test, so wird auch beim erweiterten Dickey-Fuller-Test die Hypothese getestet, ob eine Einheitswurzel existiert oder nicht.

Hypothesen: $H_0 : \delta = 0$ $H_1 : \delta \neq 0$

Nicht ganz unproblematisch ist die Bestimmung der Anzahl der lags k . Eine einfache Möglichkeit besteht darin, solange lags höherer Ordnung zuzulassen, bis die Residuen der Regressionsgleichung einem reinen Zufallsprozess genügen. Eine wichtige Entscheidungshilfe liefert neben dem Korrelogramm die Durbin-Watson-Statistik. So lang die Durbin-Watson-Statistik für die Residuen Werte signifikant unter zwei aufweist, sollte der autoregressive Term um ein lag der nächst höheren Ordnung erweitert werden.

Bei der Wahl der lag Länge sollte die Tatsache berücksichtigt werden, dass mit zusätzlicher Aufnahme von lags höherer Ordnung die Aussagekraft (Power) des Tests sinkt.

Die Prozedur der Testentscheidung ist identisch mit derjenigen beim einfachen Dickey-Fuller-Test. Per Simulation werden die kritischen Werte⁷⁷ für Prüfgrößen mit unterschiedlicher lag Länge im autoregressiven Term bestimmt.

Mit Hilfe des Augmented-Dickey-Fuller-Tests lassen sich nicht nur Random-Walk-Prozesse mit Autokorrelation im Störprozess ϵ überprüfen, sondern analog dem einfachen Dickey-Fuller-Test auch Prozesse, die zusätzlich einen Drift und/oder einen linearen deterministischen Trend aufweisen.⁷⁸

⁷⁷ Charemza/Deadman 1993, 319-333.

⁷⁸ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 187-190, Cromwell/Labys/Terraza 1994, 14-15 und Charemza/Deadman 1993, 130-135.

3.3.2.3 Durchführung Augmented-Dickey-Fuller-Test (Lütkemeyer Münster)

Die Verkaufsdaten des Grossisten Lütkemeyer Münster werden mit Hilfe des Augmented-Dickey-Fuller-Tests auf ihre Stationarität überprüft.

In der Prozedur Unit-Root-Test enthält das Programm EViews 2.0 zwei Testtypen, den Augmented-Dickey-Fuller-Test und den Phillips-Peron-Test.

Beide Testverfahren erlauben den Benutzern eine Reihe von wählbaren Einstellungen. Einstellbar ist der Grad der Differenzbildung der zu testenden Zeitreihe, die zugrundeliegende Regressionsgleichung und die Anzahl der lags zur Berücksichtigung der Autokorrelation des Störterms.

1. Grad der Differenzbildung:

Drei Einstellungsmöglichkeiten sind beim Grad der Differenzen der betrachteten Zeitreihe wählbar. Dies sind die ursprüngliche Zeitreihe ohne Differenzen (Level), die Reihe der ersten Differenzen und die Reihe der zweiten Differenzen.

2. Regressionsgleichungssystem:

Auch hier kann aus drei Möglichkeiten gewählt werden. Wählbar ist die einfache Autoregressionsgleichung ohne Intercept und ohne Deterministic Trend. Bei der zweiten Wahlmöglichkeit kommt der Intercept hinzu und bei der dritten Intercept und Deterministic Trend.

3. Lag-Struktur:

Zur Berücksichtigung der Autokorrelation des Fehlerterms lässt sich die lag-Struktur in das Regressionsgleichungssystem einbauen. Ein endliches lag von $j = 0, 1, 2, \dots, k$ findet somit seine Berücksichtigung. Bei einem lag von $k = 0$ reduziert sich der Augmented-Dickey-Fuller-Test auf den einfachen Dickey-Fuller-Test.

Bei der Durchführung des ADF-Tests wird auf die Bildung der ersten und zweiten Differenzen verzichtet, wenn der Test zu dem Ergebnis führt, dass die betrachtete empirische Zeitreihe keine Einheitswurzel besitzt und den Bedingungen eines stationären Prozesses genügt. Dies ist der Fall, wenn die Realisation der Prüfgröße kleiner als der Wert der kritischen unteren Grenze bei gegebenem Signifikanzniveau α ist und die Residuen der ADF-Testgleichung keinerlei systematische Strukturen mehr aufweisen.

Stellt sich hingegen heraus, dass die Realisation der Prüfgröße im Annahmereich der Nullhypothese liegt, so erfüllt die Zeitreihe nicht die Bedingung der Stationarität. Zu prüfen ist nun, ob durch Differenzenbildung erster Ordnung ein stationärer Prozess erzielt werden kann. Der Erfolg der Differenzenbildung lässt sich wiederum mit Hilfe des ADF-Tests überprüfen.

Analog geht man vor, wenn sogar die Differenzenbildung zweiter Ordnung erforderlich wird. Differenzen höherer Ordnung als zwei sind kaum interpretierbar und als Voreinstellung im Programm EViews auch nicht vorgesehen.⁷⁹

Aufgrund der visuellen Ergebnisse enthält die gewählte ADF-Testgleichung des Grossisten Lütkemeyer Münster einen Intercept, aber keine lineare deterministische Trendkomponente. Ein deterministischer Trend war weder bei der graphischen Darstellung der Zeitreihe noch im Korrelogramm der Autokorrelationsfunktion zu erkennen. Beim ersten Durchlauf des ADF-Tests wird auf die verzögerte Differenz der Verkaufswerte

$\delta_j \Delta X_{t-j}$ verzichtet. Stellt sich heraus, dass die Residuen auf den niedrigen lags noch signifikante Autokorrelation aufweisen, so wird der Test unter Berücksichtigung einer verzögerten Differenz von $j = 1$ in der Regressionsgleichung wiederholt. Die ganze Prozedur wird solange erweitert (mit $j = 2, 3 \dots$), bis die Residuen auf den niedrigen lags keine signifikanten Autokorrelationen mehr aufweisen.

Die Überprüfung der Autokorrelation der Residuen erfolgt zum einen mit dem Durbin-Watson-Test und zum anderen mit den Korrelogrammen der ACF und PACF.

ADF-Test Lütkemeyer Münster:

Testgleichung:

$$\Delta X_t = c + \delta X_{t-1} + e_t$$

Random-Walk mit Drift bzw. Intercept, Schreibweise im Programm EViews:

$$\Delta X_t = D(\text{VERKAUF}) \text{ und } \delta = \text{VERKAUF}(-1)$$

Hypothesen:

$H_0 : \delta = 0$ (Die Zeitreihe ist nicht stationär.)

$H_1 : \delta \neq 0$ (Für $\delta < 0$ ist die Zeitreihe stationär.)

Untere Grenze des Nicht-Ablehnungsbereichs der H_0 :

Bei einer Aussagesicherheit von 99% beträgt die kritische untere Grenze -3,557 für den Nicht-Ablehnungsbereich der Nullhypothese.

Prüfgröße und Testentscheidung:

Der Wert der ADF-Prüfgröße beträgt -6,553. Er liegt deutlich im unteren Ablehnungsbereich der Nullhypothese. Damit genügt die Zeitreihe der Stationaritätsbedingung, wenn die Residuen der ADF-Testgleichung keinerlei systematische Strukturen mehr aufweisen.

⁷⁹ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 187-190.

ADF Test Statistic	-6.552880	1% Critical Value*	-3.5572	
		5% Critical Value	-2.9167	
		10% Critical Value	-2.5958	
*MacKinnon critical values for rejection of hypothesis of a unit root.				
Augmented Dickey-Fuller Test Equation				
LS // Dependent Variable is D(VERKMUENSTER)				
Date: 03/28/97 Time: 16:14				
Sample(adjusted): 1992:02 1996:06				
Included observations: 53 after adjusting endpoints				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
VERKAUF(-1)	-0.921210	0.140581	-6.552880	0.0000
C	253.0874	38.80491	6.522046	0.0000
R-squared	0.457102	Mean dependent var	-0.245283	
Adjusted R-squared	0.446457	S.D. dependent var	32.81235	
S.E. of regression	24.41255	Akaike info criterion	6.427200	
Sum squared resid	30394.61	Schwarz criterion	6.501551	
Log likelihood	-243.5245	F-statistic	42.94023	
Durbin-Watson stat	1.920087	Prob(F-statistic)	0.000000	

Der EViews 2.0 Ausdruck enthält eine große Anzahl von statistischen Berechnungsergebnissen. Nur jene Ergebnisse werden ausführlich erörtert, die für die gegebene Fragestellung eine wichtige Rolle spielen.

Mit Hilfe der Kleinst-Quadrate-Methode wurde folgende autoregressive Regressionsgleichung ermittelt: $\Delta X_t = 253,09 - 0,9212 X_{t-1}$

Einzeln getestet, sind beide Koeffizienten hoch signifikant von Null verschieden, selbst bei einem Signifikanzniveau von 0,01%.

Die Residuen der ADF-Testgleichung werden mit Hilfe der Korrelogrammdarstellung und der Box-Ljung Q-Statistik auf mögliche Autokorrelationen überprüft.

Lütkemeyer Münster: ACF und PACF der Residuen des ADF Tests						
Sample: 1992:01 1996:06						
Included observations: 53						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	0.016	0.016	0.0136	0.907
. * .	. * .	2	-0.071	-0.071	0.3016	0.860
. .	. .	3	0.018	0.021	0.3215	0.956
. * .	. * .	4	0.181	0.176	2.2635	0.687
. * .	. * .	5	0.166	0.170	3.9470	0.557
. * .	. * .	6	-0.091	-0.072	4.4556	0.615
. * .	. * .	7	0.144	0.168	5.7648	0.567
. * .	. * .	8	0.162	0.125	7.4718	0.487
. * .	. * .	9	-0.096	-0.147	8.0780	0.526
. * .	. * .	10	-0.171	-0.180	10.071	0.434
. .	. .	11	0.065	0.032	10.367	0.498
. * * *	. * * *	12	0.348	0.270	18.989	0.089
. * .	. * .	13	-0.140	-0.155	20.417	0.085
* * * .	* * * .	14	-0.331	-0.305	28.622	0.012
. .	. * .	15	-0.051	-0.080	28.823	0.017
. .	. * .	16	0.032	-0.061	28.905	0.025
. .	. * .	17	-0.051	-0.060	29.119	0.033
* * .	. * .	18	-0.211	-0.079	32.844	0.017
. * .	. * .	19	0.092	0.115	33.563	0.021
. .	. * .	20	-0.056	-0.121	33.843	0.027
* * .	. * .	21	-0.255	-0.131	39.778	0.008
* * .	. * .	22	-0.235	-0.072	44.972	0.003
. * .	. .	23	0.076	0.035	45.526	0.003
. .	. * .	24	0.056	-0.156	45.837	0.005

(EViews 2.0)

Signifikante Autokorrelationswerte treten für die lags 12 und 14 auf, sie bestätigen sich auch in der Box-Ljung Q-Statistik. Zwischen lag 11 und 12 sinkt die berechnete Wahrscheinlichkeit für den Wert der Box-Ljung Q-Statistik deutlich von 0,498 auf 0,089 ab. Ab lag 14 liegt der Wert deutlich unter einem vorgegebenen α -Fehler von 0,05. Dieser Hinweis auf saisonale Abhängigkeiten wird im Rahmen der Modellbildung im Kapitel 5 aufgegriffen.

Zur Überprüfung der Autokorrelation erster Ordnung weist das Ausgabeprotokoll die Realisation der DW-Statistik aus. Bei einer Aussagesicherheit von 99% betragen die Intervallgrenzen des Nicht-Ablehnungsbereichs der Nullhypothese $[1,427 ; 2,573]^{80}$. Die Realisation von 1,92 liegt eindeutig in diesem Bereich, d. h., die Residuen weisen keine erkennbare Autokorrelation der Ordnung eins auf. Die Anzahl der Regressoren beträgt 2 (einschließlich des konstanten Terms) und der Stichprobenumfang $n = 54 \approx 55$. Ausführlicher wird der Durbin-Watson-Test im Kapitel 4 vorgestellt.

⁸⁰ Johnston 1987, 554-557.

Auf die Durchführung eines ADF-Tests mit verzögerten Differenzen der Beobachtungswerte kann aufgrund der Residuen der DF-Testgleichung verzichtet werden. Die ACF und die PACF enthalten keinerlei Hinweise auf eine verzögerte lag Struktur. Führt man trotzdem einen ADF-Test mit einem verzögerten Koeffizienten von eins durch, so stellt man fest, dass dieser Koeffizient nicht signifikant von Null verschieden ist.

3.3.3 Tests auf Normalverteilung

Die Normalverteilung ist zweifellos die wichtigste Wahrscheinlichkeitsverteilung in der Statistik. Von den vielen Gründen, die für ihre Ausnahmestellung sprechen, sollen daher einige genannt werden:

Die Verteilungen vieler praktischer Anwendungen besitzen näherungsweise die Form der Normalverteilung.

Bei unbekannter Verteilung kann für hinreichend große Stichprobenumfänge approximativ die Normalverteilung unterstellt werden (Zentraler Grenzwertsatz).

Erst durch die Normalverteilung wird die approximative Bestimmung einer Vielzahl anderer Verteilungen möglich.⁸¹

Auch in der Zeitreihenanalyse spielt die Normalverteilung eine wichtige Rolle. Zeitreihen, die die Definition der schwachen Stationarität (mittelwert-, varianz- und kovarianzstationär) und zusätzlich die Annahme der Normalverteiltheit erfüllen, genügen damit den Bedingungen der strengen Stationarität. Die Momente erster und zweiter Ordnung reichen dann aus, um den zugrunde liegenden Prozess exakt zu beschreiben.

Zeitreihen, die die Bedingungen der schwachen Stationarität und der Normalverteilung erfüllen, lassen sich durch lineare Modelle adäquat beschreiben.

Die Residuen eines Zeitreihenmodells sollten nach Möglichkeit stationär, normalverteilt und unabhängig sein. Residuen, die die Normalverteilungshypothese nicht erfüllen, besitzen zum Beispiel Ausreißer oder weisen Probleme wie Heteroskedastie auf.⁸²

Es existieren eine Vielzahl von Tests zur Überprüfung der Normalverteilung. Die wichtigsten werden am praktischen Beispiel vorgestellt und erörtert. Da kein optimaler Test existiert, sollten unterschiedliche Testverfahren auf Überprüfung der Normalverteilung zu denselben Ergebnissen gelangen.

Einen ersten Eindruck darüber, ob die Zeitreihe näherungsweise normalverteilt ist, liefert das Häufigkeitshistogramm. Das Programm EViews verfügt über eine Funktion, die neben dem Histogramm auch die wichtigsten Kenngrößen, wie Skewness (Schiefe), Kurtosis (Wölbung) und Jarque-Bera-Statistik berechnet, die bei einigen Normalverteilungstests von Bedeutung sind.

⁸¹ Bamberg/Baur 1998, 109.

⁸² Franses 1996, 10.

3.3.3.1 Tests auf Schiefe und Wölbung

Diese Tests gehen von der Grundidee aus, dass bei einem normalverteilten Prozess die ungeraden Momente, die eine Ordnung größer als zwei aufweisen, Null sind. Allgemein lautet die Definition des r-ten zentralen Moments:

Definition: r-te zentrale Moment

$$\mu_r = \frac{1}{N} \sum_t^N (x_t - \mu)^r$$

mit $r = 1, 2, 3, \dots, \infty$ und $t = 1, 2, 3, \dots, N$

Mit Hilfe dieser Definition lassen sich die Koeffizienten Skewness (Schiefe) und Kurtosis (Wölbung) bestimmen.⁸³

Definition:

$$1) \text{ Skewness: } \beta_1^{1/2} = \frac{\mu_3}{\mu_2^{3/2}} \qquad 2) \text{ Kurtosis: } \beta_2 = \frac{\mu_4}{\mu_2^2}$$

gilt die NV-Annahme \Rightarrow

$$\beta_1^{1/2} \sim \text{NV}\left(0; \sqrt{(6/N)}\right) \quad \text{und} \quad \beta_2 \sim \text{NV}\left(3; \sqrt{24/N}\right)$$

Normalverteilungstests:

- 1) Hyp.: H_0 : Die Zeitreihe x_t ist NV
 H_1 : Die Zeitreihe x_t ist nicht NV

2) Prüfgrößen: $\vartheta_1 = \frac{\beta_1^{1/2} - 0}{\sqrt{(6/N)}}$ und $\vartheta_2 = \frac{\beta_2 - 3}{\sqrt{(24/N)}}$

- 3) Nicht-Ablehnungsbereiche der H_0 : $[-t_\alpha; +t_\alpha]$

- 4) Testentscheidung: ϑ_1 und $\vartheta_2 \notin [-t_\alpha; +t_\alpha] \Rightarrow H_0$ verwerfen

⁸³ Cromwell/Labys/Terraza 1994, 20-22.

Die kritischen Werte t_{α} stammen aus der Standardnormalverteilung mit dem vorgegebenen Signifikanzniveau α .

Signifikant negative Skewness-Werte deuten darauf hin, dass die Zeitreihe einen ausgeprägten Schweif auf der linken Seite und positive Werte, dass sie einen ausgeprägten Schweif auf der rechten Seite besitzt.

Kurtosis-Werte, die signifikant vom Wert drei abweichen, sind ein Indikator für ausgeprägte Wölbung. Die Ablehnung der Nullhypothese sollte erst dann erfolgen, wenn beide Prüfgrößenwerte im Ablehnungsbereich der Nullhypothese liegen.

3.3.3.2 Jarque-Bera-Test

Dieser Test stellt eine Erweiterung der Normalverteilungstests auf Schiefe und Wölbung dar. Neben den Prüfgrößen Skewness und Kurtosis wird eine dritte Prüfgröße S eingeführt. Die Prüfgröße S setzt sich additiv aus den quadrierten standardisierten Koeffizienten für Skewness und Kurtosis zusammen. Die Prüfgröße S genügt einer Chi-Quadrat-Verteilung mit einem Freiheitsgrad von zwei.

Jarque-Bera-Test:

$$\text{Prüfgröße: } S = (N/6) \beta_1 + (N/24) (\beta_2 - 3)^2 \sim \chi^2 V(\nu = 2)$$

$$\text{Nicht-Ablehnungsbereich der } H_0: [0; \chi_{\text{krit.}}^2 = 5,99]$$

$$\text{Testentscheidung: } S > \chi_{\text{krit.}}^2 \Rightarrow H_0 \text{ verwerfen}$$

Die zu testenden Hypothesen sind identisch mit den Hypothesen der Tests auf Schiefe und Wölbung. Alle drei Prüfgrößen ϑ_1 , ϑ_2 und S werden berechnet. Erst wenn alle drei Prüfgrößen in die jeweiligen Ablehnungsbereiche der Nullhypothese fallen, verwirft man die Annahme der Normalverteilung der Zeitreihenwerte.⁸⁴

⁸⁴ Cromwell/Labys/Terraza 1994, 20-22.

3.3.3.3 Kolmogorov-Smirnov-Test

Getestet wird die Abweichung zwischen der empirischen Verteilung einer Zeitreihe und der unterstellten Grundgesamtheitsverteilung. Der Test lässt sich neben der hier interessierenden Normalverteilung auch auf andere Verteilungen anwenden.

Die kritische Grenze ($d_{\text{krit.}}$) ist abhängig vom Stichprobenumfang N und vom vorgegebenen Signifikanzniveau α . Die Werte für die Testgrenzen findet man zum Beispiel bei Kanji⁸⁵.

Der Kolmogorov-Smirnov-Test führt bei größeren Stichprobenumfängen ($N > 100$) sehr leicht zur Verwerfung der Normalverteilungshypothese. Sehr gute Ergebnisse erzielt man für kleinere Stichproben ($N < 100$).⁸⁶

Kolmogorov-Smirnov-Test: (Goodness of Fit)

Hyp.: H_0 : Die Zeitreihe x_t ist NV

H_1 : Die Zeitreihe x_t ist nicht NV

Prüfgröße: $D = \max_D |F(x) - S_N(x)|$

mit $F(x)$: Verteilungsfunktion der angenommenen Grundgesamtheitsverteilung

$S_N(x)$: Verteilungsfunktion der Stichprobe, berechnet als Treppenfunktion

Nicht-Ablehnungsbereiche der H_0 -Hyp.: $[0; d_{\text{krit.}}]$

Testentscheidung: $D > d_{\text{krit.}} \Rightarrow H_0$ verwerfen

⁸⁵ Kanji 1993, 186.

⁸⁶ Sauerwein/Hönekoop 1992, 304-306 und Kanji 1993, 67.

3.3.3.4 Studentized-Range-Test

Die zuvor betrachteten Testverfahren zur Überprüfung der Normalverteilung der beobachtbaren Zeitreihenwerte reagieren sehr empfindlich auf Ausreißer. Einzelne Ausreißer besitzen in den Realisationen der Prüfgrößen einen deutlichen überproportionalen Effekt. Geringer, als bei den vorherigen Testverfahren, fällt der Ausreißereffekt beim Studentized-Range-Test aus. Ausreißer führen hier nicht so schnell zu einer Verwerfung der Nullhypothese auf Normalverteilung.⁸⁷

Studentized-Range-Test:

Hyp.: H_0 : Die Zeitreihe x_t ist NV

H_1 : Die Zeitreihe x_t ist nicht NV

$$\text{Prüfgröße: } SR = \frac{\max\{x_t\} - \min\{x_t\}}{\sqrt{\frac{1}{N-1} \sum_t (x_t - \mu_x)^2}}$$

Nicht-Ablehnungsbereiche der H_0 : $[0; \tau_{\text{krit.}}]$

Testentscheidung: $SR > \tau_{\text{krit.}} \Rightarrow H_0$ verwerfen

Die Verteilung der Prüfgröße und die kritischen Werte findet man bei Pearson und Hartley⁸⁸ oder bei Kanji.⁸⁹

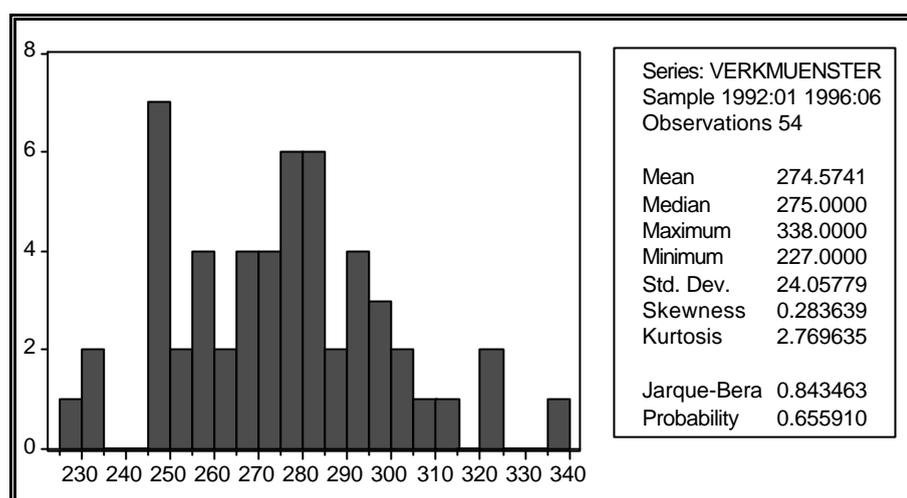
⁸⁷ Cromwell/Labys/Terraza 1994, 23-24.

⁸⁸ Pearson/Hartley 1970.

⁸⁹ Kanji 1993, 183.

3.3.3.5 Durchführung der Normalverteilungstests (Lütkemeyer Münster)

Das Programmpaket EViews 2.0 enthält eine Reihe deskriptiver Maße. Neben der graphischen Darstellung des Häufigkeitshistogramms werden Maße wie Skewness ($\beta_1^{1/2}$), Kurtosis (β_2) und Jarque-Bera-Prüfgröße (S) berechnet. Alle drei werden bei der Durchführung des Jarque-Bera-Tests benötigt.



(EViews 2.0)

Das Histogramm lässt keine sichere Aussage darüber zu, ob die Beobachtungswerte einer Normalverteilung genügen oder nicht.

Bei den folgenden Tests wird durchweg ein Signifikanzniveau von $\alpha = 0,05$ vorgegeben. Wie schon erwähnt, lassen sich mit dem Programm EViews 2.0 die notwendigen Maße zur Durchführung des Jarque-Bera-Tests bestimmen.

Das Programm SPSS/PC 6.1.3 enthält unter der Prozedur nichtparametrische Tests den Kolmogorov-Smirnov-Test. Auf die Berechnung des Studentized-Range-Test wird verzichtet, da die graphische Darstellung der Verkaufsdaten des Grossisten Lütkemeyer keine Hinweise über das Vorhandensein von Ausreißern lieferte.

Jarque-Bera-Test

Hyp.: H_0 : Die Zeitreihe x_t ist NV

H_1 : Die Zeitreihe x_t ist nicht NV

Prüfgrößen: 1) $\vartheta_1 = \frac{\beta_1^{1/2} - 0}{\sqrt{6/N}} = \frac{0,284 - 0}{\sqrt{6/54}} = 0,852$

2) $\vartheta_2 = \frac{\beta_2 - 3}{\sqrt{24/N}} = \frac{2,770 - 3}{\sqrt{24/54}} = -0,345$

3) $S = (N/6) \beta_1 + (N/24) (\beta_2 - 3)^2 = 0,843$

{mit: ϑ_1 und $\vartheta_2 \sim NV(0; 1)$ und $S \sim \chi^2 V(v = 2)$ }

Nicht-Ablehnungsbereiche der H_0 :

zu 1) und zu 2) $[-t_\alpha ; +t_\alpha] = [-1,96 ; +1,96]$

zu 3) $[0 ; \chi_{krit.}^2 = 5,99]$

Testentscheidung:

$\{\vartheta_1 = 0,852 \text{ und } \vartheta_2 = -0,345\} \in [-1,96 ; +1,96]$ und $S = 0,843 \leq 5,99$

$\Rightarrow H_0$ nicht verwerfen

Die Verkaufsdaten des Grossisten Lütkemeyer genügen der NV.

Kolmogorov-Smirnov-Test

Hyp.: H_0 : Die Zeitreihe x_t ist NV

H_1 : Die Zeitreihe x_t ist nicht NV

Kolmogorov - Smirnov Goodness of Fit Test				
VMUENSTE				
Test distribution	-	Normal	Mean:	274,5741
			Standard Deviation:	24,0578
Cases:	54			
Most extreme differences				
Absolute	Positive	Negative	K-S Z	2-Tailed P
,06375	,06375	-,05393	,4685	,9806

(SPSS/PC 6.1.3)

Im Programm SPSS wird die Prüfgröße des Kolmogorov-Smirnov-Tests, gegenüber der auf Seite 63 definierten Formel, mit der Wurzel des Stichprobenumfangs multipliziert. Es gilt somit: $K-S = D \sqrt{N} = 0,6375 \sqrt{54} = 0,4685$.

Die kritische Obergrenze wird im SPSS-Ausdruck nicht ausgewiesen, sondern das maximale Signifikanzniveau, welches gerade noch zu einer Bestätigung von H_0 führt. Es beträgt hier 0,9806. Dieser Wert ist wesentlich größer als das maximal vorgegebene Signifikanzniveau von $\alpha = 0,05$, somit wird H_0 nicht verworfen.

3.3.4 Tests auf Unabhängigkeit

Zeitreihen, die den Bedingungen der Unabhängigkeit genügen, weisen zum Beispiel keinerlei Autokorrelation auf. Der zugrunde liegende Prozess ist somit ein reiner Zufallsprozess, der sich durch Modelle mit deterministischen Komponenten nicht mehr beschreiben lässt.

Trotzdem ist Vorsicht angebracht. Man sollte nämlich die Möglichkeit in Betracht ziehen, dass eine Zeitreihe den Eindruck vermittelt, sie sei rein zufällig, tatsächlich enthält sie aber noch deterministische Komponenten. Dieses Verhalten bezeichnet man als chaotisch.⁹⁰

Unabhängige Zeitreihen sind für die Modellspezifikation eher uninteressant. In der Zeitreihenanalyse ist man ja gerade an den Abhängigkeiten, insbesondere an der Erfassung und der Autokorrelationen der Zeitreihenwerte interessiert. Ziel ist es, die Abhängigkeiten adäquat durch Modelle zu beschreiben, um sich zum einen die Wirkungszusammenhänge zu erklären und zum anderen sinnvolle Vorhersagen zu treffen. Die Residuen des gefundenen Modells sollten hingegen keinerlei Abhängigkeiten mehr aufweisen.

3.3.4.1 Portmanteau-Test

Der Portmanteau-Test ist ein visuelles Testverfahren, das schon bei der Darstellung der Korrelogramme verwendet wurde. Wenn eine Zeitreihe unabhängig verteilt ist, dann sind alle Autokorrelationskoeffizienten $p(k)$ der Zeitreihe für alle lags k nicht signifikant von Null verschieden. Als approximative Formel zur Abschätzung des Standardfehlers schlagen Kendall u. Stuart⁹¹ vor:

$$SE(p(k)) = \frac{1}{\sqrt{N}}$$

⁹⁰ Cromwell/Labys/Terraza 1994, 24.

⁹¹ Vgl. Kendall und Stuart 1979.

3.3.4.2 Box-Ljung- und Box-Pierce-Test

Zur Überprüfung der Unabhängigkeit bieten sich diese beiden Tests an. Die Prüfgrößen sind asymptotisch Chi-Quadrat verteilt mit dem Freiheitsgrad k . Die richtige Wahl von k ist nicht ganz unproblematisch, da sich k nicht eindeutig bestimmen lässt. Die korrekte Identifikation von k hängt von den a priori Kenntnissen über das „Gedächtnis“ des zugrunde liegenden Prozesses ab. Darunter versteht man die Korrelation zwischen der laufenden Periode und den vorherigen Perioden.

Box-Ljung- und Box-Pierce-Test:

Auswahl des lags k zur Schätzung des empirischen Autokorrelationskoeffizienten $p(1)$ bis $p(k)$.

Hyp.: $H_0: p(1) = p(2) = \dots = p(k) = 0$ (kein Abhängigkeit).

H_1 : Mindestens ein $p(k)$ ist signifikant von Null verschieden (Abhängigkeit).

Prüfgrößen:

$$Q_1(k) = N(N+2) \sum_{m=1}^k \frac{1}{N-k} p^2(m) \sim \chi^2 V(v=k) \quad \text{Ljung - Box}$$

$$Q_2(k) = N \sum_{m=1}^k p^2(m) \sim \chi^2 V(v=k) \quad \text{Box - Pierce}$$

Nicht-Ablehnungsbereich von H_0 : $[0; \chi_{\text{krit.}}^2]$

Testentscheidung: $Q_1(k)$ bzw. $Q_2(k) \notin [0; \chi_{\text{krit.}}^2] \Rightarrow H_0$ verwerfen

Diese Tests prüfen die empirische Korrelation unter den Annahmen, dass die Daten normalverteilt und stationär sind. Bei Verletzung einer oder sogar beider Annahmen sinkt die Aussagekraft des Tests sehr stark.⁹²

⁹² Cromwell/Labys/Terraza 1994, 25-27 und Ljung/Box 1978.

3.3.4.3 Turning-Point-Test

Eine Möglichkeit die Unabhängigkeit der Beobachtungswerte zu überprüfen, bietet die Anzahl der Wendepunkte einer Zeitreihe.

Beispielhaft betrachten wir eine Zeitreihe $x_1, x_2, \dots, x_t, \dots, x_N$. Ein Wendepunkt i in der Zeitreihe liegt vor, wenn gilt: $(x_{t-1} < x_t \text{ und } x_t > x_{t+1})$ oder $(x_{t-1} > x_t \text{ und } x_t < x_{t+1})$. Wenn die Werte der Zeitreihe zufällig verteilt sind, dann beträgt die Wahrscheinlichkeit für einen Wendepunkt in der Zeit $2/3$. Der Test führt aber nur zu sinnvollen Ergebnissen, wenn die betrachtete Zeitreihe mehr als 15 Werte umfasst und die Zeitreihe den Bedingungen der Stationarität genügt. Die Prüfgröße ist standardnormalverteilt und berechnet sich aus der Standardisierung der Anzahl von Wendepunkten in der realisierten Zeitreihe.⁹³

Turning-Point-Test:

Hyp.: H_0 : Die Zeitreihe x_t ist unabhängig

H_1 : Die Zeitreihe x_t ist abhängig

Prüfgröße: $Z = |V - E(V)| / \sigma_V \sim NV(0; 1)$

$$\text{mit: } E(V) = \frac{2}{3}(N-2) \text{ und } \sigma_V^2 = (16N-29)/90$$

N: Anzahl der Beobachtungswerte

V: Die Anzahl von Wendepunkten in der realisierten Zeitreihe

$E(V)$: Erwartete Anzahl von Wendepunkten

σ_V : Standardabweichung der erwarteten Anzahl von Wendepunkten

Nicht-Ablehnungsbereich der H_0 -Hyp.: $[0; t_\alpha]$

Testentscheidung: $Z > |t_\alpha| \Rightarrow H_0$ verwerfen

⁹³ Kanji 1993, 104 und Cromwell/Labys/Terraza 1994, 27-28.

3.3.4.4 Runs-Test

Die Unabhängigkeit einer Zeitreihe wird durch Überprüfung der Frequenz verschiedener sich wiederholender Muster getestet. Prozesse mit ähnlichen sich wiederholenden Mustern sind keine Zufallsprozesse und somit nicht unabhängig. Unabhängige Prozesse dürfen keinerlei systematisch sich wiederholende Muster aufweisen.

Jeder Beobachtungswert wird durch sein Vorzeichen ersetzt. Dies erfordert entweder eine Zeitreihe, die zuvor differenziert wurde oder eine Zeitreihe, die durch Subtraktion des Medians transformiert wurde. Die Anzahl der Läufe (Runs) mit positivem bzw. negativem Vorzeichen werden gezählt und in die Prüfgröße eingebaut.⁹⁴

Runs-Test:

Hyp.: H_0 : Die Zeitreihe x_t ist unabhängig

H_1 : Die Zeitreihe x_t ist abhängig

Prüfgröße: $Z = [(R + 0,5) - m] / \sigma_m \sim NV(0; 1)$

Es gilt:

R: Realisierte Anzahl von Läufen im Datensatz

$$m = \frac{1}{N} \left[N(N+1) - \sum_i n_i^2 \right]$$

mit n_i : Anzahl der Vorzeichen $\{i = 1 \text{ (positive)}, 2 \text{ (negative)}, 3 \text{ (Null)}\}$

$$\sigma_m^2 = \frac{\sum_i n_i^2 \left[\sum_i n_i^2 + N(N+1) \right] - 2 N \sum_i n_i^3 - N^3}{N^2(N-1)}$$

Nicht-Ablehnungsbereich der H_0 -Hyp.: $[-t_\alpha; t_\alpha]$

Testentscheidung: $Z \notin [-t_\alpha; t_\alpha] \Rightarrow H_0$ verwerfen

⁹⁴ Kanji 1993, 108-109 und Cromwell/Labys/Terraza 1994, 28-30.

3.3.4.5 Rank-Version of the von Neumann-Ratio-Test

Bei diesem Test wird die Unabhängigkeit der Zeitreihe x_t mit Hilfe der Differenzen erster Ordnung überprüft. Für jeden differenzierten Beobachtungswert wird der Rang bestimmt und daraus die Prüfgröße RVN konstruiert.

Rank-Version of the von Neumann-Ratio-Test:

Hyp.: H_0 : $\Delta^1 x(t)$ ist unabhängig

H_1 : $\Delta^1 x(t)$ ist abhängig

Die $\Delta^1 x(t)$ -Werte werden in aufsteigender Reihenfolge zur neuen Variable $R(i)$ sortiert.

$$\text{Prüfgröße: RVN} = \frac{\sum_i (R_i - R_{i+1})^2}{\sum_i (R_i - \hat{\mu}_r)^2} \quad \text{mit } \hat{\mu}_r = \overline{\Delta^1 x(t)} \text{ (arithmetisches Mittel)}$$

Kritische Grenze τ : Siehe Bartels

Entscheidung: $\text{RVN} > \tau \Rightarrow H_0$. verwerfen

Bartels lieferte eine recht einfache Erklärung, unter welchen Bedingungen der Rank- Version-Test zu besseren Ergebnissen führt als die Runs-Tests. Die Runs-Tests ignorieren völlig die Größe der Beobachtung. Mit Hilfe einer Monte-Carlo-Simulation stellte er fest, dass der Rank-Version of the von Neumann-Ratio-Test bei autoregressiven Prozessen erster Ordnung eine wesentlich größere Mächtigkeit besitzt als der Runs-Test.⁹⁵

⁹⁵ Cromwell/Labys/Terraza 1994, 31-32 und Bartels 1982, 40-46.

3.3.4.6 Durchführung der Unabhängigkeitstests (Lütkemeyer Münster)

Die Ergebnisse des Portmanteau-Tests finden sie im SPSS Korrelogrammausdruck, Seite 47. Bis auf den Wert für $k = 12$ sind alle Korrelationskoeffizienten nicht signifikant von Null verschieden.

Das Korrelogramm auf Seite 47 enthält auch die berechneten Prüfgrößenwerte der Box-Ljung Q-Statistik. Getestet wird dabei die Nullhypothese, dass alle Autokorrelationskoeffizienten von lag 1 bis lag k nicht signifikant von Null verschieden sind.

Der SPSS Ausdruck enthält die Realisationen der Prüfgrößen und die zugehörigen Wahrscheinlichkeiten. Die Wahrscheinlichkeiten geben die Höhe des möglichen maximalen α -Fehlers an. Erst wenn diese Wahrscheinlichkeit unter dem vorgegebenen Signifikanzniveau von $\alpha = 0,05$ fällt, wird die Nullhypothese verworfen. Ab lags der Ordnung $k = 14$ führt der Box-Ljung-Test zu einer Annahme der Alternativhypothese auf Abhängigkeit. Schon für $k = 12$ sinkt die berechnete Wahrscheinlichkeit für die Box-Ljung Q-Statistik von 0,413 ($k = 11$) auf 0,08 ab. Die Vermutung liegt nahe, dass eine leichte saisonale Abhängigkeit vorliegt.

Der Box-Pierce-Test unterscheidet sich vom Box-Ljung-Test lediglich in der Berechnung der Prüfgröße. Auch hier wird ein Signifikanzniveau von $\alpha = 0,05$ verwendet.

lag k	1	2	3	4	5	6	7	8	9	10	11	12	13	14
ACF	0,078	-0,062	0,030	0,194	0,184	-0,061	0,158	0,157	-0,094	-0,158	0,094	0,334	-0,131	-0,335
Box-Pierce	0,329	0,536	0,585	2,617	4,445	4,646	5,994	7,325	7,802	9,151	9,628	15,65	16,57	22,64
krit.Grenze	3,84	5,99	7,81	9,49	11,07	12,59	14,07	15,51	16,92	18,31	19,68	21,03	22,36	23,69

Die berechneten Box-Pierce-Prüfgrößen fallen alle in den Nicht-Ablehnungsbereich der Nullhypothese.

Eine weitere Möglichkeit, die Unabhängigkeit der Beobachtungswerte zu testen, bietet der Turning-Point-Test. Zur Durchführung des Tests benötigt man lediglich die Anzahl der Wendepunkte in der beobachteten Zeitreihe und den Stichprobenumfang.

Turning-Point-Test:

Hyp.: H_0 : Die Zeitreihe x_t ist unabhängig

H_1 : Die Zeitreihe x_t ist abhängig

Es gilt:

$V = 37$ (Anzahl der Wendepunkte)

$$E(V) = \frac{2}{3} (N - 2) = \frac{2}{3} (54 - 2) = 34,67$$

$$\sigma_V^2 = (16N - 29)/90 = (16 \cdot 54 - 29)/90 = 9,28$$

Prüfgröße: $Z = |V - E(V)|/\sigma_V = |37 - 34,67|/\sqrt{9,28} = 0,765 \sim NV(0; 1)$

Nicht-Ablehnungsbereich der H_0 -Hyp.: $[0; 1,96]$ mit $\alpha = 0,05$

Testentscheidung: $0,765 \in [0; 1,96] \Rightarrow H_0$ nicht verwerfen

Dieser Test führt zum Ergebnis, dass die Zeitreihe der Verkaufsdaten des Grossisten Lütke-meyer Münster den Bedingungen der Unabhängigkeit genügt.

Das Programm SPSS enthält unter der Prozedur nichtparametrische Tests / Sequenz-analyse den Runs-Test.

Runs Test	VMUENSTE		
Runs:	25	Test value =	275,000 (Median)
Cases:	26	LT Median	
	28	GE Median	Z = - ,8153
	--		
	54	Total	2-Tailed P = ,4149

(SPSS/PC 6.1.3)

Zuerst wird der Median ermittelt und von allen 54 Verkaufswerten abgezogen. Zur Berechnung der Prüfgröße des Runs-Test benötigt man nicht die um den Median bereinigten Verkaufswerte, sondern lediglich deren Vorzeichen. Bei der Auflistung der Vorzeichen muss die ursprüngliche zeitliche Reihenfolge erhalten bleiben. Neben der Anzahl der Läufe (Runs) ermittelt SPSS auch die Anzahl der negativen (LT Median) und positiven (GE Median) Vorzeichen und summiert sie getrennt voneinander auf: $\sum n_i^2$ ($i = 1$ (positive), 2 (negative)). Im Gegensatz zum zuvor auf Seite 70 vorgestellten Runs-Test erfasst die im Programm SPSS verwendete Prüfgröße die Differenzen von Null in der um den Median bereinigten Zeitreihe nicht extra. Differenzen von Null werden als positive Abweichungen mitgezählt. Somit treten Unterschiede zwischen der mit dem Programm SPSS berechneten Prüfgröße ($Z = -0,814$) und der zuvor vorgestellten Prüfgröße ($Z = -1,15$) auf. Des Weiteren wird bei der verwendeten Prüfgröße auch auf die Addition mit dem Wert 0,5 verzichtet. Sollte sich bei der praktischen Anwendung des Runs-Test herausstellen, dass die um den Median bereinigte Zeitreihe eine größere Anzahl von Nullwerten aufweist, erfolgt eine zweite von Hand korrigierte Rechnung.

SPSS Runs-Test:

Hyp.: H_0 : Die Zeitreihe x_t der Verkaufsdaten ist unabhängig

H_1 : Die Zeitreihe x_t der Verkaufsdaten ist abhängig

Es gilt:

R (Realisierte Anzahl von Läufen) = 25

$$\sum_i n_i^2 = 26^2 + 28^2 = 1460 \quad ; \quad \sum_i n_i^3 = 26^3 + 28^3 = 39528$$

$$m = \frac{1}{N} \left[N(N+1) - \sum_i n_i^2 \right] = \frac{1}{54} [54 * 55 - 1460] = 27,96$$

$$\begin{aligned} \sigma_m^2 &= \frac{\sum_i n_i^2 \left[\sum_i n_i^2 + N(N+1) \right] - 2 \sum_i n_i^3 - N^3}{N^2(N-1)} \\ &= \frac{1460[1460 + 54 * 55] - 2 * 54 * 39528 - 54^3}{54^2 * 53} = 13,21 \end{aligned}$$

Prüfgröße: $Z = [R - m] / \sigma_m = [25 - 27,96] / \sqrt{13,21} = -0,814 \sim NV(0; 1)$

Nicht-Ablehnungsbereich der H_0 -Hyp. ($\alpha = 0,05$): $[-1,96; 1,96]$

Testentscheidung: $-0,814 \in [-1,96; 1,96] \Rightarrow H_0$ nicht verwerfen

Mit dem Runs-Test gelangt man zu der Entscheidung, dass die Verkaufsdaten des Grossisten Lütkemeyer keine signifikante Abhängigkeit aufweisen.

Anstelle des Medians kann auch das arithmetische Mittel zur Bereinigung der Verkaufswerte verwendet werden. Dabei gelangt man zu derselben Testaussage, dass keine signifikante Abhängigkeit festzustellen ist.

Runs Test		VMUENSTE	
Runs:	25		Test value = 274,5741 (Mean)
Cases:	26	LT Mean	
	28	GE Mean	Z = - ,8153
	--		
	54	Total	2-Tailed P = ,4149

(SPSS/PC 6.1.3)

Bis auf den Box-Ljung-Test kommt es bei allen anderen Tests für den Grossisten Lütkemeyer Münster zu einer Verwerfung der Hypothese auf Abhängigkeit der Zeitreihenwerte.

3.3.5 Tests auf Nichtlinearität

Zeitreihen, die nicht unabhängig sind, besitzen eine bestimmte Form der Abhängigkeit, die sich je nach Datenstruktur mit linearen oder nichtlinearen Modellen beschreiben lassen. Lineare Modelle reichen dabei von einfachen deterministischen Trendmodellen bis hin zur Klasse der SARIMA-Modelle.

Viele nichtlinearen Prozesse können durch geeignete Transformationen in eine Form gebracht werden, die die Anwendung linearer Schätzmethoden auf die transformierte Zeitreihe ermöglicht.⁹⁶

Die Hypothesentests zur Unterscheidung zwischen linearen bzw. nichtlinearen Abhängigkeitsstrukturen lassen sich in drei Teststrategien einteilen:

„Chow-Tests, Tests mit Spezifizierung eines linearen Modells in der Nullhypothese und Tests, die spezifische Eigenschaften eines endlichen Markoff-Prozesses ausnutzen.“⁹⁷

Chow-Tests besitzen einige Nachteile, unter anderem führen sie zu verzerrten Ergebnissen und stellen laut Neftci keine korrekte Strategie zur Überprüfung der Asymmetriehypothese dar.⁹⁸

Die Tests mit Spezifizierung von linearen Modellen erfordern die exakte Formulierung der Modelle in Null- und Alternativhypothese und beziehen sich in der Regel auf die Überprüfung der Residuen.⁹⁹

Zur dritten Teststrategie gehört der Asymmetrietest von Neftci, der nachfolgend zur Anwendung kommt. Er lässt sich sowohl auf die Residuen nach erfolgter Modellschätzung, aber auch auf die ursprüngliche Zeitreihe anwenden. Voraussetzung ist aber, dass die Zeitreihe stationär ist.

3.3.5.1 Asymmetrietest von Neftci

Bei diesem Testverfahren wird die Symmetrie bzw. Asymmetrie von Zeitreihenwerten überprüft.

Liegt ein systematisches asymmetrisches Verhalten der Zeitreihe vor, so benötigt man Modelle, die dieses Verhalten endogen erzeugen können. Lineare Modelle sind dazu nicht geeignet.

Der Test von Neftci baut auf die Übergangswahrscheinlichkeiten der Wendepunkte in den Daten auf.

⁹⁶ Cromwell/Labys/Terraza 1994, 37.

⁹⁷ Kraft 1997, 109.

⁹⁸ Neftci 1984, 310.

⁹⁹ Kraft 1997, 109.

Theoretische Teststruktur:

Aus den Beobachtungswerten einer Zeitreihe x_t werden die ersten Differenzen gebildet ($\Delta^1 x_t = x_t - x_{t-1}$). Die differenzierte Reihe wird in den Prozess I_t umgewandelt, wobei gilt:

$$I_t = \begin{cases} +1 & , \text{wenn } \Delta^1 x_t > 0 \\ -1 & , \text{wenn } \Delta^1 x_t \leq 0 \end{cases}$$

Zyklen weisen oft asymmetrische Strukturen auf, dies bedeutet zum Beispiel, dass der Prozess I_t wesentlich öfter den Wert +1 annimmt als -1. Die Übergangswahrscheinlichkeiten von +1 zu +1 ist wesentlich größer als die Übergangswahrscheinlichkeit von -1 zu -1. Für den Prozess I_t werden folgende Restriktionen unterstellt: Erstens der Prozess ist stationär und zweitens er genügt einem Markoff-Prozess zweiter Ordnung.

Die Übergangswahrscheinlichkeiten werden für die Realisationen einer Zufallsstichprobe $S = (i_1, i_2, \dots, i_T)$ mit Hilfe einer Maximum-Likelihoodschätzung ermittelt¹⁰⁰.

Likelihoodfkt.: $L(S, \lambda_{ij}, \pi_0) = \pi_0 (\lambda_{00})^{n_{00}} (1 - \lambda_{00})^{n_{01}} (\lambda_{11})^{n_{11}} (1 - \lambda_{11})^{n_{10}}$

$$\text{mit } \pi_0 = P(I_1 = i_1) = \frac{1 - \lambda_{1-i_1, 1-i_1}}{2 - \lambda_{00} - \lambda_{11}}$$

Die von Kraft¹⁰¹ entwickelte Prozedur MCycle wird auf die stationären Zeitreihen angewandt. Als Ausgabeprotokoll erhält man in einer Graphik die einzelnen Konfidenzintervalle der geschätzten Parameter λ_{00} und λ_{11} sowie das gemeinsame Konfidenzellipse der beiden Parameter.

Darüber hinaus wird die Matrix m der geschätzten Parameter aufgeführt:

$$m = \begin{pmatrix} \lambda_{00} & \lambda_{01} \\ \lambda_{10} & \lambda_{11} \end{pmatrix}$$

Getestet werden die Hypothesen: H_0 : Symmetrische Zeitreihe
 H_1 : Asymmetrische Zeitreihe

Auf die Alternativhypothese (Asymmetrie) wird entschieden, wenn die Diagonale $\lambda_{00} = \lambda_{11}$ das Konfidenzellipse nicht schneidet. Die Größe des Konfidenzellipse hängt vom Stichprobenumfang N ab.

„Gerade für kleine Stichprobenumfänge ist die Mächtigkeit des Tests aber gering, wie Simulationsstudien zeigten, d.h., H_0 (Symmetrie) wird mit großer Wahrscheinlichkeit fälschlich beibehalten. Auch werden durch die Definition der Prüfgröße I_t die absoluten

¹⁰⁰ Kraft 1997, 110.

¹⁰¹ Kraft 1997, 110-111.

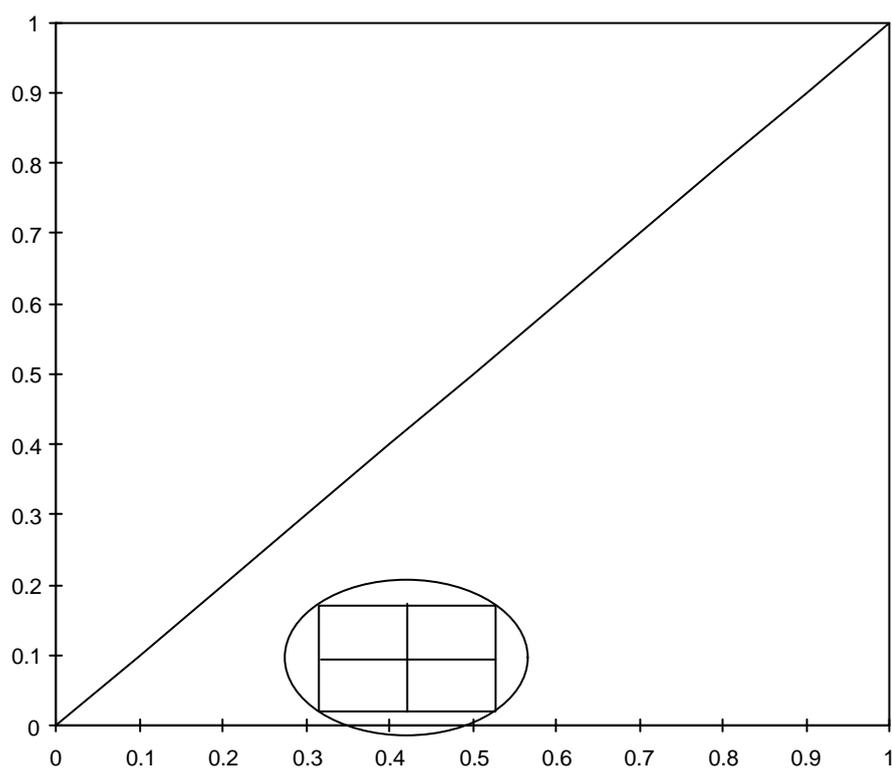
Werte der Differenzen $x(t) - x(t-1)$ nicht berücksichtigt. Größere oder kleinere Richtungswechsel können so nicht unterschieden werden und führen deshalb zu einer Überschätzung der Zahl der Wendepunkte in der Originalreihe.¹⁰²

3.3.5.2 Durchführung des Asymmetrietests von Neftci (Lütkemeyer Münster)

Das Ergebnis des ADF-Tests auf Seite 57 ließ für den Grossisten Lütkemeyer Münster die Annahme der Stationarität zu. Damit ist eine Grundvoraussetzung zur Durchführung des Neftci-Tests erfüllt. Die Matrix der geschätzten Parameter lautet:

$$m = \begin{pmatrix} 0,42 & 0,58 \\ 0,91 & 0,09 \end{pmatrix}$$

Die gesamte Fläche des Konfidenzellipsoids mit $\alpha = 0,2$ und $N = 54$ liegt eindeutig unter der Diagonalen $\lambda_{00} = \lambda_{11}$. Damit wird die Nullhypothese auf Symmetrie der Zeitreihe verworfen und auf die Alternativhypothese entschieden.



¹⁰² Kraft 1997, 112.

4 Theoretische Aspekte der Modellentwicklung

Im vorherigen Abschnitt wurden verschiedene Verfahren zur Beschreibung und Identifikation von Zeitreihen ausführlich erörtert.

Die meisten Verfahren der Zeitreihenanalyse sind nur dann anwendbar, wenn die Bedingung der schwachen Stationarität erfüllt ist. Zeitreihen, die dieser Bedingung nicht genügen, müssen in geeigneter Weise transformiert werden, bis die schwache Stationarität vorliegt. Erfüllen die Zeitreihen bzw. transformierten Zeitreihen neben der schwachen Stationarität auch die Bedingung auf Normalverteiltheit, Abhängigkeit und Symmetrie, dann lässt sich die vorliegende Abhängigkeitsstruktur durch ein lineares Modell beschreiben.¹⁰³

Eine Möglichkeit, abhängige Zeitreihen zu beschreiben, bietet der deterministische Modellansatz, bei dem ein stochastischer Prozess lediglich in einer Restkomponente auftritt. Dabei kann die Form der Abhängigkeit von einem einfachen linearen Trendmodell bis zu komplexen nichtlinearen Modellen reichen. Hinweise über die Form der Abhängigkeit liefern die Testverfahren, die im Kapitel 3 ausführlich vorgestellt werden.

Neben den deterministischen Modellen darf die Klasse der rein stochastischen Modelle nicht vergessen werden. Beide Konzepte werden erörtert, gegenübergestellt und auf die realisierten Daten übertragen.

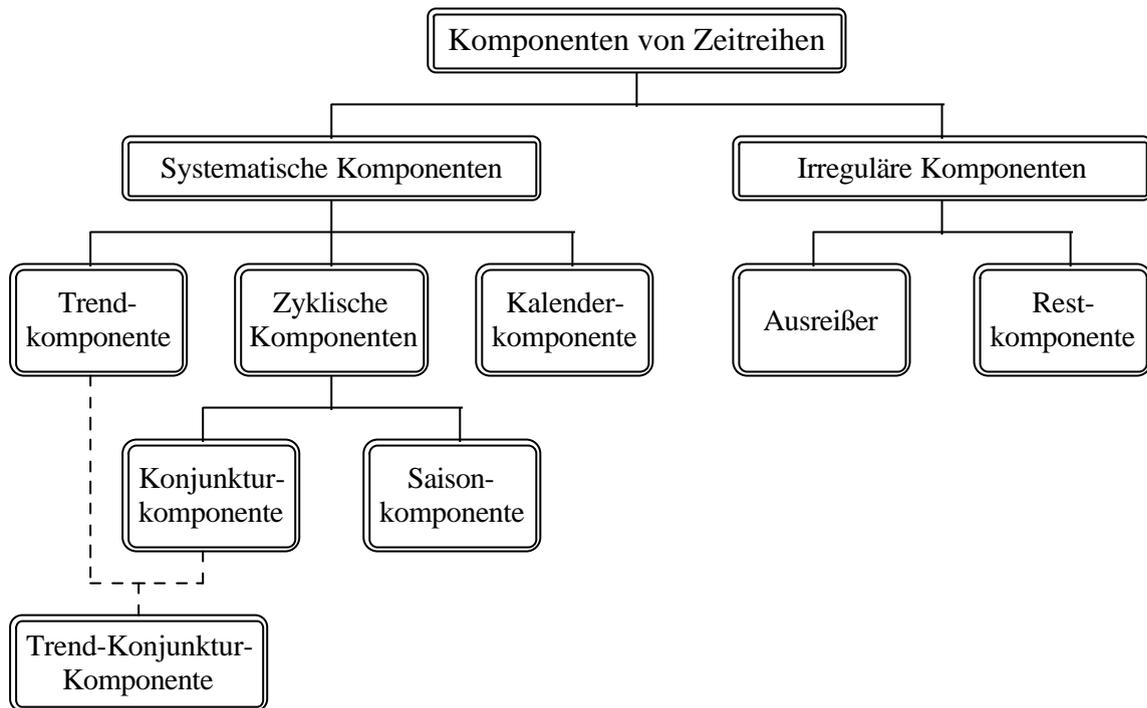
Ob ein Modellansatz als gelungen zu betrachten ist, wird anhand von Gütekriterien überprüft, dabei spielen bei der Untersuchung der Residuen die Bedingungen der Stationarität, Normalverteiltheit und Unabhängigkeit wiederum eine wichtige Rolle.

4.1 Methoden der Zeitreihenzerlegung

Die meisten ökonomischen Zeitreihen weisen im Zeitverlauf mittel- bis langfristige Veränderungen auf und verletzen somit die Stationaritätsbedingung. Eine Möglichkeit, derartige Zeitreihen in den Griff zu bekommen, kann durch die Zerlegung derselben in verschiedene systematische Teile erreicht werden. Bei unterjährigen ökonomischen Daten erfolgt zum Beispiel per Definition eine Unterteilung in die Ursachenkomplexe Trend, Konjunktur und Saison. Übrig bleibt lediglich ein unerklärter Rest, die irreguläre Komponente, die nicht zu erklärende Einflüsse enthält.

¹⁰³ Cromwell/Labys/Terrarza 1994, 19.

Schäffer verwendet folgendes Schaubild zur Darstellung der Komponenten einer Zeitreihe:¹⁰⁴



Realwissenschaftlich besteht keine Möglichkeit, die Phänomene wie Trend, Konjunktur und Saison isoliert zu messen, da sie nicht einzeln zu beobachten sind. Sie stellen Bestandteile der formalen Definition der Komponenten dar und keine realen ökonomischen Vorgänge. Für diese Phänomene bietet sich lediglich eine verbale Umschreibung an. Eine Ausnahme stellt der Kalendereffekt dar. Er lässt sich explizit erklären, da er einerseits von der Anzahl der Tage eines Monats abhängt und andererseits von deren Zusammensetzung. Unter der Zusammensetzung versteht man zum Beispiel die Anzahl der Werkzeuge eines Monats.

Der Trend einer Zeitreihe wird als die „langfristige systematische Veränderung des mittleren Niveaus der Zeitreihe“ verstanden.¹⁰⁵

Was unter langfristigen Veränderungen zu verstehen ist, hängt entscheidend von der Länge der betrachteten Zeitreihen ab. Chatfield erläutert den Effekt an einem Beispiel aus der Klimaforschung. In der Klimatologie lassen sich langfristige Zyklen von ca. 50 Jahren beobachten. Analysiert man lediglich einen Zeitraum von höchstens 20 Jahren,

¹⁰⁴ Schäffer 1997, 31.

¹⁰⁵ Schlittgen/Streitberg 1989, 9.

so kann der langfristige Zyklus nicht identifiziert werden, sondern stellt sich als Trend dar.¹⁰⁶

Saison, darunter versteht man wiederkehrende jahreszeitliche Schwankungen. Neben der Saison lassen sich gegebenenfalls noch andere zyklische Schwankungen definieren, wie zum Beispiel Konjunkturschwankungen. Konjunkturschwankungen umfassen einen mehrjährigen Zyklus, wobei sich die Intervalllänge im Zeitverlauf verändern kann. Alle Arten von zyklischen Schwankungen lassen sich aber nur feststellen, wenn in eine Zykluslänge mindestens zwei Beobachtungswerte fallen.

Die irreguläre Komponente lässt sich in Ausreißer und Restkomponente unterteilen. Auf die Problematik der Ausreißer wird an dieser Stelle nicht näher eingegangen. Die kurze Betrachtung der Restkomponente ist dagegen unerlässlich, da sie zur Beurteilung der Qualität einer Zeitreihenzerlegung eine entscheidende Rolle spielt. Die Restkomponente sollte keine strukturellen Einflüsse aufweisen, sondern nur noch unsystematische Störungen, die sich nicht weiter erklären lassen.

Die aufgeführte Komponentenzerlegung stellt eine Zerlegungsmöglichkeit dar. Bei anderen Zerlegungen verzichtet man gänzlich auf die Konjunkturkomponente oder fasst Trend- und Konjunkturkomponente zur glatten Komponente zusammen.

Die Verknüpfung der Komponenten kann auf unterschiedlichste Art und Weise erfolgen. Beeinflussen sich die Komponenten nicht gegenseitig, so bietet sich das additive Grundmodell an. Stellt man hingegen fest, dass proportional zum Trend oder zur glatten Komponente auch die Schwankungsausschläge der Saisonkomponente zu- bzw. abnehmen, so bietet sich die multiplikative Verknüpfung an. Rein multiplikative Grundmodelle lassen sich durch logarithmische Transformation in additive Modelle umwandeln.

Neben den rein additiven bzw. multiplikativen Verknüpfungsmöglichkeiten sind auch andere Formen denkbar.

Als Beispiel führt Schäffer die Reihe der Arbeitslosenzahlen in der Bundesrepublik Deutschland an. Bei einem rein additiven Grundmodell wird die Saisonkomponente unterschätzt und bei einem rein multiplikativen Modell überschätzt. In diesem Fall wird eine Lösung durch Transformation erzielt. Schäffer erwähnt in diesem Zusammenhang die Klasse der Box/Cox-Transformationen. Denkbar wäre aber auch eine Lösung mit gemischten Modellen, die sowohl additive als auch multiplikative Verknüpfungen enthalten.¹⁰⁷

¹⁰⁶ Chatfield 1985, 13.

¹⁰⁷ Schäffer 1991, 28.

Bei der Modellierung eines Komponentenmodells sollten die einzelnen Komponenten explizit definiert werden. Leider wird bei vielen praktischen Anwendungen auf die explizite Modellbeschreibung der Komponenten verzichtet. Ein Beispiel ist die Census Methode X-11.¹⁰⁸ Bei der Entstehung dieser Methode, die eine Ansammlung von Verfahrensprozeduren darstellt, machte man sich keinerlei Gedanken über die implizit zugrunde liegenden Komponentenmodelle. Eine methodologische Beurteilung der Verfahren ist aber nur möglich, wenn die implizit zugrunde liegenden Komponentenmodelle eindeutig identifiziert werden. W. P. Cleveland und G. C. Tiao gelang es, für ein additives Grundmodell der Census Methode X-11, den stochastischen Prozess zu beschreiben, der zu optimalen Ergebnissen führt.¹⁰⁹ Für die multiplikativen Grundmodelle ist dieser Nachweis bis heute nicht gelungen. Schäffer nennt in seinem Aufsatz drei Gründe, die gegen die Anwendung des multiplikativen Grundmodells der Census Methode X-11 sprechen:

Das Komponentenmodell, auf dem die multiplikativen Grundmodelle beruhen, konnte nicht identifiziert werden, einige Arbeitsschritte sind inkonsistent und die glatte Komponente ist systematisch verzerrt.

Eine besonders detaillierte und kritische Beurteilung der Census Methode X-11 findet man bei Winfried Stier.¹¹⁰

Andere Autoren wie zum Beispiel Makridakis, Reschke und Wheelwright präferieren gerade die Census Methode. „Die Gültigkeit dieses Verfahrens und die Genauigkeit seiner Ergebnisse sind durch die Anwendung auf Hunderttausende von Reihen empirisch nachgewiesen worden.“¹¹¹ Makridakis, Reschke und Wheelwright beziehen sich bei ihren Ausführungen auf die Census II Methode. Die Census Methode X-11 ist eine Weiterentwicklung der Census II Methode.¹¹²

Schon 1936 hatte A. Wald gefordert, „daß die Annahmen für die Berechnung der Komponenten explizit zu spezifizieren sind.“¹¹³

Aber erst Mitte der sechziger Jahre setzte sich diese Erkenntnis in der Zeitreihenanalyse durch. Zu unterscheiden sind zwei Gruppen von explizit formulierten Modellen, die lokalen und die globalen Modelle.

¹⁰⁸ Shiskin/Young/Musgrave 1965.

¹⁰⁹ Cleveland/Tiao 1976.

¹¹⁰ Stier 1980, Kap. 1.

¹¹¹ Makridakis/Reschke/Wheelwright 1980, 128.

¹¹² Weiterführende Literatur: Monatsberichte der Deutschen Bundesbank 1970 und 1987.

¹¹³ Schäffer 1991, 30 und Lüüs 1993.

Wie der Name schon sagt, beschreiben lokale Modelle immer nur einen Teil der Zeitreihe. Die Beschreibung erfolgt durch geeignete Filtertechniken. Der Vorteil der lokalen Modelle liegt in der zumeist einfachen Anwendung und dem geringen Rechenaufwand. Als besonders nachteilig erweist sich die Zerlegung an den Rändern, besonders am aktuellen Rand der Zeitreihe. Eine in der Praxis oft verwendete Filtertechnik sind die gleitenden Durchschnitte. Bei den gleitenden Durchschnitten lassen sich die geglätteten Werte nur mit einer deutlichen zeitlichen Verzögerung berechnen. Bei monatlichen Daten und einem Stützbereich von 12 Monaten liegt die zeitliche Verzögerung bei sechs Monaten.

Als ein komplexes Beispiel für ein lokales Komponentenmodell führt Schäffer das Berliner Verfahren an.¹¹⁴

Globale Modelle beschreiben die Eigenschaften einer gesamten Zeitreihe. Sie lassen sich in zwei Gruppen einteilen. Zum einen in die Gruppe der strukturellen Modelle und zum anderen in die Gruppe der kompakten Modelle. Bei den strukturellen Modellen werden die Komponenten der Zeitreihe einzeln modelliert und abschließend zum Gesamtmodell zusammengefasst. Kompakte Modelle hingegen werden nicht in einzelne Komponenten zerlegt, sondern die Schätzung der Modellkoeffizienten erfolgt simultan.

Als Beispiel für ein kompaktes Modell führt Schäffer die rekursiven Filter an, die zur Aufdeckung der glatten Komponente bzw. zur Eliminierung der Saisonkomponente geeignet sind. Eine andere Klasse von kompakten Modellen stellen die ARIMA-Modelle dar. Dabei wird von der Grundidee ausgegangen, dass sich eine Zeitreihe „als Realisation eines speziellen stochastischen Prozesses aus der Klasse der ARIMA-Prozesse“ darstellen lässt.¹¹⁵

¹¹⁴ Schäffer 1991, 31-32.

¹¹⁵ Schäffer 1991, 34-35.

4.2 Der Trend in der Zeitreihenanalyse

In diesem Abschnitt werden zuerst einige globale aber auch lokale Techniken zur Ermittlung und Bereinigung eines deterministischen Trends kurz vorgestellt. Danach wird als Gegenpol zum Konzept des deterministischen Trends die Differenzenbildung zur Erfassung eines stochastischen Trends erwähnt. Im Rahmen der ARIMA-Modelle schlagen Box und Jenkins die Differenzenbildung zur Entfernung des Trends vor.¹¹⁶

Zum Schluss werden noch verschiedene Filtertechniken aufgeführt, mit denen der Trend lokalisiert werden kann.

Zeitreihen, die trendbehaftet sind, egal ob mit unterstelltem deterministischen oder stochastischen Trend, erfüllen nicht mehr die Definition der Stationarität, da sich ihr Erwartungswert mit der Zeit verändert.¹¹⁷

Des Weiteren weisen trendbehaftete Reihen, je nach Trendverlauf, eine positive oder negative Autokorrelation auf. Die Autokorrelationsfunktion kann daher nicht mehr zur Beschreibung der Abhängigkeit zwischen den einzelnen Zeitpunkten benutzt werden, da sie vom Trend überlagert wird.¹¹⁸

Deterministisches Trendkonzept durch Anpassung an die Kurve:

Mit Hilfe einfacher Funktionen (lineare, quadratische, kubische, logarithmische usw.) lassen sich für viele Zeitreihen ohne Saisonschwankungen eine gute Beschreibung des Trends erreichen. Für einen polynomialen Trend der Ordnung (k-1) gilt allgemein:

$$m(t) = \beta_1 + \beta_2 t + \beta_3 t^2 + \dots + \beta_k t^{k-1}$$

Eine Alternative zu den Polynomkurven liefert die Gompertz Kurve¹¹⁹: $\log x_t = a - b r^t$

Diese Kurve hat eine S-förmige Form, wobei t gegen unendlich strebt, a, b und r Parameter darstellen und r folgenden Wertebereich annimmt: $0 < r < 1$

Stochastisches Trendkonzept durch Differenzenbildung:

Um den Trend zu entfernen, bildet man so lange Differenzen, bis die Zeitreihe stationär ist. Oft kommt man schon mit der Differenzierung erster Ordnung aus.¹²⁰ Die Differenzenbildung wird im Rahmen der ARIMA-Modelle im Kapitel 4.4 kurz vorgestellt.

¹¹⁶ Box/Jenkins 1970.

¹¹⁷ Wei 1990, 67-69.

¹¹⁸ Schlittgen/Streitberg 1989, 13.

¹¹⁹ Chatfield 1985, 16.

¹²⁰ Chatfield 1985, 21.

Weisen die Daten neben dem Trendeffekt auch einen Saisoneffekt auf, so besteht eine einfache Möglichkeit der Trendbeschreibung in der Berechnung von aufeinander folgenden jährlichen arithmetischen Mittelwerten.

In diesem Abschnitt wurden verschiedene Möglichkeiten der Trendbereinigung von Zeitreihen vorgestellt, die implizit eine bestimmte Form des Trends unterstellen. Zum Beispiel reagieren Differenzenbildung und linearer Trend sehr sensibel auf den zugrunde liegenden Trend. Die Anpassung an eine lineare Trendfunktion ist nur geeignet, wenn der zugrunde liegende Trend wirklich eine deterministische Funktion darstellt und stochastische Schocks lediglich eine kurzlebige Auswirkung besitzen. Die Bildung von Differenzen ist dann optimal, wenn die Nicht-Stationarität in der Serie vom Typ eines Random-Walk-Prozesses ist. In diesem Fall haben Schocks einen permanenten Effekt.

Bildet man zum Beispiel Differenzen im Falle eines deterministischen Trends, dann wird der Hochfrequenzbereich gegenüber dem Niedrigfrequenzbereich völlig überzeichnet.

Die Anpassung eines deterministischen Trends an einen Random-Walk-Prozess führt zu falschen Zyklen in der bereinigten Reihe.

Ist man sich über den zugrunde liegenden Trend im Unklaren, dann hat man die Möglichkeit, die Form des Trends mit Hilfe geeigneter Tests zu prüfen. Im Kapitel 3.3.2 wurde der Augmented-Dickey-Fuller-Test vorgestellt. Dabei lassen sich durch Überprüfung der Stationaritätsbedingung die folgenden Formen des Trends in der Zeitreihe testen: Kein Trend, linearer deterministischer Trend oder stochastischer Trend (Entfernung durch Differenzenbildung) vorhanden.

In einer Studie überprüften Hillinger, Reiter und Woitek¹²¹ die Robustheit einiger weit verbreiteter Trendbereinigungsverfahren. Bei der Beurteilung der Qualität der angewandten Prozeduren wurde darauf geachtet, dass sich die zyklische Komponente durch die Trendbereinigung sauber isolieren lässt.

Als ein Ergebnis der Studie lässt sich festhalten, dass die am meisten auseinander liegenden Methoden, Differenzenbildung und Anpassung an einen linearen Trend, in einigen Fällen zu jeweils optimalen Ergebnissen führen. Sie sind aber nicht robust, da sie nur für einen Teil der unterstellten Modelle gute Ergebnisse erzielen. Oft kommt es zu Verzerrungen in der Spektraldichte der Residuen, das heißt, die Zyklen werden durch die Trendbereinigung verfälscht.

Unabhängig von der exakten Natur des trenderzeugenden Prozesses führt hingegen der Hodrick-Prescott-Filter zu robusteren Ergebnissen für die verschiedenen Zeitreihenmodelle. Ausnahme stellt der Random-Walk-Prozess dar, wo der HP-Filter zu falschen Zyklen führt.

¹²¹ Hillinger/Reiter/Woitek 1992.

$$\text{HP-Filter: } \text{HP} = \sum_{i=1}^T (y_t - \tilde{y}_t)^2 + \lambda \sum_{t=2}^{T-1} ((\tilde{y}_{t+1} - \tilde{y}_t) - (\tilde{y}_t - \tilde{y}_{t-1}))^2$$

mit: y_t = Originalwert

\tilde{y}_t = Trendwert

Der HP-Filter besteht aus zwei Teilen. Der erste Teil ist ein Maß für die Güte der Anpassung („Goodness of fit“). Die Trendwerte werden so ermittelt, dass der erste Ausdruck minimiert wird. Der zweite Teil ist ein Maß für die Variation des Trends.

Für jährliche Daten wird ein Gewichtungsfaktor von 100 empfohlen. Hillinger, Reiter und Woitek hatten auch kleinere Werte für den Gewichtungsfaktor getestet, sie empfehlen aber den Wert 10 nicht zu unterschreiten, da sonst bei der Schätzung des Trends zuviel von der Fluktuation absorbiert wird.¹²²

Das Programm EViews verfügt über den HP-Filter. Standardmäßig wird bei Zeitreihen mit jährlichen Daten ein Gewichtungsfaktor von 100 verwendet, bei Quartalsdaten von 1600 und bei monatlichen Daten 14400. Dies entspricht den von Hodritt und Prescott vorgeschlagenen Werten. EViews erlaubt es dem Benutzer, jeden beliebigen Gewichtungsfaktor frei einzugeben.

Weitere vielfach angewandte Filtertechniken sind zum Beispiel die gleitenden Durchschnitte (Moving Average), die Spline-Funktionen oder die Verfahren der exponentiellen Glättung.

Bei der Verwendung von gleitenden Durchschnitten lässt sich durch Verwendung linearer Filter die Zeitreihe x_t in y_t umwandeln.

Der lineare Filter sieht wie folgt aus: $y_t = \sum_{r=-q}^{+s} a_r x_{t+r}$

Die a_r stellen einen Satz von Gewichten dar. Die Gewichte sollten so gewählt sein, dass ihre Summe 1 ergibt.

Für viele Fragestellungen ist es sinnvoll, die Gewichte so zu wählen, dass sie annähernd normalverteilt sind. Die Funktion lautet zum Beispiel:

$$y_t = \frac{1}{2q+1} \sum_{r=-q}^{+q} x_{t+r}$$

¹²² Hillinger/Reiter/Woitek 1992.

Zur Berechnung der Gewichte dient folgende Formel $\left\{ \left(\frac{1}{2} + \frac{j}{2} \right)^{2q} \right\}$, wobei q eine positive ganze Zahl ist. Für große q nähern sich die Gewichte der Normalverteilung an.¹²³

In der Literatur begegnet man einer ganzen Reihe weiterer Filter, wie zum Beispiel „Spencer’s 15 point moving average“¹²⁴ oder „Henderson moving average“¹²⁵.

Eine andere Möglichkeit der Filterung besteht in der stückweisen Anpassung durch Polynomkurven. Dabei wird nicht die gesamte Zeitreihe, sondern immer nur ein bestimmter Teil angepasst.

Die Klasse von „spline functions“ stellt ein Beispiel für die Anpassung durch stückweise Polynomzüge dar.¹²⁶

Eine in der praktischen Anwendung vielfach angewandte Filtertechnik ist die exponentielle Glättung. Das Polynom hat dabei folgende Grundform:

$$\hat{x}_t = \sum_{j=0}^q a_j x_{t-j} \quad \text{mit} \quad a_j = \alpha (1 - \alpha)^j$$

wobei $q = \infty$ und die Glättungskonstante α auf den Wertebereich $0 < \alpha < 1$ definiert ist.

Die Auswahl eines geeigneten Filters erfordert neben der intensiven Kenntnis des Frequenzaspektes von Zeitreihen ein beachtliches Maß an Erfahrungen.

Mit Hilfe von Filtertechniken lassen sich beliebige Frequenzprofile herausfiltern. Zwei extreme Filter stellen dabei „low-pass filter“ und „high-pass filter“ dar. Mit Hilfe der „low-pass filter“ sollen die lokalen Schwankungen beseitigt werden, so dass lediglich die langfristige Komponente erhalten bleibt. Bei einem „high-pass filter“ ist es genau umgekehrt; der langfristige Einfluss soll entfernt werden.

Oft werden Filter in Serie geschaltet, das bedeutet, dass die Glättung in mehreren Schritten erfolgt.¹²⁷

¹²³ Kendall 1976, Kap. 3 u. 4.

¹²⁴ Tetley 1946.

¹²⁵ Kenny/Durbin 1982.

¹²⁶ Wold 1974.

¹²⁷ Chatfield 1985, 17-20.

4.3 Saisonkomponente

In diesem Abschnitt werden einfache Prozeduren zur Handhabung von saisonalen Effekten in deterministischen und stochastischen Modellen vorgestellt. Eine Testprozedur, die es ermöglicht, zwischen bestimmten Formen von deterministischer und stochastischer Saison zu unterscheiden, wird in Kapitel 4.7.3 gesondert vorgestellt.

Welche Verfahren letztendlich bei der Modellierung des Saisoneffektes zu guten Ergebnissen führen, hängt im hohen Maße von der Art des Trends ab.

Bei Zeitreihen, die einen geringen oder keinen Trend aufweisen und deren Saisonverlauf über die Zeit konstant bleibt, genügt vielfach ein Vergleich zwischen den arithmetischen Mitteln der einzelnen Monate (\bar{x}_s) mit dem gesamten arithmetischen Mittel (\bar{x}) der Zeitreihe, um den Saisoneffekt erfassen zu können. Der Vergleich kann dabei durch Differenz- oder Quotientenbildung erfolgen. $\bar{x}_s - \bar{x}$ oder \bar{x}_s / \bar{x} mit $s = 1, 2, \dots, 12$ für Monatsdaten.

Für Zeitreihen, die einen deutlichen Trend aufweisen, sind aufwendigere Verfahren zur Erfassung der Saison notwendig.

Ein mögliches Verfahren stellen die gleitenden Durchschnitte dar. Bei einer geraden Anzahl von t Werten pro Saison nimmt man $t+1$ Werte, wobei der erste und der letzte Wert durch zwei dividiert werden.

Gleitende Durchschnitte bei monatlichen Daten:

$$\hat{x}_t = \frac{\frac{1}{2}x_{t-6} + x_{t-5} + \dots + x_t + \dots + x_{t+5} + \frac{1}{2}x_{t+6}}{12}$$

Der Saisoneffekt kann additiv oder multiplikativ geschätzt werden, entweder Beobachtungswert minus geglätteten Wert oder Beobachtungswert dividiert durch geglätteten Wert.

Die additive Methode verwendet man, wenn die Höhe der Saisonausschläge über die Zeit konstant bleibt. Wachsen hingegen die Saisonausschläge proportional zum Mittelwert an, so ist die multiplikative Methode die geeignetere.¹²⁸

¹²⁸ Weiterführende Literatur.: Box/Jenkins 1970, Pierce 1980, Cleveland/Tiao 1976 und Shiskin/Plewes 1978.

Die Methode der gleitenden Durchschnitte lässt sich sehr gut in ein deterministisches Komponentenmodell integrieren. Autoren, wie zum Beispiel Bamberg und Baur sprechen in diesem Zusammenhang von einer Saisonbereinigung mit konstanter Saisonfigur. Dabei unterstellen sie ein additives verknüpftes Zeitreihenmodell. Es besteht aus einer Trendkomponente, einer zyklischen Komponente, einer Saisonkomponente und einer irregulären Komponente. Die Verknüpfung all dieser Komponenten erfolgt additiv.¹²⁹

$$y_t = T_t + Z_t + S_t + U_t \quad (\text{für } t = 1, 2, 3, \dots, N)$$

Die Trendkomponente T_t misst die „langfristig wirkenden Ursachen“. Sie kann monoton fallend oder steigend sein. Wenn der Untersuchungszeitraum nicht gerade mehrere Jahrzehnte umfasst, wird der Trend in der Regel als lineare Funktion der Zeit betrachtet.

Die zyklische Komponente Z_t besitzt einen wellenförmigen Verlauf und spiegelt den Konjunkturzyklus wider.

Die Saisonkomponente S_t beschreibt den jahreszeitlichen Einfluss auf den Verlauf der Zeitreihe.

Unter der irregulären Komponente U_t versteht man den durch das additive Zeitreihenmodell nicht zu erklärenden Restteil. Die irregulären Schwankungen sollten den folgenden Anforderungen genügen: sie sollten unsystematisch um ihren Erwartungswert schwanken, der Erwartungswert sollte Null betragen. Man bezeichnet die irreguläre Komponente auch als Störterm. Sie stellt keine deterministische, sondern eine stochastische Größe dar und wird von daher als Zufallsvariable aufgefasst.

Die Zeitreihe wird zuerst um die glatte Komponente (Trend und zyklische Komponente) bereinigt. Zu deren Ermittlung bieten sich zum Beispiel die gleitenden Durchschnitte an.

Die um Trend und zyklische Komponente bereinigte Zeitreihe enthält nur noch die saisonale Komponente und den Störterm.

Die Saisonbereinigung erfolgt im additiv verknüpften Modell zum Beispiel mit konstanter Saisonfigur. Man berechnet für jede der 12 Ausgaben, die pro Jahr erscheinen, den entsprechenden durchschnittlichen Wert. Für die vorliegenden Zeitreihen bedeutet dies, dass für jeden einzelnen Monat die bereinigten Werte der Jahre 92 bis 96 aufaddiert werden, um sie abschließend durch die Anzahl der betrachteten Jahre zu dividieren.

¹²⁹ Bamberg/Baur 1998, 63.

$$\tilde{S}_j = \frac{1}{m_j} \sum_{i=M_j} (y_{ij} - y_{ij}^*)$$

y_{ij} = Beobachtungswert

y_{ij}^* = gleitender 12 - Monats - Durchschnitt

i = Laufindex Jahr

j = Laufindex Monat

\tilde{S}_j liefert schon eine recht gute Schätzung für die Saisonfaktoren. Damit von jedem \tilde{S}_j dasselbe Korrekturglied subtrahiert wird, ist eine Normierung notwendig, d.h., die Summe der \tilde{S}_j -Werte werden auf den Wert Null normiert.

$$\hat{S}_j = \tilde{S}_j - \frac{1}{12} \sum_{j=1}^{12} \tilde{S}_j$$

Wächst die Amplitude der Saisonschwankungen parallel zur glatten Komponente an, so verwendet man nicht das Komponentenmodell mit konstanter, sondern mit variabler Saisonfigur.¹³⁰

Liegt hingegen ein stochastischer Saisoneffekt vor, so kann analog der Vorgehensweise bei den stochastischen Trends die saisonale Differenz der Zeitreihe gebildet werden. Die genaue Vorgehensweise wird im Kapitel 4.7.2 erläutert.

¹³⁰ Bamberg/Baur 1998, 63-73.

4.4 Theoretische Erläuterungen von ARIMA-Prozessen

Entwickelt wurden die ARIMA-Modelle von Box und Jenkins. Die Abkürzung ARIMA steht für ein Autoregressives-Integriertes-Moving-Average-Modell. Zur praktischen Anwendung dieser Ansätze ist ein Computerprogramm unerlässlich. Die Berechnungen in diesem Kapitel erfolgen mit dem Programm EViews. Alternativ könnte auch SPSS/PC+ Trends verwendet werden.

Die Berechnungen erstrecken sich von der Identifizierung, Schätzung bis hin zur Diagnose von ARIMA-Modellen.

ARIMA-Modelle bestehen aus drei verschiedenen Prozessen von Zufallsschwankungen und Schocks. Jeder dieser drei Prozesse besitzt seine Ordnung. Die Variable p steht für die Ordnung des Autoregressiven-Prozesses, d für den Grad der Differenzenbildung und q für die Ordnung des Moving-Average-Prozesses.

Die ARIMA-Modelle lassen sich sowohl für Daten mit und ohne Saisoneffekt berechnen. Zuerst beschäftigen wir uns mit der Theorie der nicht saisonalen ARIMA-Modelle.

4.4.1 Der Moving-Average-Prozess (MA)

Ein Moving-Average-Prozess (MA(q)) der Ordnung q besitzt folgende Form:

$$X_t = \theta_0 Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q}$$

Z_t ist ein einfacher Zufallsprozess, die θ sind Konstanten und X_t der MA-Prozess. Der Erwartungswert ist gleich Null, die anderen Parameter wie Varianz, Autokovarianzfunktion und Autokorrelationsfunktion werden nicht explizit angegeben, man findet sie zum Beispiel bei Chatfield.¹³¹

Ein MA-Prozess erfüllt die Bedingung der schwachen Stationarität, da der Erwartungswert konstant ist und die Autokovarianzfunktion (ACVF) nicht von dem Zeitpunkt t abhängt, sondern lediglich vom „lag“. Sind die Z 's NV, so genügt der MA-Prozess den Bedingungen der strengen Stationarität. Die Gleichung kann ohne Probleme um einen konstanten Wert μ erweitert werden, dies hat keinen Einfluss auf die Eigenschaften des MA-Prozesses.

¹³¹ Chatfield 1985, 42.

Im allgemeinen lässt sich ein MA-Prozess nicht eindeutig aus seiner Autokorrelationsfunktion bestimmen. Box und Jenkins versehen daher die θ mit einer Restriktion, sie nennen diese Restriktion „Invertibility“.¹³²

Betrachten wir dazu die beiden MA-Prozesse erster Ordnung:

$$1) \quad X_t = Z_t + \theta Z_{t-1}$$

$$2) \quad X_t = Z_t + \frac{1}{\theta} Z_{t-1}$$

Beide MA-Prozesse haben dieselbe Autokorrelationsfunktion (ACF); zur Identifikation reicht die ACF nicht aus. Formt man die beiden Gleichungen nach Z_t um, für $|\theta| < 1$ konvergiert X_t in der ersten Gleichung im Gegensatz zur zweiten Gleichung. Umgeformt gilt:

$$1) \quad Z_t = X_t - \theta X_{t-1} + \theta^2 X_{t-2} - \dots$$

$$2) \quad Z_t = X_t - \frac{1}{\theta} X_{t-1} + \frac{1}{\theta^2} X_{t-2} - \dots$$

Modell 1 wird im Gegensatz zu Modell 2 als invertierbar bezeichnet. Invertierbare Modelle zeichnen sich dadurch aus, dass die ACF des MA-Prozesses eindeutig identifizierbar ist.

Recht anschaulich lässt sich die Bedingung der Invertierbarkeit mit Hilfe des „backward shift operator“ erläutern.

Der „backward shift operator“ (Rückwärtsverschiebungsoperator) ist wie folgt definiert:

$$B^j X_t = X_{t-j} \quad \text{für alle } j \Rightarrow X_t = (\theta_0 + \theta_1 B + \dots + \theta_q B^q) Z_t = \theta(B) Z_t$$

Ein MA-Prozess mit der Ordnung q ist invertierbar, wenn die Wurzel aus folgender Gleichung:

$$\theta(B) = \theta_0 + \theta_1 B + \dots + \theta_q B^q = 0$$

außerhalb des Einheitskreises liegt.¹³³

Zum Beispiel werden ökonomische Indikatoren von einer Reihe von zufälligen Ereignissen beeinflusst (z.B.: Streiks, Regierungsentscheidungen,). Solche Störungen haben nicht immer einen unmittelbaren Effekt. Viele haben einen Effekt in abgeschwächter Form, der sich erst zu einem späteren Zeitpunkt auswirkt.

¹³² Box/Jenkins 1970, 50 und Chatfield/Prothero 1973.

¹³³ Chatfield 1985, 43-44.

Zwischen dem MA-Prozess und dem im nächsten Abschnitt vorgestellten AR-Prozess besteht eine Dualität. Der AR lässt sich auch als MA-Prozess umformen, dies gilt natürlich auch umgekehrt.

4.4.2 Der Autoregressive-Prozess (AR)

Für einen Autoregressiven-Prozess $\{AR(p)\}$ gilt: $X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + Z_t$.

Dabei wird angenommen, dass Z_t ein einfacher Zufallsprozess mit Erwartungswert Null und Varianz σ_Z^2 ist.

Jede Zufallsvariable X_t ist eine lineare Funktion der vorherigen Zufallsvariablen.

Der große Unterschied zu einem multiplen Regressionsmodell liegt darin, dass X_t nicht aus unabhängigen Variablen entwickelt wird, sondern aus Vergangenheitsdaten der Zufallsvariable X_t . Daher auch der Name Autoregressiver-Prozess.

Autoregressiver-Prozess erster Ordnung (AR(p=1)):

$$X_t = \phi X_{t-1} + Z_t$$

Der AR(1) lässt sich durch sukzessive Substitution in einen MA-Prozess mit unbegrenzter Ordnung umwandeln:

$$\begin{aligned} X_t &= \phi[\phi X_{t-2} + Z_{t-1}] + Z_t = \phi^2[\phi X_{t-3} + Z_{t-2}] + \phi Z_{t-1} + Z_t \\ &= Z_t + \phi Z_{t-1} + \phi^2 Z_{t-2} + \dots \end{aligned}$$

Auch hier lässt sich die Gleichung wieder durch den „backward shift operator B“ formulieren:

$$\begin{aligned} (1 - \phi B)X_t &= Z_t \Rightarrow \\ X_t &= Z_t / (1 - \phi B) \\ &= (1 + \phi B + \phi^2 B^2 + \dots)Z_t \\ &= Z_t + \phi Z_{t-1} + \phi^2 Z_{t-2} + \dots \end{aligned}$$

Der Erwartungswert ($E(X_t) = 0$) für X_t ist 0, für $(-1 < \phi < +1)$ ist die Varianz begrenzt:

$$\text{Var}(X_t) = \sigma_Z^2 / (1 - \phi^2) = \sigma_X^2.$$

Berechnet man die ACVF und die ACF, so ergibt sich für den AR-Prozess folgende Eigenschaft. Der AR-Prozess erster Ordnung erfüllt die Bedingungen für die schwache Stationarität, wenn $|\phi| < 1$. Der Verlauf der ACF hängt entscheidend vom Parameter ϕ ab. Für ϕ -Wert zwischen 0 und 1 liegt eine positive Autokorrelation vor. Konvergiert ϕ gegen Null, so nähert sich die Autokorrelation für sehr kleine lags dem Wert 0 an. Je größer ϕ , desto langsamer erfolgt diese Annäherung, das heißt, die weiter zurückliegenden Werte haben noch einen recht großen Einfluss auf den aktuellen X_t Wert.

Nimmt ϕ Werte zwischen -1 und 0 an, so haben wir es mit einer alternierenden Autokorrelationsfunktion zu tun.¹³⁴

Ist der Wert für den Koeffizienten ϕ größer als +1 oder kleiner als -1, dann nimmt der Einfluss vorheriger Werte exponentiell zu. In dieser Hinsicht besteht eine Ähnlichkeit zwischen einem Autoregressiven-Prozess und der exponentiellen Glättung, obwohl sich die Berechnungsalgorithmen grundlegend unterscheiden.

Autoregressiver-Prozess beliebiger Ordnung (AR(p)):

Zur Darstellung des AR-Prozesses mit beliebiger Ordnung p wird direkt die Schreibweise mit dem backward shift operator B verwendet:

$$\begin{aligned} (1 - \phi_1 B - \dots - \phi_p B^p) X_t &= Z_t \quad \Rightarrow \\ X_t &= Z_t / (1 - \phi_1 B - \dots - \phi_p B^p) = \phi(B) Z_t \\ \text{mit } \phi(B) &= (1 - \phi_1 B - \dots - \phi_p B^p)^{-1} = (1 + \theta_1 B + \dots + \theta_p B^p) \\ \Rightarrow X_t &= (1 + \theta_1 B + \dots + \theta_p B^p) Z_t \end{aligned}$$

Auch hier macht man sich die Dualität zwischen AR- und MA-Prozessen zu Nutze. Für X_t in der MA-Gleichung (unterste Gleichung) gilt:

$$E(X_t) = 0 \text{ und die Varianz ist endlich, wenn } \sum_{i=1}^p \theta_i^2 \text{ endlich ist.}$$

Die Formel der Autokorrelationsfunktion wird explizit nicht extra aufgeführt. Nur soviel, die ACF erfüllt die Bedingung der Konvergenz und damit die Stationaritätsbedingung, wenn

$$\sum_{i=1}^p |\theta_i| \text{ die Bedingung auf Konvergenz erfüllt. Die } \theta_i \text{ sind}$$

¹³⁴ Chatfield 1985, 45-47.

aber sehr schwer zu ermitteln. Deutlich einfacher geht die Ermittlung durch das Yule-Walker-Gleichungssystem, die Darstellung des Gleichungssystems findet man zum Beispiel bei Box/Jenkins.¹³⁵

¹³⁵ Box/Jenkins 1970, Kap. 3.2, Mills 1990, Kap. 5.3 und Chatfield 1985, 47-50.

4.4.3 Gemischte ARIMA(p, d, q)-Modelle

Eine wichtige Modellklasse im Bereich der linearen Zeitreihenmodelle ist die Klasse der Autoregressiven-Moving-Average-Modelle (ARMA-Modelle). ARMA-Modelle lassen sich anwenden, wenn die zu analysierende Zeitreihe stationär ist und eine symmetrische Abhängigkeitsstruktur aufweist. Um dies feststellen zu können, sind die im Kapitel 3 ausführlich vorgestellten Identifikationstests notwendig.

Ein allgemeiner Autoregressiver-Moving-Average-Prozess hat die folgende Form:

$$X_t = \varphi_1 X_{t-1} + \dots + \varphi_p X_{t-p} + Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q}$$

mit backward shift operator formuliert: $\varphi(B)X_t = \theta(B)Z_t$

$$\text{mit: } \varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (\text{AR-Teil})$$

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q \quad (\text{MA-Teil})$$

Die Werte der Koeffizienten φ_i und θ_i müssen so ausfallen, dass zum einen die Lösungen für die Funktion $\varphi(B) = 0$ für den AR(p)-Teil und zum anderen die Funktion $\theta(B) = 0$ für den MA(q)-Teil alle außerhalb des Einheitskreises liegen. Ist dies der Fall, dann ist zum einen der AR(p)-Teil stationär und der MA(q)-Teil erfüllt die „invertible“ Bedingung.

Eine der wichtigsten Bedingungen bei der Anwendung der ARMA(p, q)-Modelle ist die Erfüllung der Stationarität der analysierten Zeitreihen. Die meisten ökonomischen Zeitreihen sind aber nicht stationär, sondern besitzen einen Trend. Box und Jenkins schlagen als Lösung die Differenzenbildung der Zeitreihe vor. Die Differenzenbildung soll danach solange durchgeführt werden, bis die Zeitreihe die Bedingung der schwachen Stationarität erfüllt. Den Grad der Differenzierung bezeichnet man auch als Integrationsgrad der Ordnung d. Der ARIMA(p, d, q)-Prozess lautet dann:

$$W_t = \varphi_1 W_{t-1} + \dots + \varphi_p W_{t-p} + Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q}$$

$$\text{mit: } W_t = \Delta^d X_t$$

Bei den ARIMA-Modellen handelt es sich um die Kombination dreier Arten von Zufallsprozessen, wobei es keinen Algorithmus gibt, der die Ordnung eines Modells korrekt spezifizieren kann.¹³⁶ Mit Hilfe von mathematischen Prozeduren lassen sich

¹³⁶ Chatfield 1985, 50-52 und Mills 1990, Kap. 6.3.

lediglich mögliche Modelle bestimmen. Box und Jenkins haben eine Prozedur entwickelt, die zur Findung eines geeigneten Modells in die Schrittfolgen Identifikation, Schätzung und Diagnose unterteilt wird.¹³⁷

Die Schritte Identifikation, Schätzung und Diagnose werden im nächsten Abschnitt ausführlich diskutiert. Dabei spielt die von Box und Jenkins entwickelte Prozedur nur eine geringe Rolle. Vielmehr wird eine Vorgehensweise vorgestellt, die die neueren Erkenntnisse berücksichtigt, praktisch leicht anwendbar und im Modellpaket EViews verfügbar ist.

¹³⁷ Box/Jenkins 1970.

4.5 Vorgehensweise bei der ARIMA-Analyse

Die Analyse linearer Modelle mit Hilfe des Box-Jenkins-Ansatzes wird in drei Analyseschritte unterteilt. Im ersten Schritt wird sich mit der Spezifikation der Ordnung des ARIMA-Modells, im zweiten mit der Schätzung und im dritten mit der Diagnose des geschätzten Modells beschäftigt.

Zuvor wird die Zeitreihe aber graphisch dargestellt, um Hinweise über Ausreißer, Trend, Saison, Wendepunkte, Strukturbrüche etc. zu erhalten. Die ebenfalls vorab durchgeführten Identifikationstests sollten folgende Ergebnisse gebracht haben:

Die Zeitreihe erfüllt die Bedingungen der weichen Stationarität, gegebenenfalls ist eine Transformation erforderlich, die Realisationen sind annähernd normalverteilt, voneinander abhängig und symmetrisch. Erst wenn alle diese Bedingungen hinreichend erfüllt sind, kann ein ARIMA-Modell zur Erklärung der Abhängigkeitsstrukturen verwendet werden.¹³⁸

4.5.1 Spezifikation des Modells

Die Spezifikation des ARIMA-Modells beschäftigt sich mit der Bestimmung der Ordnung des AR(p)-Teils, des MA(q)-Teils und des Differenzengrades d. Der Differenzegrad d ist positiv, wenn die Zeitreihe die Bedingung der Stationarität nicht erfüllt.

Die Sample Autokorrelationsfunktion (SACF) liefert erste wichtige Erkenntnisse über den Grad d der Differenzenbildung. Ein langsamer und fast linearer Rückgang der SACF ist ein erster Indikator für eine nicht stationäre Zeitreihe. Der Grad der Differenzierung lässt sich auf diese Weise aber nicht sicher bestimmen. Zur sicheren Bestimmung des Differenzierungsgrades wird daher der Augmented-Dickey-Fuller-Test auf die Verkaufsdaten der Grossisten angewendet. Eine visuelle Überprüfung der Zeitreihe führt in der Regel nicht zu dem gewünschten Ziel.¹³⁹

Beide Methoden zur Überprüfung des Differenzengrades SACF und ADF-Test wurden im Kapitel 3 „Beschreibung und Identifikation“ schon durchgeführt. Auf diese Ergebnisse wird im Rahmen der Modellbildung nun zurückgegriffen.

¹³⁸ Schmitz 1989, Kap. 4, Pflaumer 1981 und Cromwell/Labys/Terraza 1994, Kap. 6.

¹³⁹ Mills 1990, 120-126.

Für die Bestimmung der Ordnung des Autoregressiven-Teils (AR(p)) und/oder des Moving-Average-Teils (MA(q)) existieren neben dem traditionellen Box-Jenkins-Ansatz, eine Vielzahl weiterer Methoden.

Beim Box-Jenkins-Ansatz werden die Muster der SACF und der SPACF mit den theoretischen Mustern von bekannten Modellen verglichen. Durch diesen Vergleich erhält man die passende Modellordnung.

Neben der SACF und der SPACF kann auch die inverse Autokorrelationsfunktion (IACF) bei der Spezifikation der Ordnung des ARIMA-Modells nützlich sein. Die IACF ist nichts anderes als die ACF des inversen Prozesses:

$IACF(ARMA(p,q)) = ACF(ARMA(q,p))$. Mit Hilfe der IACF lassen sich nicht stationäre autoregressive Prozesse erkennen, denn ihre inverse Autokorrelation weist Merkmale von nicht invertierbaren MA-Prozessen auf.¹⁴⁰

In der Literatur findet man weitere Methoden wie die extendierte Autokorrelation, die Corner-Methode, die Vektorkorrelation, R- und S-array.¹⁴¹

Eine standardisierte und halbautomatische Vorgehensweise zur Spezifikation der Modellordnung bieten die Modellselektionskriterien. Das zur Analyse verwendete Programm EViews 2.0 berechnet bei der Schätzung des spezifizierten ARIMA-Modells die Modellselektionskriterien von Akaike und von Schwarz.¹⁴²

$$\text{Akaike-Informations-Kriterium: } AIC = -\frac{2k}{N} + \log\left(\frac{1}{N} u'u\right)$$

$$\text{Schwarz-Kriterium: } SC = \frac{k \log N}{N} + \log\left(\frac{1}{N} u'u\right)$$

mit: N : Anzahl der Beobachtungswerte
 k : Anzahl der Regressoren
 u'u : Quadratsumme der Residuen

Beide Kriterien verwenden die geschätzte Varianz für den Fehlerterm und bestrafen die zusätzliche Aufnahme von weiteren Parametern. Jenes Modell wird favorisiert, das das gewählte Kriterium minimiert. Hannan hat gezeigt, dass das SC zu konsistenten Ergebnissen führt. Das AIC hingegen neigt zu einer Überparametrisierung.

¹⁴⁰ Schmitz 1989, 76.

¹⁴¹ Schmitz 1989, 78-82 und Mills 1990, 130ff.

¹⁴² Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 160ff.

Dies bedeutet, dass die Strafe durch Aufnahme eines zusätzlichen Parameters zu gering ausfällt.¹⁴³

Mit Hilfe des Modellselektionskriteriums nach Schwarz lässt sich ein Modell-Portfolio aufstellen.

Zuerst werden die Werte des SC für alle Modelle, die eine Ordnung kleiner gleich den vorgegebenen maximalen Koeffizienten p_{\max} und q_{\max} aufweisen, bestimmt. Die Ergebnisse lassen sich gut in Matrixform darstellen. Aus der Matrix wird jenes Modell mit der Ordnung (p_1, q_1) bestimmt, das den minimalsten Wert für das SC besitzt. Mit Hilfe dieses Wertes werden die „posteriori odds ratios“ für jeden Wert der Matrix aufgestellt. Die von Poskitt / Tremayne¹⁴⁴ entwickelte Formel lautet:

$$R = \exp\left[-\frac{1}{2} N \{SC(p_1; q_1) - SC(p; q)\}\right]$$

Poskitt und Tremayne schlagen vor, dass erst bei einem Wert von $R > \sqrt{10}$ das zu prüfende Modell gegenüber dem favorisierten Modell mit der Ordnung (p_1, q_1) verworfen werden kann. Alle Modelle, deren R-Werte zwischen $1 < R < \sqrt{10}$ fallen, bilden ein Modellportfolio.¹⁴⁵

Aus den Modellen, die im Modellportfolio enthalten sind, wird jenes gewählt, das die robustesten Ergebnisse bei der Überprüfung der Modell- und Koeffizientenstabilität, der Residuen und der mittelfristigen Prognose erzielt.

4.5.2 Modellschätzung

Sind der Differenzierungsgrad d und die Ordnung der AR- und MA-Polynome bekannt, steht die Schätzung der Modellparameter an. Die Kleinst-Quadrate-Methode lässt sich auf ARIMA-Modelle nur bedingt anwenden.

Reine AR-Prozesse lassen sich mit Hilfe der Kleinst-Quadrate-Methode bestimmen. Bei einem AR(1)-Prozess stimmt der Schätzer exakt mit jenem überein, den wir erhalten, wenn eine autoregressive Gleichung erster Ordnung mit einem einfachen Regressionsansatz geschätzt wird.

Die Parameter von AR-Prozessen höherer Ordnung als 1 lassen sich durch Substitution der AC-Koeffizienten der Stichprobe in die ersten p Yule-Walker-Gleichungen schätzen.

¹⁴³ Hannan 1980.

¹⁴⁴ Poskitt/Tremayne 1987.

¹⁴⁵ Mills 1990, 140-142.

Die Parameter eines MA-Prozesses lassen sich dagegen nur iterativ ermitteln. Die Kleinst-Quadrate-Methode kann bei MA-Prozessen nicht verwendet werden, da die „residual sum of squares“ keine quadratische Funktion der Parameter ist. Es existieren eine Reihe von iterativen Verfahren, um eine Lösung der Koeffizientenschätzung zu erhalten. Ein mögliches iteratives Verfahren wurde von Box und Jenkins entwickelt. Dabei müssen verschiedene Werte für μ und θ vorgegeben werden. Die Quadratsumme der Residuen wird dann mit den verschiedenen Werten rekursiv berechnet. Man erhält so ein Punktenetz im (μ, θ) -Raum, aus dem sich die Kombination mit der geringsten Quadratsumme ermitteln lässt.¹⁴⁶

Bei einem anderen Schätzverfahren nutzt man die Dualität zwischen AR- und MA-Prozess und passt einen AR-Prozess höherer Ordnung an einen MA-Prozess an.

Die Schätzungen der Parameter eines ARIMA-Modells, bei dem die Ordnung des MA-Terms mindestens 1 beträgt, lassen sich ebenfalls nur iterativ ermitteln.

Genügt der Fehlerterm u einem White-Noise-Prozess, d.h., die u sind unabhängig und NV, dann lässt sich die Likelihoodfunktion zur Schätzung der Parameter aus der NV bestimmen. Die ML-Schätzer sind aber nur selten eindeutig bestimmbar. Die Lösung erfolgt deshalb mit approximativen oder iterativen Verfahren.

Das Programm EViews verwendet den Marquardt-Algorithmus zur Schätzung der Parameter eines AR-, MA- oder ARMA-Prozesses.¹⁴⁷

Bei Wahl der Kleinst-Quadrate-Methode erkennt das Programm selbständig, ob das Gleichungssystem linear oder nichtlinear in den Parametern ist. Ist es linear in den Parametern, so erfolgt die Schätzung nach der voreingestellten Kleinst-Quadrate-Methode. Ist es nichtlinear in den Parametern, wird es automatisch mit dem Marquardt-Algorithmus geschätzt. Nichtlineare Schätztechniken wie der Marquardt-Algorithmus erfordern Startwerte für alle zu schätzenden Modellparameter.

In der Regel braucht man sich um dieses Problem aber nicht zu kümmern, da EViews automatisch Startwerte berechnet. Mit Hilfe der Kleinst-Quadrate-Methode wird eine vorläufige Schätzung des ARMA-Terms vorgenommen. Die ermittelten Parameter werden als Startwerte für die nichtlineare Schätzung verwendet. Man hat aber auch die Möglichkeit, die Voreinstellung zu verändern. Man hat die Wahl, die mit der Kleinst-Quadrat-Methode ermittelten Startwerte mit dem Wert 0,8, 0,5 oder 0,3 zu multiplizieren. Des Weiteren steht die Möglichkeit zur Verfügung, alle Startwerte gleich Null zu setzen. Die Möglichkeit zur Korrektur der Startwerte sollte aber nur dann benutzt werden, wenn der Algorithmus nach der gewählten Anzahl der Iterationen abbricht, ohne eine Lösung gefunden zu haben.

¹⁴⁶ Box/Jenkins 1970, Kap. 7.2.

¹⁴⁷ Vgl. Schlittgen/Streitberg 1989, 196.

Bei jedem Iterationsschritt werden approximativ die partiellen Ableitungen nach jedem zu schätzenden Parameter gebildet. Dann wird überprüft, inwieweit sich die einzelnen Parameter gegenüber den Parametern des vorherigen Iterationsschrittes verändert haben. Die abhängige Variable wird dann auf die Ableitungen regressiert. Die Regression führt zu einem Vektor, der die vorgeschlagenen Änderungen der Parameter enthält. EViews evaluiert die Parameter dann neu, wenn die vorgeschlagenen Änderungen zu einer Reduzierung der Summe der quadratischen Residuen führt. Dieser Prozess wird solange fortgesetzt bis sich die Parameter nicht mehr nennenswert verändern. Das voreingestellte Konvergenzkriterium für die Parameter beträgt 0,001. Falls gewünscht, kann diese Voreinstellung vom Anwender verändert werden.

Auf jeder Iterationsstufe überprüft das Programm, ob durch die neu ermittelten Parameter eine Verbesserung der Modellschätzung eingetreten ist. Überprüft wird dies durch die Summe der quadratischen Abweichung der Residuen („sum of squared residuals“). Ist auf einer höheren Iterationsstufe keine Verbesserung der Summe der quadratischen Residuen möglich, dann sucht das Programm automatisch nach einer Schrittfolge, die zu einer Reduzierung führt. Erst wenn eine solche Schrittfolge nicht zu finden ist, bricht das Programm die Prozedur ab. Im Ausgabenfenster werden die Werte jener Parameter angegeben, bei denen die Iteration abgebrochen wurde.

Bei der Durchführung der nichtlinearen Kleinst-Quadrat-Methode unterstellt das Programm implizit einen additiven Störterm.¹⁴⁸

4.5.3 Diagnose des geschätzten Modells

Die Modellspezifikation führt oft zu einer Reihe alternativer Modelle. Mit Hilfe der Modelldiagnose soll die Qualität der geschätzten Modelle überprüft werden, um das am besten passende Modell auswählen zu können. Erste Hinweise über die Qualität der Modellschätzung liefert das Ausgabeprotokoll, das nach Beendigung der Schätzung ausgegeben wird. (Siehe EViews Menü: „QUICK, ESTIMATE EQUATION (LS)“.)

¹⁴⁸ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, Kap. 8.

LS // Dependent Variable is VERKAUF				
Date: 12/01/99 Time: 13:14				
Sample(adjusted): 1992:02 1996:12				
Included observations: 59 after adjusting endpoints				
Convergence achieved after 16 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	719.671	2498.111	0.288	0.774
AR(1)	0.993	0.001	1093.372	0.000
MA(1)	-0.975	0.038	-25.876	0.000
R-squared	0.681	Mean dependent var		175.542
Adjusted R-squared	0.675	S.D. dependent var		26.839
S.E. of regression	15.297	Akaike info criterion		5.489
Sum squared resid	13338.160	Schwarz criterion		5.559
Log likelihood	-243.632	F-statistic		121.548
Durbin-Watson stat	1.670	Prob(F-statistic)		0.000
Inverted AR Roots	0.99	Estimated AR process is nonstationary		
Inverted MA Roots	0.97			

(EViews 2.0)

Neben Datum, Uhrzeit, Stichprobenzeitraum und -größe gibt der erste Teil des Ausgabeprotokolls Auskunft über die abhängige Variable, die gewählte Schätzmethode und bei iterativen Verfahren über die Anzahl der Iterationsschritte. Das gewählte Verfahren (per Voreinstellung) ist LS (Kleinst-Quadrate-Methode). Da die betrachtete Gleichung aber einen MA-Term enthält, schätzt EViews das Modell automatisch mit dem Marquardt-Algorithmus. Im zweiten Teil des Ausgabeprotokolls werden die geschätzten Koeffizienten angegeben. Die Gleichung setzt sich aus dem deterministischen Teil, hier lediglich die Konstante C, und dem stochastischen Teil, bestehend aus AR- und MA-Teil, zusammen.

Die geschätzte Gleichung für den Verkauf \hat{y} lautet:

$$\hat{y} = 719,671 + 0,993 u_{t-1} - 0,975 e_{t-1}$$

Es gilt: $u_{t-1} = y_{t-1} - 719,671$ (Verkauf minus deterministischen Teil)

$$e_{t-1} = y_{t-1} - \hat{y}_{t-1} \quad (\text{Differenz Verkauf zu geschätztem Verkauf})$$

Zu jedem Koeffizienten gibt EViews den Standardfehler an. Der Standardfehler ist ein Maß für die Reliabilität der geschätzten Koeffizienten. Je größer der Standardfehler, desto größer ist die statistische Unsicherheit über den Wert des Koeffizienten.

Aus dem Verhältnis zwischen Koeffizient und Standardfehler berechnet sich der Wert der T-Statistik. Je größer der Betrag dieses Wertes ist, desto höher ist die statistische Wahrscheinlichkeit, dass der Koeffizient signifikant von Null verschieden ist. Die T-Statistik ist zumindest approximativ normalverteilt, wenn der Stichprobenumfang mindestens 30 Elemente umfasst.

In der rechten Spalte wird die zugehörige Wahrscheinlichkeit für die t-Statistik angegeben. Unterstellt man einen α -Fehler von maximal 5%, dann muss die angegebene Wahrscheinlichkeit kleiner als 5% sein, damit auf die Alternativhypothese, dass der Koeffizient signifikant von Null verschieden ist, entschieden wird.

Im dritten Teil wird die gesamte Schätzung überprüft. Neben dem Bestimmtheitsmaß (R^2) wird das bereinigte Bestimmtheitsmaß (R_A^2) ermittelt. Das bereinigte Bestimmtheitsmaß wird im Programm EViews wie folgt berechnet:

$$R_A^2 = 1 - (1 - R^2) \frac{N - 1}{N - k},$$

mit dem Stichprobenumfang N und der Anzahl der Regressoren k , einschließlich der Konstanten C .

Diese Definition hat sich in der Praxis durchgesetzt. Zwar ist das R_A^2 keine erwartungstreue Schätzfunktion für das Bestimmtheitsmaß der Grundgesamtheit, die Verzerrung ist aber wesentlich geringer als bei R^2 .

Der Vorteil des korrigierten Bestimmtheitsmaßes liegt darin, dass die Aufnahme zusätzlicher Parameter immer mit einer Bestrafung verbunden ist, die nur dann kompensiert werden kann, wenn der zusätzliche Parameter einen deutlichen Beitrag zur Erhöhung des Erklärungsgehalts beiträgt. Mit anderen Worten: Der Nutzen, den die Aufnahme eines weiteren Parameters mit sich bringt, muss den Effekt der Bestrafung kompensieren.¹⁴⁹

Neben der Summe der quadratischen Residuen wird auch der Standardfehler der Regression $S_{N^*-1}^2$ bestimmt. N^* entspricht der Anzahl der Residuen. Für einen einfachen ARMA(1, 1)-Prozess lassen sich zum Beispiel nur $N^* = N - 1$ Residuen bilden.

$$S_{N^*-1}^2 = \sqrt{\frac{1}{N^* - 1} \sum_{t=1}^{N^*} (x_t - x_t^*)^2}$$

mit den Beobachtungswerten x_t und den durch die Schätzung ermittelten Werten x_t^* .

¹⁴⁹ Hübler 1989, 56.

Zur Berechnung der Log-Likelihood-Statistik kommt in EViews folgende Formel zur Anwendung:

$$LL = -\frac{N}{2} \left[1 + \log(2\pi) + \log\left(\frac{u'u}{N}\right) \right]$$

eine sehr ausführliche Erläuterung der Log-Likelihood-Statistik findet man bei Hamilton¹⁵⁰.

Die Durbin-Watson-Statistik misst die Korrelation erster Ordnung. Die Test-Statistik ist definiert auf den Bereich von 0 bis 4. Werte, signifikant kleiner als 2, sind der Beweis für positive Korrelation erster Ordnung, Werte, signifikant größer als 2, für negative Korrelation erster Ordnung. Bei Werten um 2 liegt keine Korrelation erster Ordnung vor, dies ist die Nullhypothese des Tests.

Der Durbin-Watson-Test besitzt in Abhängigkeit vom Stichprobenumfang, der Anzahl der geschätzten Regressoren und dem vorgegebenen Signifikanzniveau zwei Unschärfbereiche. Fällt die Realisation der Testgröße in einen dieser Unschärfbereiche, so kann keine statistisch gesicherte Aussage über das mögliche Vorhandensein der Autokorrelation der Ordnung 1 getroffen werden. Die Testgrenzen sind in vielen statistischen Veröffentlichungen¹⁵¹ und im Anhang dokumentiert.

Im Ausgabeprotokoll folgen dann zwei beschreibende Variablen, das arithmetische Mittel und die Standardabweichung der abhängigen Variablen.

Die daran anschließenden Informationskriterien von Akaike und Schwarz wurden schon unter dem Punkt Modellspezifikation ausführlich behandelt.

Wichtig zur Überprüfung der Robustheit der Schätzung ist der abschließende F-Test. Der F-Test überprüft die Hypothese, dass alle Regressionskoeffizienten mit Ausnahme der Konstante Null sind. Neben der F-Statistik weist EViews auch die zugehörige Wahrscheinlichkeit aus. Ist die ausgewiesene Wahrscheinlichkeit kleiner als der vorgegebene α -Fehler, dann wird die Hypothese, dass alle Regressionskoeffizienten Null sind, verworfen.

Der vierte Teil im Ausgabeprotokoll wird nur dann ausgewiesen, wenn die Überprüfung der Einheitswurzel sinnvoll ist. In dem gewählten Beispiel wird die invertierte Einheitswurzel des AR- und des MA-Prozesses angegeben. Im vorliegenden Ausgabeprotokoll ist die Meldung aufgeführt, dass der geschätzte AR-Prozess nicht die Stationaritätsbedingung erfüllt. Es kann nicht ausgeschlossen werden, dass der AR-Schätzer auch Werte größer gleich 1 annimmt und somit ein Random-Walk- oder sogar ein explosiver Prozess vorliegt.¹⁵²

¹⁵⁰ Hamilton 1994, 296-298.

¹⁵¹ Judge/Hill/Griffiths/Lütkepohl/Lee 1988, Charemza/Deadman 1993 und Kanji 1993.

¹⁵² Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, Kap. 7. u. 8.

Neben dem Ausgabeprotokoll der Modellschätzung bietet das Programm EViews eine Vielzahl von zusätzlichen diagnostischen Testverfahren, die in drei Kategorien eingeteilt werden: Koeffizienten-Tests, Residuen-Tests und Stabilitäts-Test.

„The tests available as views of an equation are:“

1) *„Coefficient Tests“*

- *Wald test of coefficient restrictions*
- *Omitted variables*
- *Redundant variables“*

2) *„Residual tests“*

- *Correlograms and Q-statistics*
- *Histogram and normality test*
- *Serial correlation LM test*
- *ARCH LM test*
- *White's heteroskedasticity test without cross terms*
- *White's heteroskedasticity test with cross terms“*

3) *„Specification and Stability Tests“*

- *Chow's breakpoint test*
- *Chow's forecast test*
- *Ramsey's RESET test*
- *Recursive estimates*
 - Recursive residuals*
 - CUSUM test*
 - CUSUM of squares test*
 - One-step forecast test*
 - N-Step forecast test*
 - Recursive coefficients*

In addition, some other tests you may want to use are discussed elsewhere in the User's Guide. There are the ADF and Phillips-Perron tests for unit roots“, „the Granger causality test“, „and the Johansen test for cointegration“.¹⁵³

¹⁵³ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 215-216.

Die Tests werden nur sehr kurz vorgestellt. Dabei beziehen sich die Ausführungen in erster Linie auf die Darstellungen im EViews User's Guide, Kapitel 10. An den wenigen Stellen, an denen auf weiterführende Literaturquellen verwiesen wird, werden diese auch explizit angegeben.

4.5.3.1 Koeffiziententests

Koeffiziententests behandeln die Restriktionen von Variablen, ausgelassenen Variablen und Variablen, deren Bedeutungen gegenstandslos sind.¹⁵⁴

1) Wald-Test („Wald test of coefficient restrictions“):

Mit dem Wald-Test lassen sich mehrere Restriktionen der Variablen simultan prüfen. Die Restriktionsgleichungen können sowohl linear als auch nichtlinear sein. Bei linearen Restriktionsgleichungen genügt die Prüfgröße einer F-Verteilung, bei nichtlinearen Restriktionsgleichungen muss approximativ auf die χ^2 -Verteilung als Verteilung der Prüfgröße zurückgegriffen werden.

2) Test auf ausgelassene Variablen („Omitted variables“):

Dieser Test ermöglicht die Überprüfung von zusätzlichen Variablen, die in das Gleichungsmodell aufgenommen werden können. Dabei wird geprüft, ob eine Variable einen signifikanten Erklärungsbeitrag leistet oder nicht. Der Output des Tests liefert neben der F-Statistik auch die Likelihood-Ratio-Statistik.

3) Test auf Freisetzung von Variablen („Redundant variables“):

Im Gegensatz zum Test auf ausgelassene Variablen wird getestet, ob eine Variable oder eine Teilmenge von Variablen keinerlei Einfluss auf die Modellschätzung ausübt und somit aus der Gleichung entfernt werden kann.

¹⁵⁴ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 216-221.

4.5.3.2 Residuen-Tests

Der Überprüfung der Residuen kommt eine ganz besondere Bedeutung zu. Ihre Identifikation liefert wichtige Hinweise über die Qualität der Schätzung. Neben den in EViews unter dem Untermenü aufgeführten Residuen-Tests werden die im Kapitel 3.3 vorgestellten Identifikationstests auf die Residuen angewandt. Die Residuen sollten stationär, normalverteilt und unabhängig sein. Darüber hinaus bietet EViews die folgenden Testmöglichkeiten:¹⁵⁵

1) Korrelogramme und Q-Statistik:

Neben der ACF und der PACF werden die Werte der Ljung-Box Q-Statistik berechnet und zusätzlich deren Wahrscheinlichkeiten. Die gesamte Prozedur kann auch für die quadrierten Residuen durchgeführt werden. Die Residuen sollten dabei keine signifikant von Null abweichenden Werte aufweisen.

2) Histogramm und Normalverteilungstest:

Die Verteilung der Residuen wird in Form eines Histogrammes dargestellt. Die Hypothese der Normalverteilung der Residuen lässt sich somit visuell überprüfen. Zusätzlich werden die Werte für Schiefe, Wölbung und die Jarque-Bera-Statistik berechnet.

3) LM-Test auf Korrelation in der Zeitreihe:¹⁵⁶

Der LM-Test ist eine Alternative zur Ljung-Box Q-Statistik sowie zu den Korrelogrammen der ACF und PACF. LM-Test und Q-Statistik testen beide die Korrelation der Residuen bis zu einem maximal vorgegeben lag k .

Der LM-Test wurde unabhängig voneinander von Breusch und Godfrey zur Überprüfung von autokorrelierten Störungen entwickelt

(z. B.: $u_t = \phi_1 u_{t-1} + \phi_2 u_{t-2} + \dots + \phi_k u_{t-k} + \varepsilon_t$).

Dabei ist es egal, ob die Störung einem AR- oder MA-Prozess genügt. Der Störvektor u ist dabei additiver Bestandteil eines linearen Modells $y = X\beta + u$, das auch verzögerte Variablen enthalten kann.

In der Nullhypothese wird dabei getestet, ob der Störvektor u einer $NV(0, \sigma_u^2 I)$ genügt. Sind die einzelnen Störterme NV , so bedeutet dies zugleich, Unabhängigkeit der einzelnen Störungen und damit keinerlei signifikante Korrelationen für beliebige lags k mit $k > 0$.

Als Alternativhypothesen kommen zwei Hypothesen in Frage, die aber dieselbe Teststatistik besitzen.

¹⁵⁵ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 222-224.

¹⁵⁶ Johnston 1987, 319-321 und Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 184-185.

Wurden die u_t aus einem AR-Prozess erzeugt, so lautet die Alternativhypothese:

$$H_1: u_t + \phi_1 u_{t-1} + \dots + \phi_k u_{t-k} = \varepsilon_t$$

Ist der erzeugende Prozess hingegen ein MA-Prozess, so ergibt sich die folgende Alternativhypothese: $H_1: u_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_k \varepsilon_{t-k}$

Vereinfachte Teststatistik: $\ell = T \cdot R^2 \sim \chi^2(k)$

mit: T = Anzahl der Beobachtungswerte
 R^2 = Bestimmtheitsmaß

Unter dem Menü „RESIDUAL TEST / SERIAL CORRELATION LM TEST“ muss im Programm EViews die höchste Ordnung des AR- oder MA-Prozesses, die zur Beschreibung der Serienkorrelation nötig ist, spezifiziert werden. Für den LM-Test lassen sich zwei Prüfgrößen bestimmen, eine F-Statistik und eine χ^2 -Statistik. Beide testen die Hypothese, dass die Koeffizienten aller verzögerten Residuen Null sind.

Die exakte Verteilung der F-Statistik ist nicht bekannt. Die Verteilung der χ^2 -Statistik ist asymptotisch $\chi^2(k)$ verteilt. Der EViews Output gibt beide Statistiken mit den entsprechenden Wahrscheinlichkeiten an. In der Nullhypothese wird getestet, dass alle verzögerten Residuen Null sind. Diese Behauptung kann erst verworfen werden, wenn die angegebenen Wahrscheinlichkeiten der F-Statistik und der χ^2 -Statistik kleiner als die maximale Wahrscheinlichkeit für den vorgegebenen α -Fehler sind.

EViews verfügt über weitere Residuen-Tests, die sich mit dem Phänomen der Heteroskedastie der Residuen beschäftigen. Unter dem Menüpunkt „RESIDUEN TEST“ findet man neben dem ARCH-LM-Test, den White's Heteroskedasticity-Test unterteilt in cross terms und no cross terms. Diese Tests kommen natürlich nur dann zur Anwendung, wenn die Residuen aller Wahrscheinlichkeit nach dem Phänomen der Heteroskedastie unterliegen. Da dieses Problem bei den vorliegenden Zeitreihen nur eine untergeordnete Rolle spielt, werden die Residuen der Zeitreihen lediglich mit Hilfe graphischer Methoden auf Heteroskedastie untersucht.¹⁵⁷

¹⁵⁷ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 222-224.

4.5.3.3 Spezifikations- und Stabilitätstests

Mit dieser Gruppe von Tests lässt sich die Spezifikation und die Stabilität des geschätzten Modells überprüfen. EViews verfügt über drei Typen von Spezifikations- und Stabilitätstests:¹⁵⁸

- 1) Chow-Tests¹⁵⁹: Sie überprüfen die Stabilität der Beziehung für unterschiedliche Zeiträume oder für unterschiedliche Stichproben bei Querschnittsdaten.
- 2) Ramsey-Reset-Test: Ist ein allgemeiner Test auf Fehlspezifikation des Modells durch Überprüfung der Variablen, des funktionellen Zusammenhangs und der Modellannahmen.
- 3) Rekursive Schätzmethoden: Diese Tests geben Auskunft über die Entwicklung der geschätzten Modellparameter, wenn die Stichprobe um weitere Beobachtungen vergrößert wird.

zu 1) Chow's Vorhersage- und Strukturbruchtest:

Dabei wird die Stichprobe in zwei Teile unterteilt. N_1 Beobachtungswerte dienen zur Schätzung des Modells. Mit den restlichen $N_2 = N - N_1$ Beobachtungswerte wird der Chow-Test durchgeführt.

Bei Verwendung aller zur Verfügung stehenden Beobachtungswerte wird zwar die beste Modellanpassung erzielt, eine Überprüfung der Vorhersagequalität, der Konstanz der Parameter und der Stabilität (Robustheit) ist damit aber nicht mehr möglich.

Als Vorschlag zur Unterteilung der Beobachtungswerte in zwei Stichproben verwendet man bei der empirischen Arbeit folgende Faustregel: 85-90% der Beobachtungsdaten sollten zur Schätzung und 10-15% zur Validierung verwendet werden.

- Chow's Vorhersagetest:

Die ersten N_1 -Beobachtungswerte werden dazu genutzt, die restlichen N_2 -Werte vorherzusagen. Die Größe des Vektors der Differenzen zwischen vorhergesagten und beobachtbaren Werten stellt ein Maß für die Qualität der Schätzung dar.

Die Nullhypothese beim Chow-Vorhersagetest lautet: Die vorhergesagten Werte stammen von demselben Modell ab wie die Werte der geschätzten Gleichung. In der Prüfgröße wird der realisierte Vorhersagefehler der Varianz gegenübergestellt, die bei Gültigkeit der Nullhypothese zu erwarten wäre.

Als Output gibt EViews die Prüfgrößenwerte und die dazugehörigen Wahrscheinlichkeiten der F-Statistik und der LR-Statistik an.

¹⁵⁸ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 224-235.

¹⁵⁹ Weiterführende Literatur: Chow 1960.

$$\text{F-Statistik: } F = \frac{\frac{\tilde{u}'\tilde{u} - u'u}{q}}{\frac{u'u}{N - k}}$$

$\tilde{u}'\tilde{u}$: Summe der quadratischen Abweichungen, wenn die Gleichung aus allen N Beobachtungswerten angepasst wurde.

$u'u$: Summe der quadratischen Abweichungen, wenn die Gleichung aus N_1 Werten angepasst wird.

Die Chow-Vorhersagetests lassen sich auf Modelle anwenden, die mit Hilfe der Kleinst-Quadrate- oder der zweistufigen Kleinst-Quadrate-Methode geschätzt wurden.

- Chow's Strukturbruchtest:

Beim Strukturbruchtest werden die Daten in zwei oder mehr Gruppen unterteilt. Die Anzahl der Beobachtungswerte in jeder Gruppe muss größer als die Anzahl der zu schätzenden Koeffizienten in der Gleichung sein. Dabei wird getestet, dass sich die Vektoren der Koeffizienten aller Untergruppen nicht signifikant voneinander unterscheiden.

Zu diesem Zweck wird für jede Untergruppe die Koeffizientengleichung ermittelt. Die „unbeschränkte“ Summe der quadrierten Residuen berechnet sich aus der Addition der Summe der quadrierten Residuen jeder Untergruppe. In der Prüfgröße wird die „unbeschränkte“ mit der „beschränkten“ Summe der quadrierten Residuen verglichen. Die „beschränkte“ Summe der quadrierten Residuen wird aus der Schätzung über alle Beobachtungswerte ermittelt.

Auch bei diesem Test gibt EViews den Wert der F-Statistik und der LR-Statistik an. Die F-Statistik basiert auf dem Vergleich zwischen beschränkter und unbeschränkter Summe der quadratischen Residuen. Die LR-Statistik berechnet sich aus dem beschränkten und unbeschränkten Maximum der Likelihood-Funktion.

Auch dieser Test lässt sich auf Modellschätzungen anwenden, die mit Hilfe der Kleinst-Quadrate- oder zweistufiger Kleinst-Quadrate-Methode erfolgen.

zu 2) Ramsey's Reset-Test

Die folgenden Spezifikationsfehler lassen sich mit dem Ramsey's Reset-Test überprüfen:

- Weggelassene Variablen (Das Modell enthält nicht alle relevanten Variablen).
- Falscher Funktionstyp (evtl. sollten einige oder sogar alle Variablen y und X transformiert werden).
- Korrelation zwischen X und ε (Ursache können sein: Messfehler in den Variablen X , simultane Gleichungssysteme, Kombinationen von verzögerten Variablen und Serienkorrelation im Störterm).

Liegen derartige Spezifikationsfehler vor, dann führt die Kleinst-Quadrate-Schätzung zu verzerrten und inkonsistenten Ergebnissen. Ramsey zeigte, dass alle genannten Typen von Spezifikationsfehlern zu einem Vektor ε führen, dessen Erwartungswert signifikant von Null abweicht.¹⁶⁰

Null- und Alternativhypothese lauten:

$$H_0: \varepsilon \sim NV(0, \sigma^2 I)$$

$$H_1: \varepsilon \sim NV(\mu, \sigma^2 I), \mu \neq 0$$

Der Test basiert auf einer erweiterten Regressionsgleichung: $y = X\beta + Z\alpha + \varepsilon$

Der Spezifikationsfehler lässt sich durch Untersuchung von α überprüfen. Bei der Durchführung des Tests ist die entscheidende Frage, welche Variablen in der Z-Matrix enthalten sind.

- Im Falle von ausgelassenen Variablen gibt es mit der Ausgestaltung der Matrix Z keine Probleme. Die ausgelassenen Variablen bilden die Z-Matrix. Durch Testen der Hypothese $\alpha = 0$ wird der Einfluss der ausgelassenen Variablen auf das Modell ermittelt. Weicht α signifikant von Null ab, so besitzen die ausgelassenen Variablen einen signifikanten Einfluss.
- Bei Tests auf inkorrektter Funktionsform wird der weggelassene Teil der Regression als Funktion der Regressoren X formuliert ($Z = f(X)$).

Beim Ramsey-Reset-Test gibt EViews ebenfalls die Werte der F- und der LR-Statistik an. Die Nullhypothese lautet dabei, dass die Koeffizienten von Z nicht signifikant von Null verschieden sind.

In einer 1984 veröffentlichten Studie haben Ramsey und Alexander¹⁶¹ gezeigt, dass der Reset-Test Spezifikationsfehler in einer Gleichung aufdecken kann, wo a priori schon bekannt war, dass eine Fehlspezifikation vorlag, aber alle traditionellen Tests zu einer Modellannahme geführt hatten.

Dieser Test lässt sich nur auf Gleichungssysteme anwenden, die nach der Kleinst-Quadrate-Methode geschätzt wurden.

¹⁶⁰ Ramsey 1969, 350-371.

¹⁶¹ Ramsey/Alexander 1984, 347-356.

zu 3) Rekursive Kleinst-Quadrate-Tests

Bei der Anwendung der rekursiven Kleinst-Quadrate-Methode werden die Gleichungen mehrmals geschätzt. Nach jeder Schätzung wird die Stichprobe um den nächsten Beobachtungswert erweitert. Sind k Koeffizienten des Koeffizientenvektors b zu schätzen, so benötigt man für die erste Schätzung die ersten k Beobachtungswerte. Für jede Schätzung wird ein weiterer Beobachtungswert aufgenommen. Man erhält so $N - k$ Schätzungen für den Koeffizientenvektor b .

Mit X_{t-1} wird der Vektor $t-1$ der Matrix k der Regressoren bezeichnet. Die Periodenlänge beträgt dabei 1 bis $t-1$. Y_{t-1} stellt den entsprechenden Vektor der Beobachtungswerte der abhängigen Variablen dar. Die Kleinst-Quadrate-Methode angewandt auf die obigen Variablen liefert den geschätzten Koeffizientenvektor b_{t-1} . Der Koeffizientenvektor ermöglicht die Vorhersage der Werte der abhängigen Variablen für die Periode t . Vorhersage: $x'_t b_{t-1}$, wobei x'_t der Vektor der Beobachtungen der Regressoren in Periode t ist.

Definition

Vorhersagefehler: $\varepsilon_t = y_t - x'_t b_{t-1}$

Rekursive Residuen: $w_t = \frac{y_t - x'_t b_{t-1}}{\sqrt{1 + x'_t (X'_{t-1} X_{t-1})^{-1} x_t}}$

Die Residuen lassen sich berechnen für $t = k+1, \dots, N$.

Bei Gültigkeit des behaupteten Modells sind die rekursiven Residuen unabhängig und normalverteilt mit Erwartungswert Null und konstanter Varianz.

Die rekursiv berechneten Residuen werden zum Testen von strukturellen Modelländerungen verwendet.

Das Programm EViews verfügt über sechs verschiedene Plots, die hier nicht einzeln vorgestellt werden. Die Berechnung dieser Plots ist nur möglich, wenn die Schätzung nach der Kleinst-Quadrate-Methode durchgeführt wurde. Das Modell muss dabei frei von AR- und MA-Termen sein.¹⁶²

¹⁶² Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 230-235.

4.6 Regressionsansatz mit ARMA-Term zur Beschreibung der Störgröße

Ausgangspunkt bildet das klassische Regressionsmodell. Eine der Grundannahmen dieses Modells ist die Unkorreliertheit in der Störgröße. Verwendet man den Regressionsansatz aber in der Zeitreihenanalyse, so ist gerade die Annahme der Unkorreliertheit oft verletzt. Betrachtet man die Störgröße als Anzahl ausgelassener Variablen, so ist die Autokorrelation als recht wahrscheinlich anzusehen. Folgt man dieser Argumentation, dann ist es vernünftig, die Störgröße mit einem ARMA(p; q)-Modell zu beschreiben.

In einer Studie von Harvey und McAvinchey¹⁶³ wurden verschiedene Schätzverfahren mittels Monte-Carlo-Experimenten miteinander verglichen. Das untersuchte Modell lautete:

$$y_t = \beta_1 + \beta_2 x_t + u_t$$

Wobei u durch einen AR(1)-Prozess generiert wird und zwei Formen für die erklärende Variable x_t betrachtet wurden. Die erste Form für x_t bestand aus einem exponentiell wachsenden Trend mit der Zeit t und die zweite aus einer Variable x_t , die zufällig verteilt und stationär ist. Das Modell in seinen beiden Varianten wurde mit vier verschiedenen Verfahren geschätzt: Kleinst-Quadrate (1), Cochrane-Orcutt (2), Iteratives Cochrane-Orcutt (3), vollständige Transformation (4).

Ein Ergebnis der Studie soll besonders hervorgehoben werden. In kleineren Stichproben führte die Kleinst-Quadrate-Methode bei trendbehafteten Daten zu sehr guten Ergebnissen. Die Leistungsfähigkeit fällt aber deutlich geringer aus, wenn die Daten stationär sind.

Die oben benutzte AR(1)-Störgröße ist in ihrer Wirksamkeit aber begrenzt, auch wenn mit Hilfe der DW-Statistik auf eine signifikante Autokorrelation der Ordnung 1 entschieden wird. Besonders für saisonbehaftete Daten oder zyklische Effekte kommt es zu schlechten Schätzergebnissen.

Bei Monatsdaten kann die serielle Korrelation zum Beispiel durch einen AR(12)- Störterm modelliert werden.

Bei der Verwendung eines Regressionsansatzes, bei dem der strukturelle Teil der Gleichung korrekt spezifiziert werden kann, sollte man für den Störterm einen ARMA(p, q)-Prozess in Betracht ziehen. Wie letztendlich die Ordnung des ARMA(p, q)-Prozesses ausfällt, hängt vom Verlauf der ACF und der PACF, der um den

¹⁶³ Vgl. Harvey/McAvinchey 1978.

strukturellen Teil bereinigten Zeitreihe ab. Als Entscheidungskriterium wird die Stabilität der geschätzten Koeffizienten und der Wert des Schwarz-Kriteriums benutzt.

Allgemein lässt sich sagen, dass erstens die Aggregation von Variablen generell zu einem ARMA-Prozess führt und zweitens, dass jeder stochastische Prozess durch ein sparsames ARMA-Modell angemessen wiedergegeben werden kann.¹⁶⁴

Die vorgestellten Regressionsmodelle mit ARMA(p; q)-Störterm gehören zur Klasse der statischen Modelle, das heißt, die erklärenden Variablen sind zum Prognosezeitpunkt t schon bekannt.

Bei vielen statistischen Fragestellungen kennt man die Werte der erklärenden Variablen aber nicht zum Zeitpunkt t. Die Lösung findet man in der Modellierung dynamischer Modelle. Ein Möglichkeit zur Modellierung dynamischer Modelle bietet das Konzept der adaptiven Erwartungen. Harvey führt dazu das folgende Beispiel an. Geschätzt werden soll eine landwirtschaftliche Angebotsfunktion, bei der die Menge y vom Preis x abhängt. Ein Landwirt muss eine Entscheidung darüber treffen, ob er eine bestimmte Frucht anbaut und wie groß die mögliche angebaute Menge y_t werden soll, ohne den tatsächlich zu erzielenden Preis für den Absatz des Produktes zu kennen. Folglich wird der Landwirt die Produktion auf der Basis des für die nächste Periode zu erwarteten Preises x_{t+1}^* planen.

Es gilt: $y_t = \beta x_{t+1}^* + u_t$

Der Wert für x_{t+1}^* ist nicht bekannt, folglich muss eine Hypothese formuliert werden, die die Erwartungen adäquat ausdrückt. Eine Möglichkeit besteht in der Formulierung einer adaptiven Erwartung, das heißt, dass der Entscheidungsträger seine Erwartungen auf der Basis der Differenz zwischen der Prognose des Wertes der Periode t und dem tatsächlich realisierten Wert revidiert: $x_{t+1}^* = x_t^* + \gamma(x_t - x_t^*)$, mit $0 < \gamma < 1$

Der Parameter γ drückt aus, in welchem Umfang auf die Diskrepanz zwischen Prognose und tatsächlichem Wert zum Zeitpunkt t reagiert wird.

Eine andere Möglichkeit der Modellierung von dynamischen Modellen stellt das Konzept des partiellen Anpassungs-Mechanismus (partial adjustment) dar. Die meisten ökonomischen Sachverhalte reagieren mit Verzögerungen auf Veränderungen, die Anpassungen sind vielfach nur in partiellen Teilschritten möglich. Zum Beispiel verändert sich das Konsumverhalten von Personen nicht schlagartig, wenn die Person ein höheres Einkommen erhält. Vielmehr passt sich das Konsumverhalten recht langsam dem höheren Einkommen an. Modellieren lässt sich der Sachverhalt mit einer Reaktionsfunktion:¹⁶⁵

¹⁶⁴ Harvey 1994, Kap. 6.

¹⁶⁵ Harvey 1994, 233-236.

$$y_t = y_{t-1} + \gamma(y_t^* - y_{t-1}) + u_t \quad \text{mit} \quad y_t^* = \beta x_t \quad \text{und} \quad 0 < \gamma < 1$$

x_t : Einkommen zum Zeitpunkt t

y_t^* : Gewünschtes Konsumniveau zum Zeitpunkt t

y_t : Konsum zum Zeitpunkt t

Der Konsum erreicht in der folgenden Periode nur ein Teil des Optimums, die Anpassungsgeschwindigkeit wird durch den Parameter γ bestimmt.

4.7 Analyse saisonaler Zeitreihen

4.7.1 Einführung in die saisonale Zeitreihenanalyse

In diesem Kapitel wird zuerst eine Definition von Saisonalität vorgestellt. Danach werden einige Hilfsmittel zur Erkennung saisonaler Schwankungen beschrieben. Den Schluss in diesem einführenden Kapitel bildet die Vorstellung zweier kontroverser Konzepte, der SARIMA-Modelle und der unbeobachtbaren Komponentenmodelle.

Definition von Saisonalität

Franses beschreibt eine Reihe von saisonalen Beobachtungswerten wie folgt:

*„A seasonally observed time series is a time series that is regularly observed during a time interval that is shorter than a year. It can relate to quarterly and monthly observations as well as hourly or daily observations.“*¹⁶⁶

Nicht alle saisonal beobachtbaren Zeitreihen weisen tatsächlich saisonale Schwankungen auf.

Eine ausführlichere Definition wählte Hyllberg. Er präzisiert die Gründe für saisonale Schwankungen. Diese Definition wird von anderen Autoren wie zum Beispiel Franses ebenfalls favorisiert:

*„Seasonality is the systematic, although not necessarily regular, intra-year movement caused by changes of the weather, the calendar, and timing of decisions, directly or indirectly through the production and consumption decisions made by the agents of the economy. These decisions are influenced by the endowments, the expectations and the preferences of agents, and the production techniques available in the economy.“*¹⁶⁷

In dieser Definition finden sich sowohl die deterministischen als auch die stochastischen Aspekte von saisonalen Schwankungen wieder. Die deterministischen Aspekte sind zum Beispiel Kalendereffekt wie Anzahl der Werkzeuge pro Monat oder jahreszeitliche Effekte wie Frühjahr, Sommer, Herbst und Winter. Die eher stochastischen Aspekte liegen im Verhalten der ökonomisch handelnden Personen und der ökonomischen Rahmenbedingungen. Für die untersuchte Zeitschrift ergibt sich damit die Fragestellung, inwieweit saisonale Schwankungen auf Kalendereffekt und jahreszeitlichen Effekt zurückzuführen sind oder inwieweit das Kaufverhalten beeinflusst wird durch heftspezifische Effekte, das Verhalten der Einzelheftkäufer, den Entscheidungen von Verlagen, Grossisten und Einzelhändlern. Fragestellungen, wie

¹⁶⁶ Franses 1996, 32.

¹⁶⁷ Hyllberg 1992, 4.

stark der Verkauf durch die gesamtwirtschaftliche Situation, dem Freizeit- und Leseverhalten der potentiellen Leser oder der Konkurrenzsituation beeinflusst werden, sollten zusätzlich analysiert werden.

Diese Fragestellungen führen automatisch zu der Schlussfolgerung, dass die saisonalen Schwankungen nicht konstant über die Zeit sein können. Die Stärke aber auch der Zeitpunkt des Auftretens der angeführten Effekte von saisonalen und anderen Schwankungen werden über den betrachteten Zeitraum mehr oder weniger starken Veränderungen unterworfen sein.¹⁶⁸

Hinweise auf saisonale Schwankungen lassen sich recht gut graphisch erkennen. Dabei sind verschiedene Darstellungsformen denkbar. Eine Möglichkeit wäre die Darstellung der absoluten Verkaufswerte über den betrachteten Zeitraum, eine andere die Darstellung von relativen Verkaufswerten (z.B. als Indexwerte). Sehr nützlich zur Erkennung von saisonalen Effekten zum Beispiel für Monatsdaten ist die Betrachtung der Verkaufswerte getrennt nach den einzelnen Monaten Januar bis Dezember. Für jeden Monat wird im Zeitverlauf eine eigene Verlaufskurve geplottet.

4.7.2 Saisonale Anpassung und SARIMA-Modelle

Den Verfahren der saisonalen Anpassung liegt die Annahme zugrunde, dass die Saisonalität eine Form von Datenverschmutzung darstellt, die entfernt werden sollte, um eine Analyse zu ermöglichen. Im Rahmen dieses Konzepts lässt sich eine saisonale Zeitreihe in die unbeobachtbaren Komponenten wie Trend, zyklische Schwankungen und Saison zerlegen.

Franses nennt drei Beispiele für Methoden, mit denen die saisonalen Fluktuationen von Zeitreihen erfasst werden können.

Die erste Methode ist die Regression einer Zeitreihe als Funktion der Zeit.

Die zweite Methode ist die Filterung der saisonalen Schwankungen durch eine Folge von Moving-Average-Filtern (Gleitende Durchschnitte). Die Moving-Average-Filter kommen zum Beispiel in der Census X-11 Methode zur Anwendung.

Die dritte, für die weitere Vorgehensweise sehr wichtige Methode, ist die Klasse der saisonalen ARIMA-Modelle, sie impliziert die Betrachtung der verschiedenen unbeobachtbaren Komponenten, einschließlich der saisonalen Komponente.

¹⁶⁸ Franses 1996, 33.

Franses betrachtet in seinem 1996 erschienenen Buch „Periodicity and Stochastic Trends In Economic Time Series“ die Darstellung des stochastischen Trends in saisonalen Zeitreihen als einen Schlüsselpunkt zur Analyse saisonaler Zeitreihen. Ein falsches Trendmodell führt automatisch zu falschen zyklischen Verläufen.

Bei der Zerlegung von Zeitreihen in die beiden Komponenten saisonal und nicht saisonal, kann je nach Datenlage, die Zusammensetzung der Komponenten additiv oder multiplikativ erfolgen. Dabei können die folgenden Kombinationen auftreten:¹⁶⁹

- Trend und Saison sind beide deterministische Größen.
- Stochastischer Trend und deterministische Saison.
- Stochastischer Trend und stochastische Saison.

Die Klasse von ARIMA-Modellen wurde zuvor schon ausführlich dargestellt. Ihre Konzeption lässt sich auch auf Zeitreihen mit saisonalen Schwankungen übertragen, da in saisonalen Zeitreihen die einzelnen Beobachtungswerte mit den entsprechenden saisonalen Werten des Vorjahres eine hohe Abhängigkeit aufweisen.

Die so entstehenden Modelle bezeichnet man als SARIMA-Modelle. Auf die theoretische Darstellung wird im Rahmen dieser Arbeit nur kurz eingegangen. Das theoretische Konzept geht auf die grundlegenden Arbeiten von Box und Jenkins¹⁷⁰ zurück.

Weitere Erläuterungen findet man bei Franses¹⁷¹, Chatfield¹⁷², Granger/Newbold¹⁷³, Hylleberg¹⁷⁴, Mills¹⁷⁵.

Die Gleichung beschreibt das allgemeine multiplikative Saisonmodell für Monatsdaten ($S = 12$).

SARIMA(p, d, q) (P, D, Q)_{S=12}-Prozess:

$$\phi_p(B) \phi_P(B^{12}) W_t = \theta_q(B) \vartheta_Q(B^{12}) Z_t$$

¹⁶⁹ Franses 1996, 49-50.

¹⁷⁰ Box/Jenkins 1970.

¹⁷¹ Franses 1996, Kap. 3.2.

¹⁷² Chatfield 1985, Kap. 4.6.

¹⁷³ Granger/Newbold 1986, Kap. 3.7.

¹⁷⁴ Hylleberg 1986, Kap. 7.

¹⁷⁵ Mills 1990, Kap. 10.2-10.3.

$$\begin{aligned}
\text{mit: } \quad \varphi(B) &= 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p && \text{(AR-Teil)} \\
\theta(B) &= 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q && \text{(MA-Teil)} \\
\phi(B) &= 1 - \phi_{1,S} B^S - \phi_{2,S} B^{2S} - \dots - \phi_{P,S} B^{PS} && \text{(SAR-Teil)} \\
\vartheta(B) &= 1 + \vartheta_{1,S} B^S + \vartheta_{2,S} B^{2S} + \dots + \vartheta_{Q,S} B^{QS} && \text{(SMA-Teil)}
\end{aligned}$$

$\varphi_p, \phi_P, \theta_q, \vartheta_Q$ sind Polynome der Ordnung $p, P, q,$ und Q . Die Polynome lassen sich sehr einfach durch den „backward shift operator“ B darstellen. Für Z_t handelt es sich um einen reinen Zufallsprozess mit Erwartungswert Null und konstanter Varianz über die Zeit t . Die Zufallsvariable W_t erhält man durch Differenzenbildung der Zeitreihe X_t , dabei wird zwischen nicht saisonaler und saisonaler Differenzenbildung unterschieden.

$$\text{Es gilt: } W_t = \Delta^d \Delta_S^D X_t$$

mit: Δ^d : nicht saisonale Differenzenbildung der Ordnung $d \in \mathbb{N}_0$

Δ_S^D : saisonale Differenzenbildung der Ordnung $D \in \mathbb{N}_0$

und $S = 12$ für Monatsdaten

Die SARIMA-Modelle bestehen aus zwei getrennten Zeitreihenmodellen. Ein Teil für die saisonalen und der andere für die nicht saisonalen Schwankungen. Auch beim SARIMA-Modell lässt sich unter Umständen durch Vergleich von theoretischer mit empirischer ACF bzw. PACF die Modellordnung identifizieren. Praktisch ist die Identifikation aber recht schwierig, da eine riesige Anzahl von typischen ACF und PACF denkbar sind.

Zusätzlich ist bei nicht stationären Zeitreihen eine Entscheidung über die Ordnung der Differenzen des Modells zu treffen, was die Komplexität der Modelle nochmals erhöht.

Die Box-Jenkins SARIMA-Methode liefert vernünftige Modelle zur Beschreibung von saisonalen Schwankungen in ökonomischen Zeitreihen, wenn die Zeitreihe keinerlei Trend enthält und somit stationär ist. Zur Trendbereinigung wird die Differenzenbildung verwendet mit dem Filter Δ^d , in der Regel mit $d = 1$. Für saisonale Daten bietet sich der Differenzen-Filter Δ_S^D an. Auch bei diesem Filter genügt in der Regel eine Differenzenbildung der Ordnung $D = 1$. Neben der Beseitigung der stochastischen Saison bereinigt dieser Filter zum Teil auch den stochastischen Trend. Die mögliche Doppeldifferenzierung $\Delta^d \Delta_S^D$ von saisonalen Zeitreihen sollte mit Bedacht eingesetzt werden, da die Gefahr der Überdifferenzierung des stochastischen Trends besteht. Nur wenn der Trend nichtlinear ist, dann ist zusätzlich zur saisonalen Differenzenbildung Δ_S^D die einfache Differenzenbildung Δ^d notwendig.¹⁷⁶

¹⁷⁶ Charemza/Deadman 1993, 129.

Ein in vielen Analysen verwendetes Modell ist das „Airline-Modell“. Es wurde 1970 erstmals von Box und Jenkins auf einen Datensatz aus der zivilen Luftfahrt (Meilen der weltweiten Airline-Passagiere pro Monat für die Periode 1951-1960) angewandt und liefert für viele Untersuchungen ökonomischer saisonaler Zeitreihen gute Ergebnisse. Es handelt sich um ein SARIMA (0, 1, 1) (0, 1, 1)_s Modell.¹⁷⁷

$$\Delta^1 \Delta_S^1 x_t = (1 - B)(1 - B^S) x_t = (1 + \theta_1 B)(1 + \vartheta_{1,S} B^S) \varepsilon_t$$

Der Hauptgrund für die häufige Verwendung liegt in der recht einfachen Identifikation des Modells.¹⁷⁸ Die Autokorrelationsfunktion der doppelt differenzierten Zeitreihe $W_t = \Delta^1 \Delta_S^1 X_t$ besitzt signifikant von Null abweichende Werte lediglich für lag 1, S-1, S und S+1.

Das Airline-Modell weist aber ein theoretisches Problem auf. Die saisonale Differenzenbildung $(1 - B)^S$ geht von der Annahme aus, dass die saisonale Fluktuation durch einen saisonalen stochastischen Trend generiert wird, wenn gilt: $\vartheta_{1,S} \neq -1$.

Zum Beispiel: $(1 - B^S) x_t = \varepsilon_t$ mit x_{-j} (für $j = 0, 1, 2, \dots, S$)

$$\Rightarrow y_t = \varepsilon_t + \varepsilon_{t-S} + \varepsilon_{t-2S} + \dots$$

Dies impliziert, dass bestimmte Schocks eine permanente Änderung im saisonalen Muster verursachen können.

Eine Alternative zum Airline-Modell besteht in der Verwendung einer deterministischen Saison, generiert durch Dummies, als Ersatz für den saisonalen stochastischen Trend.

ARIMA(p, d, q) mit saisonalen Dummies $D_{S,t}$:

$$\varphi_p(B)(1 - B)^d x_t = \sum_{s=1}^S \delta_s D_{S,t} + \theta_q(B) \varepsilon_t$$

¹⁷⁷ Box/Jenkins 1970 und Franses 1996, 41-42.

¹⁷⁸ Eine Vielzahl von Autoren verwendeten das Airline Modell in ihren statistischen Untersuchungen ökonomischer Zeitreihen, zum Beispiel: Nelson 1973, Kap. 7, Abraham/Ledolter 1983, Kap. 6 und Granger/Newbold 1986, Kap. 3.

Ob dieses Modell vernünftig ist, kann anhand der ACF und PACF der differenzierten Zeitreihe $(1 - B)^d x_t$ überprüft werden. Zuvor muss aber eine Regression zur Bestimmung der Koeffizienten der saisonalen Dummies durchgeführt und die Zeitreihe um den deterministischen saisonalen Effekt, falls erforderlich auch um die Differenzenbildung, bereinigt worden sein.¹⁷⁹

¹⁷⁹ Franses 1996, 41-42.

4.7.3 Stationarität von saisonalen Zeitreihen

Die Untersuchung der Stationarität ist bei saisonalen Zeitreihen wesentlich komplexer als bei nicht saisonalen Zeitreihen.

Box und Jenkins stellten als eine Lösung zur Erzielung der Stationarität die Doppeldifferenzenbildung vor (z.B. für Monatsdaten: $\Delta^1 \Delta_{12}^1$, d.h. einfache Differenz erster Ordnung und einfache saisonale Differenz von 12 Monaten).

Für viele saisonale Zeitreihen erzielt man durch saisonale Differenzenbildung mit der Periodenlänge s schon eine stationäre Reihe. Vorsicht ist aber angebracht, wenn der Trend einen nichtlinearen Verlauf besitzt. Die saisonale Differenzenbildung führt in diesem Fall nicht zur Entfernung des Trends. In einem solchen Fall sollte die Doppeldifferenzierung als mögliche Lösung des Stationaritätsproblems berücksichtigt werden.¹⁸⁰

Definition einer saisonal integrierten Zeitreihe:¹⁸¹

„Definition: A nonstationary series is said to be seasonally integrated of order(d, D), denoted $SI_S(d, D)$, if it can be transformed to a stationary series by applying s -differences D times and then differencing the resulting series d times using first differences.“

Die Definition wird im folgenden zur Beschreibung der Integrationsgrade von saisonalen Zeitreihen verwendet. Die Länge der Saison S beträgt zum Beispiel für Quartalsdaten $S = 4$ und für Monatsdaten $S = 12$.

¹⁸⁰ Franses 1996, 61.

¹⁸¹ Charemza/Deadman 1993, 129.

Tests zur Überprüfung der Ordnung der saisonalen und/oder nicht saisonalen Integration

Für Zeitreihen mit stochastischen saisonalen Schwankungen lassen sich, analog dem im Kapitel 3.3.2 vorgestellten ADF-Test zur Bestimmung des nicht saisonalen Differenzengrades d , Tests zur Identifikation des saisonalen Differenzengrades D formulieren. Auch bei diesen Tests spielt das Einheitswurzelkonzept eine zentrale Rolle.

In diesem Abschnitt werden die theoretischen Aspekte der verschiedenen saisonalen Einheitswurzeltests kurz vorgestellt und zu einer Vorgehensweise fokussiert, die sich auf die praktische Analyse der Zeitreihen der Verkaufszahlen übertragen lässt. Als Basisliteratur dienen dabei die Autoren Charmeza/Deadman¹⁸² und Franses¹⁸³, ergänzt durch diverse andere Autoren.

Der einfachste Test, der DHF-Test, wurde 1984 von Dickey, Hasza und Fuller entwickelt. Er ähnelt einer Verallgemeinerung des ADF-Tests.

Der DHF-Test prüft in der Nullhypothese die Existenz der Einheitswurzeln gegen die Alternativhypothese, dass keine Einheitswurzel vorliegt. Für Quartalsdaten werden zum Beispiel vier Einheitswurzeln auf ihre Existenz geprüft, eine nicht saisonale und drei saisonale. Dieses Ergebnis lässt sich auch auf Zeitreihen mit monatlichen Beobachtungswerten übertragen. Analog wird dann die Existenz von 12 Einheitswurzeln getestet.

Eine überdifferenzierte Zeitreihe erhält man zum Beispiel, wenn der einfache Differenzenfilter $(1-B)$ schon eine stationäre Zeitreihe ergibt, und wenn die Saisonalität mit saisonalen Dummies erfasst werden kann. Überdifferenzierung verkompliziert die Konstruktion von univariaten Zeitreihen, da das Muster der PACF in diesem Fall kaum noch zu interpretieren ist. Des Weiteren können Schätzprobleme auftreten, da bei der Verwendung von MA-Polynomen ein Teil der Einheitswurzeln auf dem Einheitskreis liegen.

Bei Unterdifferenzierung hingegen erhält man zu wenig Einheitswurzeln im autoregressiven Teil. Die Gefahr besteht darin, dass falsche Beziehungen zwischen zwei univariaten Zeitreihen auftreten, wenn relevante saisonale Einheitswurzeln nicht berücksichtigt werden.

Für eine Zeitreihe, die S Beobachtungswerte pro Jahr aufweist, basiert der Test für den Parameter δ in der Regressionsgleichung auf der Student T-Statistik.:

¹⁸² Charmeza/Deadman 1993, 136ff.

¹⁸³ Franses 1991, 199-208 und Franses 1996, Kap.5.

$$SI_S(0,1): \Delta_S^1 y_t = \delta z_{t-S} + \sum_{i=1}^k \delta_i \Delta_S^1 y_{t-i} + \varepsilon_t \quad (a)$$

Zuerst regressiert man $\Delta_S^1 y_t$ auf seine eigenen Werte zurück ($\Delta_S^1 y_t = y_t - y_{t-S}$), verzögert um k Perioden. Daraus folgt: $\Delta_S^1 y_t = \sum_{i=1}^k \lambda_i \Delta_S^1 y_{t-i} + \xi_t$.

Danach werden die Parameter $\lambda_1, \lambda_2, \dots, \lambda_k$ mit Hilfe der Kleinst-Quadrate-Methode geschätzt, um im nächsten Schritt die Variable z_t aus $y_t, y_{t-1}, \dots, y_{t-k}$ zu konstruieren. Es gilt:

$$z_t = y_t - \sum_{i=1}^k \hat{\lambda}_i y_{t-i} \quad \left(\text{Umgeformt: } z_t = (1 - \hat{\lambda}_1 B - \hat{\lambda}_2 B^2 \dots - \hat{\lambda}_k B^k) y_t \right)$$

Zum Schluss substituiert man den verzögerten Wert z_{t-s} in der Ausgangsgleichung (a), schätzt die Gleichung und berechnet den Wert der Student-t Statistik für δ .

Die kritischen Werte für den Test findet man zum Beispiel bei Dickey, Hasza und Fuller¹⁸⁴.

Liefert die Schätzung von δ einen signifikant negativen Wert, so wird die Nullhypothese, dass ein saisonaler integrierter Prozess vorliegt, verworfen und auf die Alternativhypothese entschieden. Das bedeutet, dass keine stochastische Saisonalität vorliegt, die durch Berechnung von S -Differenzen entfernt werden könnte. Der mögliche Grad der nicht saisonalen Differenzenbildung zur Erreichung der Stationarität muss aber noch überprüft werden. Als Testverfahren wurde dazu der ADF-Test schon ausführlich vorgestellt.

Wenn die Nullhypothese für den Test von $SI_S(0,1)$ nicht abgelehnt wird, so bedeutet dies aus statistischer Sicht nicht, dass die saisonale Differenzenbildung erster Ordnung $SI_S(0,1)$ schon zu einer stationären Zeitreihe führt. Bevor man die Ordnung der saisonalen Differenzen erhöht, sollten die verschiedenen nicht-saisonalen Differenzen geprüft werden. Das heißt, man würde nun $SI_S(1,1)$ testen.

Bei ökonomischen Daten mit saisonaler Struktur erwartet man in der Regel, dass die Integration die folgende Ordnung aufweist: $SI_S(0,0)$, $SI_S(0,1)$ und $SI_S(1,1)$.

Für die Vorgehensweise zur Erzielung von Stationarität bei saisonalen Zeitreihen bedeutet dies, dass zuerst $SI_S(0,0)$ überprüft wird. Dazu verwendet man den ADF-Test. Kommt es dabei zu einer Nicht-Ablehnung der Nullhypothese, so wird $SI_S(0,1)$ getestet. Führt dieser Test wiederum zu einer Nicht-Ablehnung der Nullhypothese, so testet man $SI_S(1,1)$. Sind weitere Tests mit höherer Ordnung notwendig, so sollten nur noch die nicht saisonale Differenz erhöht werden $SI_S(d,1)$. Dabei ist zu beachten, dass sich Differenzen mit einer Ordnung größer als 2 kaum noch interpretieren lassen.

¹⁸⁴ Dickey/Hasza/Fuller 1984, 355-367.

Die Ausgangsgleichungen für die Tests lauten dann:

$$SI_S(1,1): \Delta^1 \Delta_S^1 y_t = \delta \Delta_S y_{t-1} + \sum_{i=1}^k \delta_i \Delta^1 \Delta_S^1 y_{t-i} + \varepsilon_t$$

$$SI_S(2,1): \Delta^2 \Delta_S^1 y_t = \delta \Delta^1 \Delta_S^1 y_{t-S} + \sum_{i=1}^k \delta_i \Delta^2 \Delta_S^1 y_{t-i} + \varepsilon_t$$

Zu beachten ist weiterhin, dass die konstruierte Variable z_t beim DHF Test nur bei der saisonalen Integration zur Anwendung kommt. Für die Tests auf nicht saisonale Integration benötigt man z_t nicht.¹⁸⁵

Der DHF-Test lässt sich recht gut vereinfachen. Dabei wird die konstruierte Variable $z_{t,S}$ ersetzt durch $y_{t,S}$.

Wird unterstellt, dass alle Parameter δ_i Null sind, dann erhält man den Dickey-Fuller-Seasonal-Integration-Test (DFSI-Test).

$$\Delta_S^1 y_t = \delta y_{t-S} + \varepsilon_t$$

Andernfalls erhält man den Augmented-Dickey-Fuller-Seasonal-Integration-Test (ADFSI-Test).

$$\Delta_S^1 y_t = \delta y_{t-S} + \sum_{i=1}^k \delta_i \Delta_S^1 y_{t-i} + \varepsilon_t$$

Die kritischen Werte für den DFSI- und den ADFSI-Test sind identisch. Man darf aber nicht vergessen, dass die beiden letzten Tests nur eine Vereinfachung darstellen und damit eine recht grobe Approximation.¹⁸⁶

Zur Überprüfung der Frage, ob der von Box-Jenkins erstmals vorgeschlagene Doppel-Differenzenfilter (Airline-Modell) zu einer geeigneten Entfernung des stochastischen Trends führt, entwickelte Osborn 1988 am Beispiel von Quartalsdaten einen eigenen methodischen Testansatz. Er verwendet folgende Hilfsregression zur Überprüfung der saisonalen Stationarität:

$$\phi_k(B) \Delta^1 \Delta_4^1 y_t = \sum_{s=1}^4 \delta_s D_{S,t} + \beta_1 \Delta_4^1 y_{t-1} + \beta_2 \Delta^1 y_{t-4} + \varepsilon_t$$

mit $\phi_k(B)$ einem Polynom mit der Ordnung k und einer saisonalen Dummy Variable $D_{S,t}$.

¹⁸⁵ Charemza/Deadman 1993, 139ff.

¹⁸⁶ Charemza/Deadman 1993, 319-333.

Die Regression kann dabei für Zeitreihen mit deterministischem Trend oder saisonalem deterministischen Trend durchgeführt werden.

Es gilt:

- 1) $\beta_1 = 0$ und $\beta_2 < 0 \Rightarrow$ Stationärer Prozess durch Verwendung des Δ_1 Filters
- 2) $\beta_1 < 0$ und $\beta_2 = 0 \Rightarrow$ Stationärer Prozess durch Verwendung des Δ_4^1 Filters
- 3) $\beta_1 = 0$ und $\beta_2 = 0 \Rightarrow$ Stationärer Prozess durch Verwendung des $\Delta_1 \Delta_4^1$ Filters
- 4) $\beta_1 < 0$ und $\beta_2 < 0 \Rightarrow$ Stationärer Prozess ohne Differenzenfilter

Die kritischen Werte für die relevanten t- und F-Statistiken der Hilfsregression findet man bei Osborn¹⁸⁷ und für eine erweiterte Version bei Franses/Koehler¹⁸⁸.

Anhand der beschreibenden Hilfsregression überprüfte Osborn viele ökonomische Zeitreihen auf ihren möglichen Differenzegrad ($\Delta^1 \Delta_S^1$). Er gelang zu dem Ergebnis, dass es keinen klaren Beweis dafür gab, dass die Doppeldifferenzierung notwendig sei. Bei vielen saisonalen Zeitreihen reicht der saisonale Differenzenfilter Δ_S^1 aus, um den stochastischen Trend aus einer saisonalen Zeitreihe y_t zu entfernen. Eine solche Zeitreihe bezeichnet man als saisonal integriert.¹⁸⁹

Tests auf saisonale Integration und stochastischer Saisonalität sind äquivalent zueinander. Die einfachste Form stochastischer Saisonalität liegt vor, wenn die saisonale Differenz stationär ist oder wenn der Prozess wie folgt beschrieben werden kann: $y_t = y_{t-S} + \varepsilon_t$ oder $\Delta_S^1 y_t = \varepsilon_t$ mit ε_t als unabhängige Zufallsvariable.

Ein solcher Prozess weist ein saisonales Muster auf, das sich mit der Zeit verändert. Diese Betrachtungsweise steht im Kontrast zur deterministischen Saisonalität.

Der prinzipielle Unterschied zwischen den beiden Konzepten liegt in der Betrachtung von Schocks. In deterministischen saisonalen Modellen sterben die Schocks mit der Zeit aus. In stochastischen saisonalen Modellen haben sie hingegen einen permanenten Effekt. Charemza und Deadman interpretieren deterministische Saisonalität als einfache Approximation der stochastischen Saisonalität.¹⁹⁰

Welches dieser beiden Konzepte letztendlich am besten auf die vorliegenden Daten passt, sollte man eingehend überprüfen. Dabei gibt es recht hilfreiche Testverfahren, die einen guten Einblick in die Struktur der Daten erlauben, so dass eine Entscheidung für eines der beiden Konzepte mit guter Sicherheit getroffen werden kann.

¹⁸⁷ Osborn 1990, 327-336.

¹⁸⁸ Franses/Koehler 1994.

¹⁸⁹ Osborn/Chui/Smith/Birchenhall 1988, 361-377.

¹⁹⁰ Charemza/Deadman 1993, 140.

Eine Testmethode, die eine Entscheidung zwischen den beiden Konzepten ermöglicht, wurde 1990 von Hylleberg, Engle, Granger und Yoo vorgeschlagen (HEGY-Test).

$$\Delta_4^1 y_t = (1 - B^4) y_t = \sum_{i=1}^4 \delta_S D_{S,t} + \sum_{i=1}^4 b_i y_{i,t-1} + \sum_{i=1}^k c_i \Delta_4^1 y_{t-i} + \varepsilon_t \quad \text{mit:}$$

k: Anzahl der verzögerten Terme

$D_{S,t}$: Saisonale Dummy Variablen

$y_{i,t}$: Die Variablen werden wie folgt konstruiert:

$$y_{1,t} = (1 + B)(1 + B^2) y_t = y_t + y_{t-1} + y_{t-2} + y_{t-3}$$

$$y_{2,t} = -(1 - B)(1 + B^2) y_t = -y_t + y_{t-1} - y_{t-2} + y_{t-3}$$

$$y_{3,t} = -(1 - B)(1 + B) y_t = -y_t + y_{t-2}$$

$$y_{4,t} = -(B)(1 - B)(1 + B) y_t = y_{3,t-1} = -y_{t-1} + y_{t-3}$$

$$\text{Es gilt: } 1 - B^4 = (1 - B)(1 + B)(1 + B^2) = (1 - B)(1 + B)(1 - iB)(1 + iB)$$

Das Modell wird nach der Kleinst-Quadrate-Methode geschätzt. Für eine stochastische Saisonalität würde man sich entscheiden, wenn die Koeffizienten δ_i alle denselben Wert besitzen und die Koeffizienten b_i alle gleich Null sind. Weisen hingegen die Koeffizienten δ_i alle verschiedene Werte auf und einer der b_i Werte ist signifikant von Null verschieden, dann geht man von einer Kombination zwischen deterministischer und stochastischer Saisonalität aus. Jeder negative b_i Wert besitzt eine eigene Interpretation. Zum Beispiel, wenn lediglich b_1 negativ ist, dann liegt keine nicht saisonale stochastische stationäre Komponente in der Zeitreihe vor. Ist hingegen lediglich b_2 negativ, dann liegt kein halbjährlicher Zyklus vor. Die Koeffizienten b_3 und b_4 hängen beide mit dem jährlichen Zyklus zusammen und werden daher gemeinsam getestet. Die kritischen Werte für diesen Test findet man bei Hylleberg.¹⁹¹

¹⁹¹ Hylleberg/Engle/Granger/Yoo 1990, 215-238 und Charemza/Deadman 1993, 140-142.

Beaulieu und Miron¹⁹² sowie Franses¹⁹³ haben diesen Test auf Monatsdaten übertragen. Die Testversion von Franses wird auf den nächsten Seiten ausführlich vorgestellt, dabei werden zwei verschiedene Modellansätze gegeneinander getestet.

Beim ersten Modell (von Franses mit MSBJ bezeichnet) wurden die Zeitreihenwerte durch die Verwendung des Doppeldifferenzenfilters $\Delta^1 \Delta_{12}^1$ bereinigt. Dieser Modellansatz geht auf das 1970 von Box und Jenkins vorgestellte Airline-Modell zurück.

Dem wird ein ARMA-Modell (von Franses mit FSDS bezeichnet) gegenübergestellt, dessen Zeitreihenwerte lediglich durch die Differenz erster Ordnung Δ_1 bereinigt wurden und bei dem die Saisonalität durch elf saisonale Dummies plus einer Konstante erfasst wurden.

Franses stellt eine Testmethode dar, die es ermöglicht, aus den beiden alternativen Modellen das passende zu selektieren. Die Überprüfung der Ergebnisse erfolgt auf zwei Arten, zum einen empirisch und zum anderen durch Simulation.

In einer empirischen Studie hat Osborn aufgezeigt, dass das Problem der Überdifferenzierung bei Modellen mit Doppeldifferenzierung (MSBJ) des öfteren eintritt.¹⁹⁴

Der Differenzenfilter Δ_{12}^1 unterstellt die Präsenz von 12 Einheitswurzeln, die sich mit Hilfe des lag-operators B herleiten lassen.

Franses entwickelte eine Testprozedur, die es erlaubt, aus den beiden Modellen den jeweils optimalen Differenzenfilter zu bestimmen. Getestet wird dabei, ob man zur Erzielung eines stationären Prozesses den Doppeldifferenzenfilter benötigt oder ob der einfache Differenzenfilter vollkommen ausreichend ist.

Es gilt:

$$\begin{aligned} \Delta_{12}^1 &= 1 - B^{12} = (1 - B)(1 + B)(1 - iB)(1 + iB) \\ &\quad \times \left[1 + (\sqrt{3} + i)B / 2 \right] \left[1 + (\sqrt{3} - i)B / 2 \right] \\ &\quad \times \left[1 - (\sqrt{3} + i)B / 2 \right] \left[1 - (\sqrt{3} - i)B / 2 \right] \\ &\quad \times \left[1 + (i\sqrt{3} + 1)B / 2 \right] \left[1 - (i\sqrt{3} - 1)B / 2 \right] \\ &\quad \times \left[1 - (i\sqrt{3} + 1)B / 2 \right] \left[1 + (i\sqrt{3} - 1)B / 2 \right] \end{aligned}$$

¹⁹² Beaulieu/Miron 1993, 305-328.

¹⁹³ Franses 1991, 199-208.

¹⁹⁴ Osborn 1990, 327-336.

Der Test baut auf die folgende Hilfsregression, dabei wird die Äquivalenz zwischen der Signifikanz der Regressionsparameter und den Einheitswurzeln genutzt.

$$\varphi^*(B) y_{8,t} = \pi_1 y_{1,t-1} + \pi_2 y_{2,t-1} + \pi_3 y_{3,t-1} + \pi_4 y_{3,t-2} + \pi_5 y_{4,t-1} + \pi_6 y_{4,t-2} + \pi_7 y_{5,t-1} + \pi_8 y_{5,t-2} \\ + \pi_9 y_{6,t-1} + \pi_{10} y_{6,t-2} + \pi_{11} y_{7,t-1} + \pi_{12} y_{7,t-2} + \mu_t + \varepsilon_t$$

ε_t : White-Noise-Prozess wird unterstellt

μ_t : Deterministischer Teil, je nach Datenlage Konstante, Trend und/oder saisonale

Dummies

$\varphi^*(B)$: Polynomiale Funktion des „lag operators“ B, wobei gilt:

$$y_{1,t} = (1+B)(1+B^2)(1+B^4+B^8)y_t \\ y_{2,t} = -(1-B)(1+B^2)(1+B^4+B^8)y_t \\ y_{3,t} = -(1-B^2)(1+B^4+B^8)y_t \\ y_{4,t} = -(1-B^4)(1-\sqrt{3}B+B^2)(1+B^2+B^4)y_t \\ y_{5,t} = -(1-B^4)(1+\sqrt{3}B+B^2)(1+B^2+B^4)y_t \\ y_{6,t} = -(1-B^4)(1-B^2+B^4)(1-B+B^2)y_t \\ y_{7,t} = -(1-B^4)(1-B^2+B^4)(1+B+B^2)y_t \\ y_{8,t} = (1-B^{12})y_t$$

Die Nebenrechnung der Regressionsgleichung erfolgte mit EViews 2.0. Die Gleichungen mussten dazu transformiert werden. Die folgenden Umformungen gingen in die Regressionsgleichung ein:

$$y_{1,t} = y_t + y_{t-1} + y_{t-2} + y_{t-3} + y_{t-4} + y_{t-5} + y_{t-6} + y_{t-7} + y_{t-8} + y_{t-9} + y_{t-10} + y_{t-11} \\ y_{2,t} = -y_t + y_{t-1} - y_{t-2} + y_{t-3} - y_{t-4} + y_{t-5} - y_{t-6} + y_{t-7} - y_{t-8} + y_{t-9} - y_{t-10} + y_{t-11} \\ y_{3,t} = -y_t + y_{t-2} - y_{t-4} + y_{t-6} - y_{t-8} + y_{t-10} \\ y_{4,t} = -y_t + \sqrt{3}y_{t-1} - 2y_{t-2} + \sqrt{3}y_{t-3} - y_{t-4} + y_{t-6} - \sqrt{3}y_{t-7} + 2y_{t-8} - \sqrt{3}y_{t-9} + y_{t-10} \\ y_{5,t} = -y_t - \sqrt{3}y_{t-1} - 2y_{t-2} - \sqrt{3}y_{t-3} - y_{t-4} + y_{t-6} + \sqrt{3}y_{t-7} + 2y_{t-8} + \sqrt{3}y_{t-9} + y_{t-10} \\ y_{6,t} = -y_t + y_{t-1} - y_{t-3} + y_{t-4} - y_{t-6} + y_{t-7} - y_{t-9} + y_{t-10} \\ y_{7,t} = -y_t - y_{t-1} + y_{t-3} + y_{t-4} - y_{t-6} - y_{t-7} + y_{t-9} + y_{t-10} \\ y_{8,t} = y_t - y_{t-12}$$

Bevor die eigentliche Regressionsgleichung nach der Kleinst-Quadrate-Methode berechnet werden kann, müssen die Gleichungen $y_{1,t}$ bis $y_{8,t}$ ermittelt werden.

Besitzt die Reihe Einheitswurzeln, dann muss der entsprechende Koeffizient π_i den Wert Null aufweisen. Aufgrund der Tatsache, dass Paare von komplexen Einheitswurzeln konjugiert sind, sollte beachtet werden, dass eine Einheitswurzel nur dann vorhanden ist, wenn das Paar π_i gleichzeitig Null ist. Zum Beispiel sind die Einheitswurzeln von i und $-i$ nur dann präsent, wenn beide π_3 und π_4 den Wert Null aufweisen. (Detaillierte Herleitung siehe Franses¹⁹⁵). Es gibt keine saisonale Einheitswurzel, wenn alle Koeffizienten π_2 bis π_{12} signifikant von Null verschieden sind.

Besitzt lediglich der Koeffizient π_1 den Wert Null, dann kann die Präsenz von der ersten Einheitswurzel nicht verworfen werden.

Gilt $\pi_1 = 0$ und π_2 bis π_{12} sind signifikant von Null verschieden und lässt sich zusätzlich die Saisonalität mit saisonalen Dummies modellieren, dann sollte das FSDS-Modell verwendet werden.

Sind hingegen alle Koeffizienten nicht signifikant von Null verschieden, dann ist es vernünftiger den Δ_{12} Filter zur Erfassung der Saisonalität zu verwenden und ein MSBJ-Modell wäre zu bevorzugen.

Mittels 5000 Monte-Carlo-Simulationen hat Franses die kritischen Grenzen für die t -Prüfgrößen ermittelt. Der Test für die beiden ersten Koeffizienten ist ein linksseitiger Test. Die übrigen 10 Koeffizienten werden mittels zweiseitiger Tests überprüft. Zusätzlich hat Franses die kritischen Werte für den F-Test, für Paare von π_i Werten berechnet und für den multiplen Test der Koeffizienten π_3 bis π_{12} .

Franses testet die beiden Methoden in seinen Ansatz an der Entwicklung der Flugpassagierzahlen, dem Industrieproduktionsindex der Niederlande und den Pkw-Registrationszahlen in den Niederlanden. Er kommt dabei zu den Ergebnissen, dass der Δ_{12}^1 -Filter und insbesondere der $\Delta^1 \Delta_{12}^1$ -Filter nicht geeignet sind, die Zeitreihen vernünftig zu beschreiben.¹⁹⁶

Diese Ergebnisse decken sich mit den Untersuchungen von Osborn¹⁹⁷ und Beaulieu/Miron¹⁹⁸. Bei der sich anschließenden Modellentwicklung zur Beschreibung und Prognose der Zeitschriftenverkäufe werden diese Erkenntnisse berücksichtigt.

¹⁹⁵ Franses 1990.

¹⁹⁶ Franses 1991, 199-208.

¹⁹⁷ Osborn 1990, 327-336.

¹⁹⁸ Beaulieu/Miron 1993, 305-328.

5 Modellentwicklung

Im ersten Schritt der Modellentwicklung erfolgt eine grobe Einteilung der Zeitreihen jedes einzelnen Grossisten in sieben verschiedene Klassen. Als Entscheidungsgrundlage zur Einteilung werden die graphischen Darstellungen der Verkaufszahlen sowie die Korrelogramme der ACF und der PACF der Verkaufszahlen verwendet.

Die Prüfung der Zeitreihen auf Stationarität, Normalverteiltetheit und Unabhängigkeit schließt sich im zweiten Schritt an.

Danach werden im dritten Schritt Modelle zur Beschreibung und Prognose der Abverkäufe entwickelt, interpretiert und kritisch analysiert.

Zusätzlich zu den entwickelten Modellen wird eine Prognose der Verkaufszahlen mit den Verfahren der exponentiellen Glättung vorgenommen und den entwickelten Modellen zum Vergleich gegenübergestellt.

5.1 Beschreibung und Identifikation des gesamten Datensatzes

Im Kapitel 3 wurden die wichtigsten Verfahren und Tests zur Identifikation von Zeitreihen vorgestellt. In diesem Abschnitt erfolgt die Analyse der Verkaufszahlen einer Special Interest Zeitschrift. Von den insgesamt 91 westdeutschen Grossisten konnten 87 analysiert werden. Nicht analysiert wurden die Grossisten: DPV Düsseldorf, Richter Essen, NPV Bayreuth und Trunk München. Ihre Verkaufszahlen enthielten Datenfehler (wie negative Verkaufswerte) oder starke Sprünge, da es im Analysezeitraum zum Zusammenschluss mit anderen Grossegebieten gekommen war. Zum Beispiel wies der Grossist Richter die Verkaufszahlen der Grossegebiete Essen und Leichlingen nicht mehr getrennt aus.

Mitte 1997 wurde für alle Grossisten ein Teil der ISPC Verkaufsmeldungen auf Datenträger zur Verfügung gestellt. Der Datensatz besteht aus den Variablen: Anzahl der eingeschalteten Einzelhandelsgeschäfte, Anzahl der Einzelhandelsgeschäfte mit Nullverkauf, Anzahl der Einzelhandelsgeschäfte mit Ausverkauf, Gesamtbezug der Einzelhandelsgeschäfte mit Nullverkauf und Gesamtbezug der Einzelhandelsgeschäfte mit Ausverkauf. Die folgende Tabelle enthält exemplarisch den Datensatz für den Grossisten Lütkemeyer Münster.

Jahr/Monat	Bezug	Verkauf	Bezug Nullverkauf	Bezug Ausverkauf	Einzelhd. Nullverkauf	Einzelhd. Ausverkauf	Einzelhd. eingeschaltet
92/01	550	265					
92/02	550	306					
92/03	550	276					
:	:	:					
:	:	:					
93/07	500	282					
93/08	500	275	53	105	29	45	144
93/09	500	304	38	127	22	60	146
93/10	500	290	44	123	29	54	153
93/11	500	231	69	81	31	35	141
93/12	500	267	46	76	27	37	146
:	:	:	:	:	:	:	:
:	:	:	:	:	:	:	:
96/10	500	237	62	68	33	36	148
96/11	550	246	77	49	33	30	153
96/12	550	238	69	45	29	28	150
97/01	550	307					
97/02	500	280					
97/03	470	243					
97/04	470	257					

Die Bezugs- und Verkaufszahlen wurden vom Verlag zur Verfügung gestellt und die übrigen Daten von dem Zeitschriftenvertriebsunternehmen IPV, das seit Mitte 96 mit dem Vertrieb des untersuchten Objektes beauftragt ist. Der Verlag lieferte die Bezugs- und Verkaufszahlen für 64 Ausgaben von Januar 1992 bis einschließlich April 1997. Die IPV Verkaufsmeldungen konnten für die meisten Grossisten von August 1993 bis Dezember 1996 rekonstruiert werden. Bei einigen Grossisten sind die Angaben aber nur noch unvollständig vorhanden. Aus Platzgründen wird auf die Darstellung der restlichen 90 Datenmatrizen verzichtet.

Die Datenmatrizen wurden in Excel bearbeitet und dann per Datentransfer in das Programm EViews geladen. Für jeden Grossisten wurde ein eigenes „Workfile“ angelegt, das die verschiedenen Variablen, aber auch die Ergebnisse der Identifikationstests und die entwickelten Modelle enthält.

Im ersten Schritt der Analyse erfolgt die Betrachtung der Verkaufszahlen jedes einzelnen Grossisten. Dazu werden die Verkaufszahlen aller Grossisten einzeln geplottet und zusätzlich die Korrelogramme der ACF und der PACF berechnet. Anhand der Graphen der Verkaufszahlen und deren Korrelogramme erfolgt eine erste grobe Sortierung der Grossisten. Dabei lassen sich die folgenden groben Klassifizierungen herausstellen:

Klasse	Graph	Korrelogramme (lag 1 bis 25)
1	Reiner Zufallsprozess, keinerlei systematische Strukturen lassen sich erkennen.	Für keine lags weisen die ACF und PACF signifikante Abweichungen von Null auf.
2	Vermutlich reiner Zufallsprozess, keinerlei systematische Strukturen lassen sich erkennen.	Einzelne lags der ACF- und PACF-Werte sind signifikant von Null verschieden.
3	Systematische Strukturen lassen sich nicht erkennen	Signifikant von Null verschiedene AC- und PAC-Werte für lag 1; teilweise geringe Signifikanz auf lag 12 der ACF.
4	Deutlicher Trendverlauf	Hohe Werte der ACF und PACF für lag 1, Werte der ACF nehmen mit zunehmendem lag ab. Bei einigen Zeitreihen liegt ein geringer Ausschlag auf lag 12 der ACF vor.
5	Sehr starke Saisonfigur	Die Saisonfigur spiegelt sich im Verlauf der ACF wider. PACF weist sehr hohe Werte für lag 1 auf.
6	Saisonverlauf	Leichte signifikante Ausschläge auf lag 1 der ACF und der PACF. Deutlich stärkere Ausschläge auf lag 12 der ACF und PACF.
7	Saisonverlauf	Deutlich signifikante Ausschläge nur auf lag 12 der ACF und der PACF.

Es handelt sich um eine erste grobe Einteilung der Zeitreihen, wobei eine eindeutige Abgrenzung nicht immer möglich ist. Die ACF und PACF einiger Zeitreihen weisen weitere einzelne signifikante Ausschläge auf, hinter denen sich aber keine Systematik erkennen lässt. Diese Fälle wurden bei der Beschreibung der Klassen nicht explizit aufgeführt. Im Anhang wurden für jeweils einen Grossisten aus jeder der 7 Klassen der Graph der Verkaufszahlen und die Korrelogramme der Verkaufszahlen dargestellt.

5.2 Durchführung der Modellentwicklung

Innerhalb der sieben Klassen wird die Zeitreihe jedes Grossisten mit den in Kapitel 3 vorgestellten Testverfahren auf Stationarität, Normalverteiltheit und Unabhängigkeit überprüft. Der Test von Neftci zur Überprüfung der Linearität wird nur auf die Zeitreihen der Klassen 1 bis 4 angewendet, da er als eine Grundvoraussetzung die Stationarität der Zeitreihe verlangt. Zwar erfüllen nicht alle Zeitreihen der Klassen 1 bis 4 die Stationaritätsbedingung, aber durch Anwendung des HP-Filters lassen sich die entsprechenden Zeitreihen in stationäre Reihen transformieren. Nur bei vereinzelt Zeitreihen führt der Neftci-Test zu einer Verwerfung der Nullhypothese auf Linearität.

Die Zeitreihen der Klasse 5 bis 7 verletzen durchweg die Stationaritätsbedingung, alle besitzen eine recht ausgeprägte saisonale Struktur. Sie lässt sich nicht so einfach entfernen, da damit schon eine Entscheidung über die Form der Saison, deterministische oder stochastische getroffen werden muss. Die dazu notwendigen Testverfahren, vorgestellt im Kapitel 4.7, können leider nicht verwendet werden, da bei Zeitreihen mit monatlichen Daten mindestens 120 Beobachtungswerte vorliegen sollten, zur Verfügung stehen aber nur 64.

Im zweiten Schritt werden je nach Datenlage und Ergebnissen der Identifikationstests geeignete Modelle zur kurz- bis mittelfristigen Prognose der Verkaufszahlen entwickelt.

Die Modellvarianten reichen von einfachen deterministischen Modellen, über Modelle mit Dummy-Variablen zur Beschreibung der Saison, bis hin zu SARIMA-Modellen. Auf die Implementierung von nichtlinearen Modellen wird aber verzichtet.

Recht uninteressant sind dabei jene Zeitreihen, die alle drei Identifikationskriterien erfüllen und somit den Bedingungen eines reinen Zufallsprozesses genügen. Reine Zufallsprozesse besitzen keinerlei systematische Strukturen und eignen sich leider nicht zu Erstellung von Prognosemodellen.

Neben der Modellschätzung liefert das Programm EViews auch die Möglichkeit der Modellprognose. Es stehen dabei zwei Ansätze zur Verfügung, die statische und die dynamische Prognose. Der Unterschied zwischen den beiden Ansätzen erklärt sich in der Behandlung von verzögerten abhängigen Variablen in der Prognosegleichung. Bei der statischen Prognose benötigt man jeweils die aktuellen Realisationen der verzögerten abhängigen Variablen, um die nächsten Werte prognostizieren zu können. Die dynamische Prognose kommt ohne die aktualisierten Realisationen der verzögerten abhängigen Variablen aus. Die Werte der verzögerten Variablen werden durch die zuvor prognostizierten Werte geschätzt.

Alternativ wird für jede Zeitreihe eine Prognose mit Hilfe der exponentiellen Glättung¹⁹⁹ erstellt. Je nach Datenlage wird die einfache oder doppelte exponentielle Glättung, die exponentielle Glättung nach Holt-Winter ohne Saison, mit additiv verknüpfter Saison oder mit multiplikativ verknüpfter Saison verwendet.²⁰⁰

EViews weist eine Reihe von Prognosefehlermaßen aus, unter anderem auch den RMSE

(Root Mean Squared Error):
$$\text{RMSE} = \sqrt{\frac{1}{N-\nu} \sum_{t=1}^{N-\nu} (y_t - \hat{y}_t)^2}$$

Der RMSE ist definiert als die Summe der quadrierten Abweichungen zwischen den realisierten und den prognostizierten Werten, dividiert durch die Anzahl der Zeitreihenwerte N , die um die Freiheitsgrade ν reduziert werden. Dieser Fehler wird als Vergleichsmaß zwischen den geschätzten Modellen und den Verfahren der exponentiellen Glättung verwendet.²⁰¹

Die Darstellung der Ergebnisse der Identifikationstests erfolgt in tabellarischer Form.

Kompakt und übersichtlich werden die Ergebnisse der Modellentwicklungen und der Prognosen dargestellt. Angegeben werden im einzelnen:

1. Das geschätzte Prognosemodell mit den Koeffizienten, berechnet auf einen Stützbereich von maximal fünf Jahren (01/1992 bis 12/1996).
2. Der Vergleich zwischen Prognose und Realisationen für den Zeitraum 01/1997 bis 04/1997. Der RMSE (Root Mean Squared Error) des Modells für den Stütz- und Prognosezeitraum.
3. Die Prognose mit der exponentiellen Glättung inklusive RMSE.
4. Das Modellprotokoll mit den wichtigsten Kenngrößen zur Beurteilung der Modellqualität:
 -) M.D.: Arithmetisches Mittel der abhängigen Variablen.
 -) S.D.: Standardabweichung der abhängigen Variablen.
 -) S.E.: Standardfehler der Schätzung.
 -) R_A^2 : Bereinigtes Bestimmtheitsmaß.
 -) F-ST: Realisation der F-Statistik.
 -) W(F): Maximale Wahrscheinlichkeit für den α -Fehler der F-Statistik. Es gilt: $W(F) < 0,05 \Rightarrow H_1$.
5. Die graphische Darstellung der Verkaufszahlen, der Prognosewerte (Modell und exponentielle Glättung) und der durch den HP-Filter geglätteten Verkaufszahlen.

¹⁹⁹ Weiterführende Lit.: Mertens 1994, 61-78 und Lewandowski 1974.

²⁰⁰ Hall/Lilien/Sueyoshi/Engle/Johnston/Ellsworth 1995, 237-248.

²⁰¹ Rudolph 1998, 7-15.

5.2.1 Klasse 1 - Einfacher Zufallsprozess

Die Verkaufssreihen, die zur Klasse 1 zusammengefasst wurden, erfüllen bis auf zwei Ausnahmen die Bedingungen, die an einen reinen Zufallsprozess zu stellen sind. Die Zeitreihen sind stationär, normalverteilt und besitzen keine erkennbare Abhängigkeitsstruktur.

Für alle Zeitreihen der Klasse 1 führt der ADF-Test mit Intercept zu einer klaren Annahme der Alternativhypothese auf Stationarität und das schon bei einer lag Länge von Null im verzögerten Teil der ADF-Testgleichung. Die Residuen der ADF-Testgleichungen weisen keine systematischen Strukturen mehr auf.

Alle Zeitreihen schwanken mehr oder weniger zufällig um ihre jeweiligen arithmetischen Mittelwerte. Nur für die Zeitreihe des Grossisten Jost Gersthofen lässt sich ein geringer Teil der Variation der Verkaufswerte durch einen deterministischen linearen Trend erklären.

Zur Absicherung dieser Ergebnisse wurde auf alle Zeitreihen die HP-Filtertechnik angewandt. Die Abweichungen zwischen den mit dem HP-Filter geglätteten Zeitreihenwerten und dem arithmetischen Mittelwert fielen nur minimal aus.

Zusätzlich wurden die um den HP-Filterwert bereinigten Zeitreihen betrachtet. Wie zu erwarten, stellten sich die bereinigten Zeitreihen als reiner Zufallsprozess dar.

Auf den nächsten Seiten werden die Ergebnisse der Identifikationstests dargestellt, danach folgen Modellbildung und Prognose. Die gewählte Vorgehensweise bei der Modellbildung und -diagnose wird ausführlich am Beispiel des Grossisten Jost Gersthofen erläutert.

Klasse 1	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig		H ₀ : Symmetrie H ₁ : keine Symmetrie
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	Matrix der geschätzten Übergangswahrsch.
Mende Eggenstein	ADF = -6,60 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		$ \vartheta_1 = 0,28 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,33 \leq t_{\alpha} = 1,96$ $S = 0,19 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,66 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,30 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,39 & 0,61 \\ 0,84 & 0,16 \end{pmatrix}$ ⇒ H ₁
PVG Fulda	ADF = -7,21 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		$ \vartheta_1 = 0,30 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,51 \leq t_{\alpha} = 1,96$ $S = 2,36 < \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,83 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,82 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,37 & 0,63 \\ 0,80 & 0,0,2 \end{pmatrix}$ ⇒ H ₀
Jost Gersthofen	ADF = -6,91 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend)		$ \vartheta_1 = 0,10 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,13 \leq t_{\alpha} = 1,96$ $S = 0,03 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,96 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,20 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,40 & 0,60 \\ 0,76 & 0,24 \end{pmatrix}$ ⇒ H ₀ (mit HP)
Tonollo Göttingen	ADF = -7,68 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		$ \vartheta_1 = 0,99 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,01 \leq t_{\alpha} = 1,96$ $S = 0,99 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,70 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,45 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,35 & 0,65 \\ 0,66 & 0,34 \end{pmatrix}$ ⇒ H ₀
Doll Gummersbach	ADF = -8,04 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		$ \vartheta_1 = 1,74 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,42 \leq t_{\alpha} = 1,96$ $S = 5,04 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,88 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,58 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,32 & 0,68 \\ 0,81 & 0,19 \end{pmatrix}$ ⇒ H ₀

Klasse 1	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
Grossist	ADF-Test	Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	Matrix der ge- schätzten Über- gangswahrsch.
Rübartsch & Reiners Mönchengladb.	ADF = -7,06 < $k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0)	$ \vartheta_1 = 0,68 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,55 \leq t_{\alpha} = 1,96$ $S = 0,76 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,28 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags k gilt: W(Q-Stat.) $\geq \alpha = 0,05$ $\Rightarrow H_0$	W(RT) = 0,09 $\geq \alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,46 & 0,54 \\ 0,64 & 0,36 \end{pmatrix}$ $\Rightarrow H_0$
Trunk Oberau	ADF = -6,99 < $k_{(1\%)} = -3,56$ $\Rightarrow H_1$ (lag 0)	$ \vartheta_1 = 1,54 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,03 \leq t_{\alpha} = 1,96$ $S = 2,37 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,91 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags k < 24 gilt: W(Q-Stat.) $\geq \alpha = 0,05$ $\Rightarrow H_0$	W(RT) = 0,02 < $\alpha = 0,05 \Rightarrow H_1$	$\begin{pmatrix} 0,46 & 0,54 \\ 0,83 & 0,17 \end{pmatrix}$ $\Rightarrow H_1$

Die Ergebnisse der Identifikationstests der Grossisten Mende Eggenstein und Trunk Oberau weichen bei den Unabhängigkeitstests und dem Symmetrietest von denen der übrigen Grossisten der Klasse 1 ab.

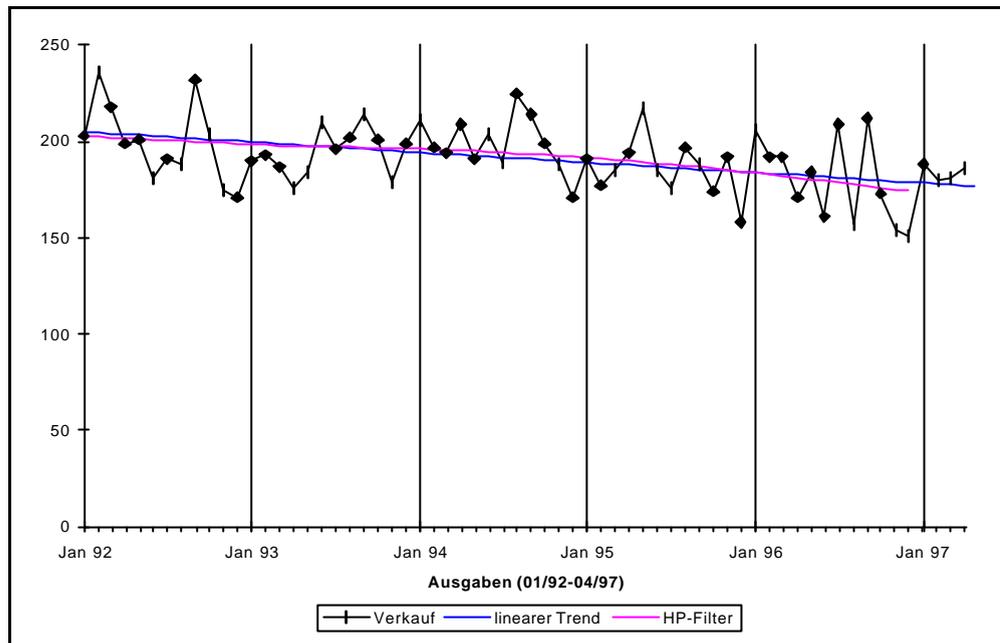
Beim Grossisten Mende Eggenstein führt der Test von Neftci zu einer Verwerfung der Nullhypothese auf Symmetrie in den Daten. Alle anderen Tests deuten aber darauf hin, dass die Verkaufszahlen des Grossisten Mende hinreichend stationär, normalverteilt und unabhängig sind.

Etwas anders sehen die Testergebnisse für den Grossisten Trunk Oberau aus. Neben der Verwerfung der Nullhypothese beim Test von Neftci führt auch der Runs-Test zur Überprüfung der Unabhängigkeit/Abhängigkeit zu einer Verwerfung der Unabhängigkeitshypothese. Die ACF und die PACF sowie die Ljung-Box Q-Statistik lassen hingegen keinerlei Abhängigkeiten erkennen. Inwieweit zur Beschreibung der Abhängigkeitsstruktur nichtlineare Modelle in Frage kommen, müsste detailliert geprüft werden. Der Beobachtungszeitraum für die monatlichen Verkäufe umfasst lediglich die Jahre 1992 bis 1996. Für so wenige Beobachtungswerte ist es sehr schwierig, die asymmetrische Struktur der Auf- und Abschwünge mit geeigneten Techniken zu modellieren und daraus eine stabile Prognose abzuleiten. Außerdem lassen sich nur sehr wenige Grossisten finden, deren Zeitreihen eine asymmetrische Struktur aufweisen. Daher wird auf die Entwicklung von nichtlinearen Modellen zur Prognose der Abverkäufe verzichtet.

Systematische Strukturen zur Beschreibung der Zeitreihen der Klasse 1 lassen sich lediglich für den Grossisten Jost Gersthofen finden. Für diesen Grossisten beobachtet man eine geringe Zunahme der Verkaufswerte, diese Trendentwicklung kann durch eine deterministische lineare Trendgerade beschrieben werden. Bestätigt wird die richtige Wahl der linearen Trendgeraden durch den auf die Zeitreihe angewandten HP-Filter. Die Abweichungen sind nur minimal.

Die nachfolgenden Erläuterungen zur Schätzung der Testgeraden sollen in erster Linie zur Vorstellung des Programms EViews genutzt werden, um die Möglichkeiten und Leistungsfähigkeiten des Programms darzustellen, die Qualität und Effektivität der Schätzung spielt dabei eine untergeordnete Rolle, da der lineare Trend nur einen sehr geringen Teil der Variationen erklären kann.

Verkauf Grossist Jost Gersthofen



Die beiden Koeffizienten der Trendgeraden wurden mit der KQ-Methode geschätzt. Das Ausgabeprotokoll enthält neben den Schätzwerten der Koeffizienten eine Vielzahl von Maßzahlen und statistischen Testergebnissen.

GERSTHOFEN				
LS // Dependent Variable is VERKAUF				
Sample: 1992:01 1996:12				
Included observations: 60				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	205.485	4.372	47.001	0.000
NUMMER	-0.443	0.125	-3.556	0.001
R-squared	0.179	Mean dependent var		191.967
Adjusted R-squared	0.165	S.D. dependent var		18.297
S.E. of regression	16.721	Akaike info criterion		5.666
Sum squared resid	16216.700	Schwarz criterion		5.736
Log likelihood	-253.120	F-statistic		12.644
Durbin-Watson stat	1.850	Prob(F-statistic)		0.001

Grob lassen sich die Ergebnisse in zwei Teile aufteilen. Im ersten Teil werden die geschätzten Koeffizienten einzeln untersucht. Dabei werden die Parameterschätzer, deren Standardabweichungen und die Realisationen der Studentized T-Statistiken einschließlich der Wahrscheinlichkeiten ausgewiesen. Mit der Studentized T-Statistik wird die Alternativhypothese getestet, dass der jeweilige Koeffizient signifikant von Null verschieden ist.

Ist die angegebene Wahrscheinlichkeit kleiner als ein vorgegebener α -Fehler, so liegt die Realisation der Studentized T-Statistik im Ablehnungsbereich der Nullhypothese, das heißt, der getestete Koeffizient ist signifikant von Null verschieden.

Die Maßzahlen und Testergebnisse im zweiten Teil des Ausgabeprotokolls beziehen sich auf das Gesamtmodell.

Schon die graphische Darstellung verdeutlichte, dass nur ein geringer Teil der Variation der Verkaufswerte durch die Trendgerade erklärt werden kann. Dieses Ergebnis wird durch das Bestimmtheitsmaß R^2 und das korrigierte Bestimmtheitsmaß R_A^2 bestätigt. Insgesamt erklärt die Regression nur 16,5% der Variation in den Verkaufswerten.

Zur Berechnung des korrigierten Bestimmtheitsmaßes wird im Programm EViews folgende Definition verwendet:

$$R_A^2 = 1 - (1 - R^2) \frac{N - 1}{N - k} \quad \text{mit: } N = \text{Anzahl der Verkaufswerte}$$

$$k = \text{Anzahl der Regressoren (inklusive der Konstante C)}$$

Des Weiteren weist das Protokoll die Standardabweichung der Regression, die Summe der quadrierten Residuen, den Log-Likelihood-Wert und das arithmetische Mittel sowie die Standardabweichung der abhängigen Variablen aus.

Ein Maß zur Beurteilung der Korrelation erster Ordnung ist die Durbin-Watson-Statistik. Die Durbin-Watson-Statistik kann Werte zwischen 0 und 4 annehmen. Werte um 2 sind ein Indiz dafür, dass die Residuen keine nennenswerte Autokorrelation der Ordnung eins aufweisen.

Zur Ermittlung der kritischen Grenzen benötigt man neben dem Stichprobenumfang die Anzahl der geschätzten Koeffizienten, einschließlich der Konstanten c. Der betrachtete Datensatz enthält 60 Beobachtungswerte und zwei Regressoren. Bei einer vorgegebenen Aussagesicherheit von 95% ergibt sich der Nicht-Ablehnungsbereich der Nullhypothese als Intervall von $[1,616 ; 2,384]^{202}$. Der Wert der Prüfgröße von 1,850 liegt im Nicht-Ablehnungsbereich der Nullhypothese. Die Residuen weisen somit keine positive Autokorrelation der Ordnung 1 auf.

Die Bedeutung der Informationskriterien von Akaike und Schwarz für die Modellauswahl wurde in Abschnitt 4.5.1 schon ausführlich erörtert.

Als letzte statistische Maßzahl weist das Ausgabeprotokoll die F-Statistik mit der dazugehörigen Wahrscheinlichkeit aus.

²⁰² Judge/Hill/Griffiths/Lütkepohl/Lee 1988, 992.

Die F-Statistik ist ein Maß zur simultanen Überprüfung der Nullhypothese, dass kein Koeffizient der Regressionsgleichung signifikant von Null verschieden ist. Mit 12,644 liegt der Wert der F-Statistik mit sehr hoher Wahrscheinlichkeit ($0,0008 < \alpha = 0,05$) im Bereich der Alternativhypothese. Das heißt, dass es in der Regressionsgleichung mindestens einen Koeffizienten gibt, der signifikant von Null verschieden ist.

Zur Überprüfung der Qualität der Schätzung sind neben der kritischen Interpretation der Ergebnisse des Ausgabeprotokolls, die Prognosefähigkeit des geschätzten Modells und die Untersuchung der Residuen von elementarer Bedeutung. Erst wenn die Residuen keinerlei systematische Strukturen mehr aufweisen und die Prognose eine bestimmte Güte und Stabilität erzielt, kann von einem geeigneten Modell ausgegangen werden.

EViews stellt zur Beurteilung der Qualität der Residuen eine Reihe von Prozeduren zur Verfügung, die im Abschnitt 4.5.3 schon eingehend vorgestellt wurden.

Eine zentrale Bedeutung nimmt die Überprüfung der Autokorrelation und partiellen Autokorrelation der Residuen ein. Neben den Korrelogrammen kann im Programm EViews die Box-Ljung Q-Statistik der Residuen für beliebig vorgegebene endlich lange lags berechnet werden. Die beiden Korrelogramme sollten nur wenige signifikante unsystematische Abweichungen vom Wert Null besitzen. Die berechneten Wahrscheinlichkeiten der Ljung-Box Q-Statistik sollten für die vorab gewählte Länge k der lags größer als das vorgegebene Signifikanzniveau $\alpha = 0,05$ sein, damit die Nullhypothese auf Unabhängigkeit der Residuen nicht verworfen werden kann.

Grossist Jost Gersthofen: ACF und PACF der Residuen

Sample: 1992:01 1996:12
Included observations: 60

Autocorrelation		Partial Correlation		AC	PAC	Q-Stat	Prob	
.	.	.	.	1	0.051	0.051	0.1624	0.687
.	.	.	.	2	0.055	0.053	0.3593	0.836
.*	.	.*	.	3	-0.182	-0.188	2.5102	0.473
.	.*	.	.*	4	0.075	0.095	2.8832	0.578
.*	.	.*	.	5	-0.066	-0.059	3.1789	0.672
.	.*	.	.*	6	0.124	0.094	4.2332	0.645
.	.	.	.	7	0.027	0.051	4.2841	0.747
.	.*	.	.*	8	0.169	0.131	6.3369	0.610
.*	.	.*	.	9	-0.122	-0.108	7.4308	0.592
.*	.	.*	.	10	-0.073	-0.083	7.8269	0.646
.	.	.	.*	11	-0.006	0.079	7.8297	0.728
.	.*	.	.	12	0.091	0.027	8.4774	0.747
.*	.	.*	.	13	-0.101	-0.125	9.2801	0.751
.*	.	.*	.	14	-0.137	-0.161	10.789	0.703
.*	.	.*	.	15	-0.127	-0.085	12.126	0.669
.	.	.	.	16	0.041	0.036	12.270	0.725
.	.	.	.	17	-0.024	-0.013	12.318	0.780
.*	.	.*	.	18	-0.123	-0.174	13.664	0.751
.	.	.	.	19	-0.041	-0.032	13.817	0.794
.*	.	.*	.	20	-0.066	-0.055	14.220	0.819
.*	.	.*	.	21	-0.112	-0.068	15.416	0.801
.	.	.	.	22	-0.036	0.021	15.541	0.838
.	**	.	**	23	0.209	0.203	19.941	0.645
.	.	.*	.	24	0.019	-0.066	19.978	0.698
.	.*	.	.*	25	0.078	0.109	20.629	0.713
.*	.	.	.	26	-0.162	-0.041	23.489	0.605
.*	.	**	.	27	-0.127	-0.208	25.307	0.557
.*	.	.*	.	28	-0.107	-0.097	26.628	0.539

Die Korrelogramme der ACF und der PACF der Residuen enthalten für den Grossisten Gersthofen keinerlei Hinweise auf weitere Abhängigkeiten. Zu demselben Ergebnis gelangt man bei Betrachtung der Ljung-Box Q-Statistik. Alle ausgewiesenen Wahrscheinlichkeiten sind größer als das vorgegebene Signifikanzniveau von $\alpha = 0,05$.

Zusätzlich wurde der LM-Test auf die Residuen angewandt, dabei wurde eine lag Länge von $k = 12$ (entspricht dem Zeitraum einer Saison) gewählt. Es trat bei den Residuen keine signifikante Autokorrelation auf. Auch höhere lags, wie zum Beispiel $k = 24$, ändern an diesem Ergebnis nichts.

Die Überprüfung der Normalverteilungshypothese führt ebenfalls zu einer Nicht-Ablehnung derselben.

(Schiefe: $|\vartheta_1| = 0,69 \leq t_\alpha = 1,96$, Wölbung: $|\vartheta_2| = 1,05 \leq t_\alpha = 1,96$ und Jarque-Bera: $S = 1,57 \leq \chi^2_k = 5,99$ liegen alle im Nicht-Ablehnungsbereich der Nullhypothese \Rightarrow Entscheidung auf H_0 : Residuen genügen der NV).

Das untersuchte Trendmodell kann nur einen geringen Teil der Variation in den Daten erklären. Daher sollte geklärt werden, ob das Modell im Zeitverlauf wenigstens stabil bleibt. Dazu wird der Chow-Breakpoint-Test zweimal durchgeführt. Bei der Durchführung des ersten Tests werden die Residuen in die beiden Intervalle 1992:01 bis 1993:12 und 1994:01 bis 1996:12 aufgesplittet. Beim zweiten Testlauf erfolgt die Unterteilung der Zeitreihe in die Intervalle 1992:01 bis 1994:12 und 1995:01 bis 1996:12.

Erster Chow-Test:

(Chow Breakpoint Test: 1994:01)

F-statistic	2.371491	Probability	0.102653
Log likelihood ratio	4.877992	Probability	0.087248

Zweiter Chow-Test:

(Chow Breakpoint Test: 1995:01)

F-statistic	1.206945	Probability	0.306770
Log likelihood ratio	2.532121	Probability	0.281940

Die H_0 -Hypothese kann nicht verworfen werden, da die Wahrscheinlichkeiten für die Prüfgrößen in beiden Testläufen größer als $\alpha = 0,05$ sind und damit die Realisationen in den Nicht-Ablehnungsbereich der Nullhypothese fallen, das heißt, dass das einfache lineare Trendmodell innerhalb des betrachteten Zeitfensters keine Strukturbrüche aufweist.

Als Ergebnis für die Zeitreihen der Klasse 1 lässt sich festhalten, dass die Verkaufsschwankungen in erster Linie vom Zufall abhängen. Lediglich für den Grossisten Jost Gersthofen könnte bei der Prognose der deterministische Trend berücksichtigt werden.

Die ersten Hinweise über die Struktur der Zeitreihe, die aus der graphischen Betrachtung und den Ergebnissen der Korrelogramme gewonnen wurden, bestätigten sich bei der genaueren Analyse der Zeitreihen der Klasse 1.

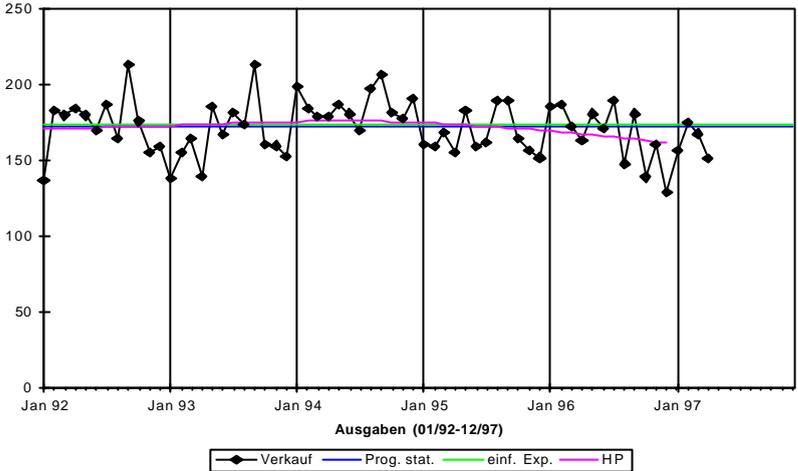
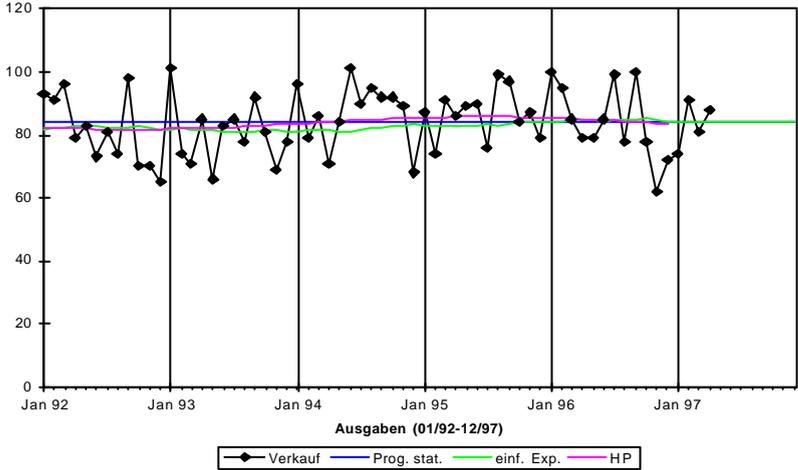
Auf die Implementierung von nichtlinearen Modellen für die Grossisten Trunk Oberau und Mende Eggenstein wird verzichtet.

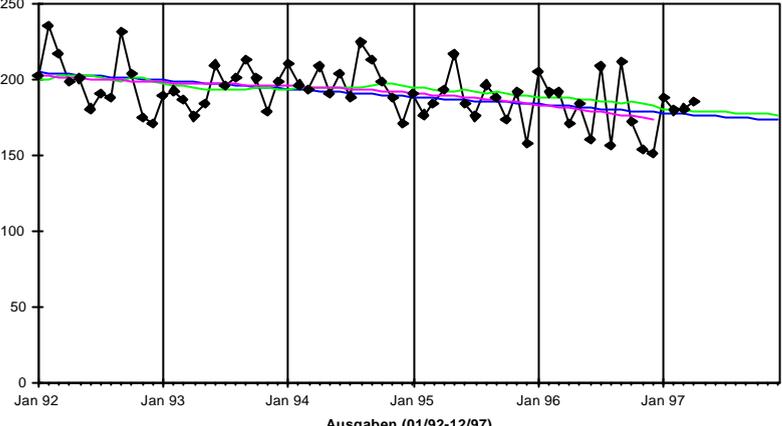
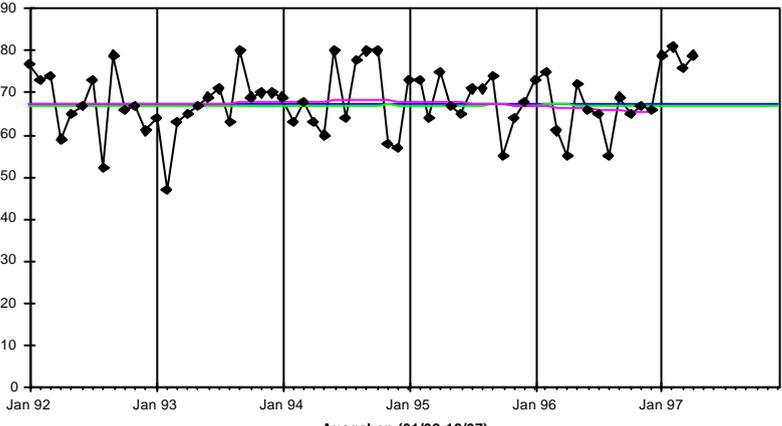
Prognose

Eine Hauptzielsetzung dieser Arbeit ist die kurz- bis mittelfristige Prognose der Abverkaufszahlen pro Grossgebiet. Für die kurzfristige Auflagenplanung sind die ersten drei bis vier Vorhersagemonate von entscheidender Bedeutung. Alle drei bis vier Monate sollte daher die durchgeführte Prognose durch die neuesten realisierten Verkaufszahlen aktualisiert und auf ihre Vorhersagequalität überprüft werden. Als Prognosezeitraum werden jeweils die kommenden 12 Ausgaben betrachtet.

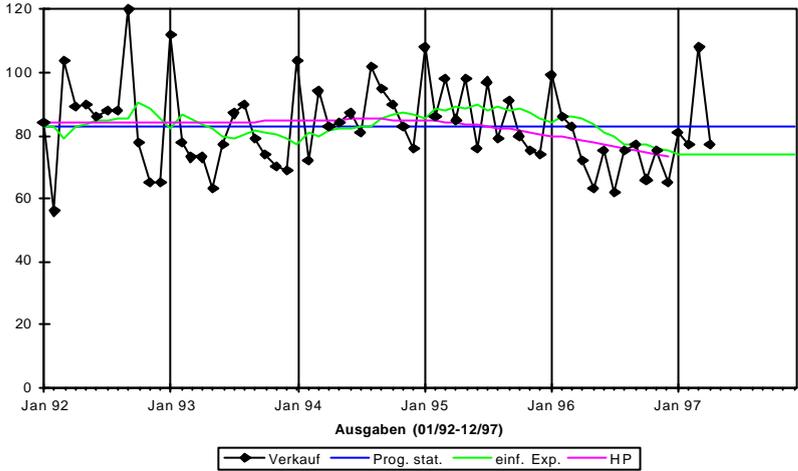
Da bis auf den Grossisten Gersthofen die Zeitreihen der Klasse 1 keinerlei systematische Strukturen erkennen ließen, wird zur Prognose der Verkaufswerte der arithmetische Mittelwert, berechnet auf Basis der Daten der Ausgaben 01/1992 bis 12/1996, herangezogen. In der statistischen Literatur wird diese Vorgehensweise auch als naive Methode bezeichnet. Zusätzlich zum arithmetischen Mittel werden zwei Verfahren der exponentiellen Glättung auf die Zeitreihen angewandt (einfache und doppelte exponentielle Glättung). Verfahren der exponentiellen Glättung sind einfach durchführbar und den Verlagen aufgrund der MBR hinreichend bekannt.

Prognosen, ermittelt mit Verfahren der exponentiellen Glättung, reagieren je nach Wahl des Parameters α sehr empfindlich auf die letzten Beobachtungswerte. Weicht die Prognose mittels der exponentiellen Glättung stärker vom arithmetischen Mittel ab, so sollte man diese Zeitreihen bei der späteren Überprüfung der Prognosequalität genauer analysieren. Zu überprüfen ist dabei, ob die Abweichung zwischen arithmetischem Mittelwert und exponentieller Glättung eher zufälliger Natur ist, auf eine Änderung des Niveaus hindeutet oder sogar ein Strukturbruch wahrscheinlich geworden ist.

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Mende Eggenstein	$\hat{y}_t = 172$	Realisationen: 157 ; 175 ; 168 ; 151 alle im Intervall RMSE = 17,9	Einfache exp. Glättung mit Mittelwert = 173,7 RMSE = 18,0
<u>Modellprotokoll:</u> M.D. = 172 S.D. = 18,3 S.E. = 18,3 DW = 1,63			
PVG Fulda	$\hat{y}_t = 84$	Realisationen: 74 ; 91 ; 81 ; 88 alle im Intervall RMSE = 10,0	Einfache exp. Glättung mit Mittelwert = 83,0 RMSE = 10,1
<u>Modellprotokoll:</u> M.D. = 84 S.D. = 10,3 S.E. = 10,3 DW = 1,88			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Jost Gersthofen	$\hat{y}_t = 205,5 - 0,443 t$ (mit $t = 1$ für 1992:01)	Realisationen: 188 ; 180 ; 181 ; 186 alle im Intervall RMSE = 16,0	Doppelte exp. Glättung ähnlich Trendmodell RMSE = 16,8
<u>Modellprotokoll:</u> M.D. = 192 S.D. = 18,3 S.E. = 16,7 DW = 1,85 $R_A^2 = 0,16$ F-ST = 12,6 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—●— Verkauf — Prog. stat. — dopp. Exp. — HP</p>		
Tonollo Göttingen	$\hat{y}_t = 67$	Realisationen: 79 ; 81 ; 76 ; 79 alle im Intervall RMSE = 7,5	Einfache exp. Glättung mit Mittelwert = 67,4 RMSE = 7,5
<u>Modellprotokoll:</u> M.D. = 67 S.D. = 7,2 S.E. = 7,2 DW = 1,97	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—●— Verkauf — Prog. stat. — einf. Exp. — HP</p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Doll Gummersbach	$\hat{y}_t = 48$	Realisationen: 58 ; 51 ; 43 ; 59 alle im Intervall RMSE = 8,0	Einfache exp. Glättung mit Mittelwert = 48,3 RMSE = 8,0
<u>Modellprotokoll:</u> M.D. = 48 S.D. = 8,0 S.E. = 8,0 DW = 2,12	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—●— Verkauf — Prog. stat. — einf. Exp. — HP</p>		
Rübartsch & Reiners Mönchengladbach	$\hat{y}_t = 244$	Realisationen: 273 ; 255 ; 233 ; 248 alle im Intervall RMSE = 21,7	Einfache exp. Glättung unterhalb von 244 RMSE = 21,9
<u>Modellprotokoll:</u> M.D. = 244 S.D. = 22,2 S.E. = 22,2 DW = 1,84	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—●— Verkauf — Prog. stat. — einf. Exp. — HP</p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Trunk Oberau	$\hat{y}_t = 83$	Realisationen: 81 ; 77 ; 108 ; 77 alle im Intervall RMSE = 13,1	Einfache exp. Glättung unterhalb von 83 RMSE = 13,1
<u>Modellprotokoll:</u> M.D. = 83 S.D. = 13,2 S.E. = 13,2 DW = 1,85			

5.2.2 Klasse 2 - Vermutlich einfacher Zufallsprozess, nur einzelne lags der ACF oder PACF besitzen signifikante Ausschläge

Die Modelle der Klasse 2 sind recht interessant. Die Betrachtung der Plots der Verkaufszahlen lässt kaum Einflüsse wie Trend, Saison, Wendepunkte, Strukturbrüche oder Ausreißer erkennen. Dieser erste Eindruck wird durch die Korrelogramme der ACF und PACF bestätigt. Nur einzelne Werte sind signifikant von Null verschieden.

Bei der Berechnung der ADF-Tests stellt sich ein deutlich differenzierteres Bild der in Klasse 2 zusammengefassten Zeitreihen dar. Die ADF-Testgleichungen einiger Zeitreihen führen bereits durch Berücksichtigung des Intercepts und der passenden Ordnung der verzögerten Differenzen der Verkaufswerte zu stationären Zeitreihen.

Bei weiteren Zeitreihen erreicht man erst durch zusätzlicher Berücksichtigung eines deterministischen linearen Trends in den ADF-Testgleichungen das Ziel der Stationarität. Man bezeichnet diese Zeitreihen auch als trendstationär. Bei einigen Zeitreihen führt die Berücksichtigung von Intercept und der verzögerten Differenzen der Verkaufswerte zu akzeptablen Ergebnissen auf Stationarität. Die zusätzliche Aufnahme des deterministischen linearen Trends in der Testgleichung bringt aber eine deutliche Verbesserung der Testaussage. Besonders interessant sind die Zeitreihen, die erst durch Anwendung der Differenzenbildung den Bedingungen der Stationarität genügen. Dabei kann die Testgleichung durchaus verzögerte Differenzen der Verkaufswerte aufweisen, damit die Residuen keinerlei systematische Strukturen mehr enthalten.

Bis auf die Zeitreihen der Grossisten Schulte Bremen und B&P Hamburg wird die Nullhypothese auf Normalverteiltheit nicht verworfen. Dabei gelangt man mit den verwendeten Tests zu unterschiedlichen Ergebnissen. Der Kolmogorov-Smirnov-Test führt bei den Zeitreihen Schulte Bremen und B&P Hamburg nicht zur Verwerfung der Hypothese auf Normalverteiltheit. Der Jarque-Bera-Test und die Tests auf Schiefe und Wölbung hingegen führen zu einer Verwerfung der Nullhypothese auf Normalverteiltheit. Die Diskrepanz der Testergebnisse geht auf die unterschiedliche Berücksichtigung von Ausreißern in den Prüfgrößen zurück. Beide Zeitreihen besitzen für einzelne Ausgaben Verkaufswerte, die sehr stark vom Niveau der übrigen Realisationen abweichen. Der Kolmogorov-Smirnov-Test berücksichtigt den Betrag der maximalen Abweichung zwischen empirischer Verteilung und unterstellter Grundgesamtheitsverteilung. In den Prüfgrößen der anderen Normalverteilungstests wird die durchschnittliche Summe der um drei bzw. vier potenzierten Abweichungen zwischen empirischen Werten und arithmetischem Mittel berechnet.

Einzelne Realisationen, die sehr stark vom arithmetischen Mittel der Zeitreihe abweichen, führen damit zu einer überproportionalen Vergrößerung des Prüfgrößenwertes.

Unterschiedliche Ergebnisse erzielt man auch bei den Tests zur Beurteilung der Abhängigkeit bzw. Unabhängigkeit der Zeitreihenwerte.

Der Runs-Test, der lediglich die Vorzeichenwechsel in der Differenz der Zeitreihenwerte berücksichtigt, führt zu dem Ergebnis, dass keine der betrachteten Zeitreihen eine signifikante Abweichung von der Nullhypothese auf Unabhängigkeit besitzt.

Mit der Box-Ljung Q-Statistik gelangt man bei den meisten Zeitreihen zu einer signifikanten Testentscheidung auf Abhängigkeit der Zeitreihenwerte. Hinsichtlich der Signifikanz der betrachteten ersten 25 lags gibt es aber leichte Unterschiede. Bei einigen Zeitreihen sind nicht alle 25 lags signifikant von Null verschieden.

Die Zeitreihen mit erkennbaren Abhängigkeiten lassen sich sehr gut durch lineare Modelle beschreiben. Diese Aussage lässt sich aus den Ergebnissen des Tests von Neftci gewinnen. Nur für den Grossisten Lütkemeyer Münster kommt der Test von Neftci zu einer Verwerfung der Hypothese auf Symmetrie und damit zur Empfehlung, mit nicht-linearen Modellen zu arbeiten.

Die Modelle, die auf den nächsten Seiten für die Zeitreihen der Klasse 2 vorgestellt werden, sind zum Teil recht unterschiedlich. Grob lassen sie sich zu drei Modelltypen zusammenfassen. Modelltyp 1 besteht aus Zeitreihen, die sehr stark von zufälligen und unsystematischen Schwankungen der Realisationen dominiert werden. Sie enthalten keine saisonalen Strukturen, sondern Strukturen, die sich höchstens mit linearen deterministischen Trendmodellen oder ARIMA-Modellen beschreiben lassen.

Modelltyp 2 besteht aus Zeitreihen, die sich durch SARIMA- und Kombinationen aus SARIMA- und deterministischen Trendkomponenten beschreiben lassen.

Der letzte Modelltyp, der Typ 3, enthält Zeitreihen, bei denen die einfache Differenzenbildung der Ordnung eins erforderlich ist. Die entwickelten Modelle beziehen sich folglich auf die differenzierten Zeitreihen.

Klasse 2	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig		H ₀ : Symmetrie H ₁ : keine Symmetrie
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	Matrix der geschätzten Übergangswahrsch.
Staab Bad Kreuznach	ADF = -6,18 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		ϑ ₁ = 0,74 ≤ t _α = 1,96 ϑ ₂ = 0,62 ≤ t _α = 1,96 S = 0,94 ≤ χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,60 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,77 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,34 & 0,66 \\ 0,68 & 0,32 \end{pmatrix}$ ⇒ H ₀
Müller & Schultz Bremen	ADF = -6,12 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		ϑ ₁ = 2,01 > t _α = 1,96 ϑ ₂ = 3,36 > t _α = 1,96 S = 15,32 > χ ² _k = 5,99 ⇒ H ₁	W(K-S) = 0,59 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,30 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,40 & 0,60 \\ 0,72 & 0,28 \end{pmatrix}$ ⇒ H ₀
Grade Elmshorn	ADF = -6,79 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend)		ϑ ₁ = 1,76 ≤ t _α = 1,96 ϑ ₂ = 1,12 ≤ t _α = 1,96 S = 4,36 ≤ χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,46 ≥ α = 0,05 ⇒ H ₀	Für lags 3 bis 5 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,97 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,25 & 0,75 \\ 0,70 & 0,30 \end{pmatrix}$ ⇒ H ₀
PVP Frankenthal	ADF = -2,66 ≥ k _(1%) = -3,55 ⇒ H ₀ (lag 3) <u>Differenzenbildung (d = 1):</u> ADF = -5,88 < k _(1%) = -2,61 ⇒ H ₁ (lag 4)		ϑ ₁ = 2,02 > t _α = 1,96 ϑ ₂ = 0,18 ≤ t _α = 1,96 S = 4,10 ≤ χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,34 ≥ α = 0,05 ⇒ H ₀	Für lag 12 und ab 15 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,94 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,38 & 0,62 \\ 0,74 & 0,26 \end{pmatrix}$ ⇒ H ₀

Klasse 2	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	
Grossist	ADF-Test					Matrix der geschätzten Übergangswahrsch.
Kaschewitz Gelsenkirchen	ADF = -6,31 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 1 u. det. Trend)	$ \vartheta_1 = 1,14 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,05 \leq t_{\alpha} = 1,96$ $S = 1,29 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,61 ≥ α = 0,05 ⇒ H ₀	Für alle lags ab 7 gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₁	W(RT) = 0,20 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,48 & 0,52 \\ 0,71 & 0,29 \end{pmatrix}$ ⇒ H ₀ (mit HP)
B & B Hamburg	ADF = -6,45 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend)	$ \vartheta_1 = 2,73 > t_{\alpha} = 1,96$ $ \vartheta_2 = 9,54 > t_{\alpha} = 1,96$ $S = 30,47 > \chi^2_k = 5,99 \Rightarrow H_1$	W(K-S) = 0,63 ≥ α = 0,05 ⇒ H ₀	Für lag 2 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₀	W(RT) = 0,12 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,38 & 0,62 \\ 0,74 & 0,26 \end{pmatrix}$ ⇒ H ₀
Jost Ingolstadt	ADF = -2,40 ≥ $k_{(1\%)} = -4,12$ ⇒ H ₀ (lag 3 u. det. Trend) <u>Differenzenbildung (d = 1):</u> ADF = -10,1 < $k_{(1\%)} = -2,60$ ⇒ H ₁ (lag 2)	$ \vartheta_1 = 1,06 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,59 \leq t_{\alpha} = 1,96$ $S = 1,48 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,89 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 1 u. 3 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,19 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,36 & 0,64 \\ 0,71 & 0,29 \end{pmatrix}$ ⇒ H ₀
Schmitz Remscheid	ADF = -7,49 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend)	$ \vartheta_1 = 0,15 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,44 \leq t_{\alpha} = 1,96$ $S = 2,09 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,85 ≥ α = 0,05 ⇒ H ₀	Für alle lags ab 4 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,07 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,54 & 0,46 \\ 0,63 & 0,37 \end{pmatrix}$ ⇒ H ₀
Kossmann Reutlingen	ADF = -5,33 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 2 u. det. Trend)	$ \vartheta_1 = 1,11 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,29 \leq t_{\alpha} = 1,96$ $S = 2,89 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,42 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 24 gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,80 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,35 & 0,65 \\ 0,77 & 0,23 \end{pmatrix}$ ⇒ H ₀

Klasse 2	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 15)	Runs-Test (RT) (Berechnung mit arith. Mittel)	
Grossist	ADF-Test					Matrix der geschätzten Übergangswahrsch.
Siegerland Scheuerfeld	ADF = -5,98 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 1)	$ \vartheta_1 = 0,90 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,68 \leq t_{\alpha} = 1,96$ $S = 2,57 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,76 ≥ α = 0,05 ⇒ H ₀	Für alle lags ab 10 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,79 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,46 & 0,54 \\ 0,69 & 0,31 \end{pmatrix}$ ⇒ H ₀
Mügge Stade	ADF = -2,52 ≥ $k_{(1\%)} = -3,55$ ⇒ H ₀ (lag 5) <u>Differenzenbildung (d = 1):</u> ADF = -4,11 < $k_{(1\%)} = -2,60$ ⇒ H ₁ (lag 6)	$ \vartheta_1 = 0,82 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,40 \leq t_{\alpha} = 1,96$ $S = 2,63 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,78 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,04 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,40 & 0,60 \\ 0,72 & 0,28 \end{pmatrix}$ ⇒ H ₀
Kirschner Troisdorf	ADF = -6,43 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 1 u. det. Trend)	$ \vartheta_1 = 0,03 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,08 \leq t_{\alpha} = 1,96$ $S = 1,17 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,90 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 4 gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,07 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,35 & 0,65 \\ 0,63 & 0,37 \end{pmatrix}$ ⇒ H ₀

Klasse 2 - Modelltyp 1 (Starker Zufallseinfluss)

Zum Typ 1 wurden die Zeitreihen der Grossisten Staab Bad Kreuznach, Müller&Schultz Bremen, Grade Elmshorn und Kirschner Troisdorf zusammengefasst. Bis auf den Grossisten Kirschner unterscheiden sich die Zeitreihen kaum von einem reinen Zufallsprozess.

Für den Grossisten Grade Elmshorn führt die Berücksichtigung eines deterministischen Trends zu signifikanten Schätzkoeffizienten. Der Erklärungsgehalt des Trendmodells fällt aber sehr gering aus, nur knapp 9% der Variation der Zeitreihenwerte lassen sich durch den deterministischen Trend erklären (bereinigtes Bestimmtheitsmaß $R_A^2 = 0,086$). Bei der Modellbildung wird aber nicht auf die Berücksichtigung des deterministischen Trends verzichtet, da die Zeitreihe erst durch Hinzunahme des linearen Trends die Stationaritätsbedingung erfüllt.

Andere Modelle, zum Beispiel aus der Klasse der ARIMA-Modelle führen für den Grossisten Grade zu keinerlei Modellverbesserung und kommen daher zur Beschreibung nicht in Betracht.

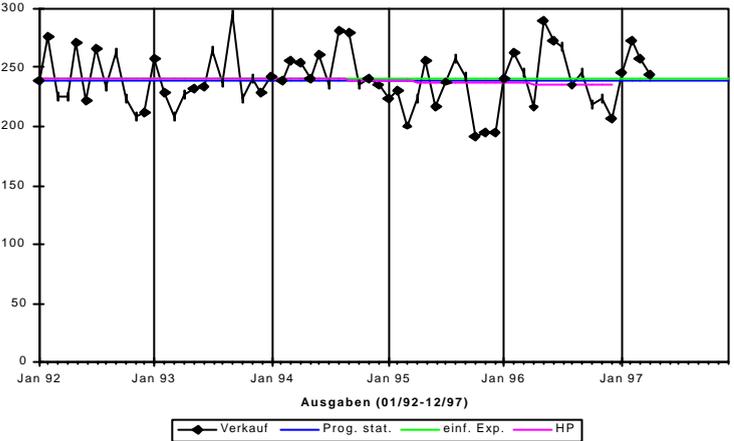
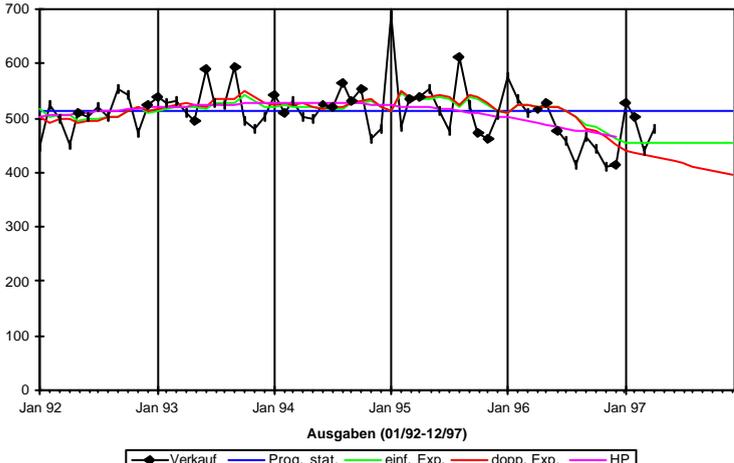
Die Zeitreihe des Grossisten Schulte Bremen liefert recht interessante Ergebnisse für die Glättung mit dem HP-Filter. Bis Mitte 94 steigen die HP-Werte leicht an, um dann ab Mitte 94 zu stagnieren und ab Ende 94 zu fallen. Der Abschwung verstärkt sich bis Ende 96 stetig. Die Prognosen mit Hilfe der Verfahren der exponentiellen Glättung (einfache, doppelte und Holt-Winter-Methode) fallen sehr unterschiedlich aus. Eine verlässliche Prognose ist daher äußerst schwierig. Die Zeitreihe stellt ein gutes Beispiel für starke Instabilität am rechten Prognosezeitraum dar.

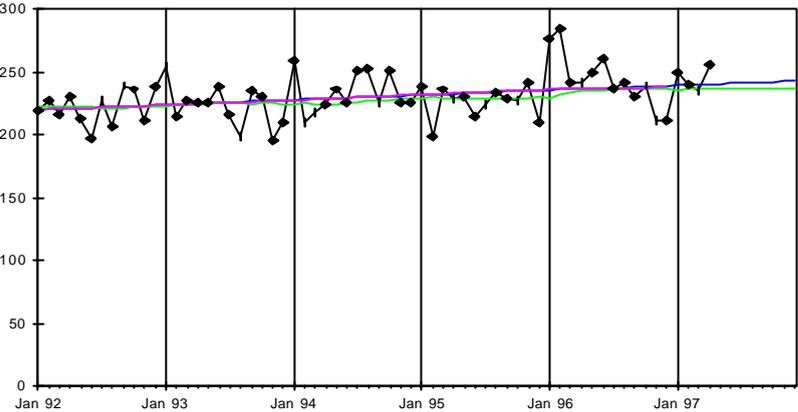
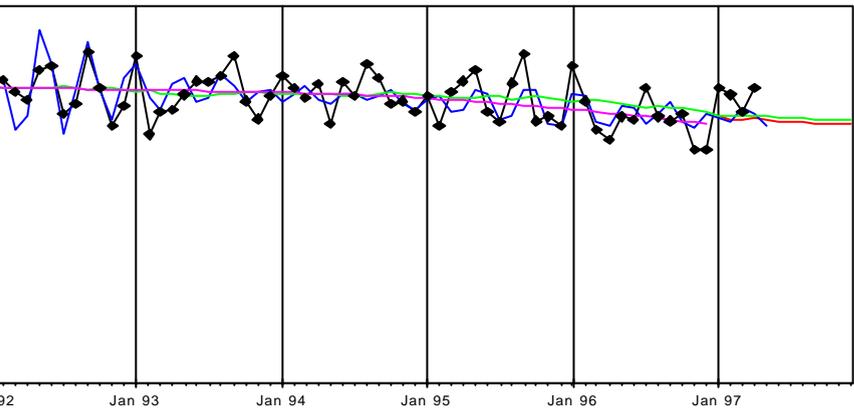
Nach eingehender Prüfung bleiben zwei Modellvarianten übrig. Bei der einen wird der Stützbereich zur Modellentwicklung eines einfachen deterministischen Trendmodells auf die Jahre 1995 und 1996 reduziert. Die andere Möglichkeit besteht in der Verwendung des arithmetischen Mittels, berechnet auf Basis der Beobachtungswerte der Jahre 1992 bis 1996. Letztendlich fiel die Entscheidung auf die Variante mit dem arithmetischen Mittel, da der Stützbereich des Trendmodells zum einen sehr kurz ist und es zum anderen eher ungewiss ist, ob die starke negative Entwicklung der Verkaufszahlen auch in den kommenden Jahren so anhalten wird.

Die Zeitreihe des Grossisten Kirschner Troisdorf lässt sich durch eine Kombination aus linearem Trend und ARIMA-Fehlerterm schätzen, wobei der Erklärungsgehalt des Modells mit $R_A^2 = 0,36$ nicht sehr hoch ausfällt.

Die Prognosefähigkeit des Modells unterscheidet sich im Prognosezeitraum Januar 97 bis Dezember 97 kaum von einer linearen Trendgeraden. Der Grund liegt in der gegenseitigen Neutralisierung der geschätzten AR- und MA-Koeffizienten.

Für alle vier Grossisten lassen sich mit den Verfahren der exponentiellen Glättung ebenfalls geeignete Prognosen formulieren. Je nach Datenlage werden die folgenden Verfahren verwendet: einfache sowie doppelte exponentielle Glättung.

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Staab Bad Kreuznach	$\hat{y}_t = 239$	Realisationen: 246 ; 272 ; 257 ; 244 alle im Intervall RMSE = 23,3	Einfache exp. Glättung mit Mittelwert = 241 RMSE = 23,6
<u>Modellprotokoll:</u> M.D. = 239 S.D. = 23,7 S.E. = 23,7 DW = 1,62			
Müller & Schultz Bremen	$\hat{y}_t = 512$	Realisationen: 529 , 501 , 439 , 480 alle im Intervall RMSE = 47,4	Einfache u. doppelte exp. Glättung klar unterhalb von 512 RMSE = 46,0 (einf. exp. Glättung)
<u>Modellprotokoll:</u> M.D. = 512 S.D. = 48,2 S.E. = 48,2 DW = 1,55			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Grade Elmshorn	$\hat{y}_t = 219,5 + 0,326 t$ (mit $t = 1$ für 1992:01)	Realisationen: 249 ; 240 ; 235 ; 256 alle im Intervall RMSE = 16,8	Doppelte exp. Glättung ähnlich Modell RMSE = 16,5
<u>Modellprotokoll:</u> M.D. = 229 S.D. = 17,9 S.E. = 17,1 DW = 1,82 $R_A^2 = 0,09$ F-ST = 6,6 W(F) = 0,013	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—◆— Verkauf — Prog. stat. — dopp. Exp. — HP</p>		
Kirschner Troisdorf	$\hat{y}_t = 323,0 - 0,685 t$ $- 0,118 u_{t-1} - 0,806 u_{t-2}$ $+ 0,288 e_{t-1} + 0,960 e_{t-2}$ (Linearer Trend + ARIMA(2, 0, 2))	Realisationen 313 ; 306 ; 288 ; 314 alle im Intervall RMSE = 21,9	Doppelte exp. Glättung ähnlich Modell RMSE = 23,7
<u>Modellprotokoll:</u> M.D. = 301 S.D. = 25,5 S.E. = 20,4 DW = 1,93 $R_A^2 = 0,36$ F-ST = 7,3 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—◆— Verkauf — Prog. dyn. — Prog. stat. — dopp. Exp. — HP</p>		

Klasse 2 - Modelltyp 2 (Mit Saison)

Zu diesem Typ gehören alle Zeitreihen der Klasse 2, die neben einem linearen Trend auch einen saisonalen ARMA-Term enthalten. Der Trendeinfluss fällt meistens sehr gering und von seinem Verlauf nicht immer ganz eindeutig aus.

Trotzdem wird auf die Implementierung des linearen Trends in den geschätzten Modellgleichungen nicht verzichtet. Nicht zuletzt erfüllt ein Teil der Zeitreihen die Stationaritätsbedingung erst durch Aufnahme eines linearen Trends in die Testgleichung des ADF-Tests. Alle Zeitreihen des Modelltyps 2 besitzen leichte positive Ausschläge in der ACF auf lag 12, die sich aber nicht in der PACF wiederfinden.

Zur Beschreibung der saisonalen Einflüsse werden die um ein Jahr verzögerten Verkaufszahlen als Variable untersucht. Dies entspricht einem autoregressiven Prozess der Ordnung 12 (SAR(12)). Darüber hinaus wird die Alternative eines saisonalen Moving-Average-Prozesses (SMA(12)) geprüft. Bei einigen Zeitreihen erzielt man die besten Ergebnisse, indem beide Alternativen zur Beschreibung der Saisoneinflüsse in die Modellgleichungen implementiert werden.

Ausführlich wird die Modellentwicklung am Beispiel des Grossisten Kossmann Reutlingen erläutert.

Kossmann Reutlingen

Die graphische Darstellung bringt keinerlei Hinweise über die mögliche Modellstruktur. Anders sieht es mit dem Korrelogramm aus. Auf lag 12 und lag 24 der ACF lassen sich signifikant positive Ausschläge erkennen, die eine Implementierung von saisonal verzögerten Komponenten in die Modellgleichung nahe legen.

Grossist Kossmann: ACF und PACF der Residuen

Sample: 1992:01 1996:12
Included observations: 60

Autocorrelation		Partial Correlation		AC	PAC	Q-Stat	Prob	
.	*	.	*	1	0.066	0.066	0.2756	0.600
.	*	.	*	2	0.074	0.070	0.6284	0.730
**	.	**	.	3	-0.204	-0.215	3.3402	0.342
.	*	.	*	4	0.103	0.134	4.0423	0.400
.	*	.	*	5	0.131	0.153	5.1969	0.392
.	*	.	.	6	0.128	0.043	6.3256	0.388
.	*	.	*	7	0.083	0.102	6.8063	0.449
.	.	.	.	8	0.007	0.029	6.8097	0.557
*	.	**	.	9	-0.177	-0.211	9.1077	0.427
*	.	*	.	10	-0.106	-0.094	9.9395	0.446
.	.	.	.	11	0.036	0.057	10.037	0.527
.	**	.	**	12	0.287	0.220	16.442	0.172
.	.	*	.	13	-0.002	-0.066	16.443	0.226
*	.	*	.	14	-0.139	-0.133	18.002	0.207
**	.	*	.	15	-0.208	-0.062	21.588	0.119
.	.	.	*	16	0.060	0.082	21.898	0.147
.	*	.	.	17	0.110	0.060	22.943	0.151
.	.	*	.	18	0.038	-0.067	23.073	0.188
.	.	.	.	19	0.029	0.032	23.148	0.231
.	*	.	*	20	0.078	0.171	23.711	0.255
*	.	*	.	21	-0.164	-0.145	26.292	0.196
.	.	.	.	22	0.003	0.041	26.293	0.239
.	.	.	.	23	-0.027	-0.023	26.367	0.284
.	***	.	*	24	0.329	0.154	37.569	0.038
*	.	*	.	25	-0.112	-0.167	38.902	0.038
.	.	.	.	26	-0.020	0.053	38.945	0.049
**	.	*	.	27	-0.226	-0.071	44.705	0.017
.	.	**	.	28	-0.050	-0.214	44.991	0.022

Der erste Versuch einer Modellschätzung beruht auf einem reinen linearen Trendmodell, ad die Zeitreihe erst durch Hinzunahme des linearen Trends in der ADF-Testgleichung die Stationaritätsbedingung erfüllt.

Reutlingen (Kossmann)				
LS // Dependent Variable is VERKAUF				
Sample: 1992:01 1996:12				
Included observations: 60				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	106.432	3.416	31.161	0.000
NUMMER	-0.257	0.097	-2.637	0.011
R-squared	0.107	Mean dependent var		98.600
Adjusted R-squared	0.092	S.D. dependent var		13.707
S.E. of regression	13.063	Akaike info criterion		5.172
Sum squared resid	9897.757	Schwarz criterion		5.242
Log likelihood	-238.308	F-statistic		6.954
Durbin-Watson stat	1.952	Prob(F-statistic)		0.011

Die Koeffizienten sind zwar signifikant von Null verschieden, aber der Erklärungsgehalt des Modells ist recht gering, nur 9,2% der Variation der Verkaufswerte kann durch den Trend erklärt werden. Das Korrelogramm der Residuen enthält weiterhin die signifikanten Abweichungen von Null für die lags 12 und 24 der ACF.

Im nächsten Schritt wird eine saisonal um ein Jahr verzögerte autoregressive Komponente zur Erklärung der saisonalen Einflüsse in das Modell aufgenommen.

Reutlingen (Kossmann)				
LS // Dependent Variable is VERKAUF				
Sample(adjusted): 1993:01 1996:12				
Included observations: 48 after adjusting endpoints				
Convergence achieved after 3 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	111.348	8.473	13.142	0.000
NUMMER	-0.358	0.184	-1.938	0.059
AR(12)	0.364	0.126	2.882	0.006
R-squared	0.247	Mean dependent var		97.500
Adjusted R-squared	0.214	S.D. dependent var		12.475
S.E. of regression	11.062	Akaike info criterion		4.867
Sum squared resid	5506.401	Schwarz criterion		4.984
Log likelihood	-181.928	F-statistic		7.386
Durbin-Watson stat	1.983	Prob(F-statistic)		0.002
Inverted AR Roots	0.92	.80+.46i	.80 -.46i	.46 -.80i
	.46+.80i	.00+.92i	-.00 -.92i	-.46 -.80i
	-.46+.80i	-.80 -.46i	-.80+.46i	-0.92

Der zusätzlich aufgenommene saisonale autoregressive Koeffizient ist zwar signifikant von Null verschieden, der Erklärungsgehalt des Modells ist aber immer noch recht gering.

Alternativ wird daher neben dem autoregressiven saisonalen Koeffizienten noch ein saisonaler Moving-Average-Koeffizient getestet.

Reutlingen (Kossmann)				
LS // Dependent Variable is VERKAUF				
Sample(adjusted): 1993:01 1996:12				
Included observations: 48 after adjusting endpoints				
Convergence achieved after 20 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	243.647	142.803	1.706	0.095
NUMMER	-1.738	1.056	-1.646	0.107
AR(12)	0.802	0.114	7.055	0.000
MA(12)	-0.866	0.043	-20.006	0.000
R-squared	0.554	Mean dependent var		97.500
Adjusted R-squared	0.523	S.D. dependent var		12.475
S.E. of regression	8.614	Akaike info criterion		4.386
Sum squared resid	3264.968	Schwarz criterion		4.542
Log likelihood	-169.384	F-statistic		18.189
Durbin-Watson stat	2.098	Prob(F-statistic)		0.000
Inverted AR Roots	0.98	.85+.49i	.85 -.49i	.49+.85i
	.49 -.85i	.00 -.98i	-.00+.98i	-.49 -.85i
	-.49+.85i	-.85 -.49i	-.85+.49i	-0.98
Inverted MA Roots	0.99	.86+.49i	.86 -.49i	.49+.86i
	.49 -.86i	-.00 -.99i	-.00+.99i	-.49 -.86i
	-.49+.86i	-.86+.49i	-.86 -.49i	-0.99

Die Ergebnisse des obigen Modells enthalten einige kritische Punkte. Zwar verringert sich der Wert des SC gegenüber dem vorherigen Modell von 4,984 auf 4,484, die ersten beiden Koeffizienten sind bei einer vorab unterstellten Aussagesicherheit von 95% aber nicht signifikant von Null verschieden.

Ebenso weist das Korrelogramm der Residuen eine positive signifikante Autokorrelation auf lag 2 der ACF und PACF auf.

Neben dem saisonalen Teil wird die zusätzliche Berücksichtigung von nicht saisonalen ARIMA-Kombinationen in der Modellgleichung getestet.

Ausgangspunkt für die Modellerweiterung bildet dabei das saisonale ARIMA(0, 0, 0) (1, 0, 1)-Modell, dessen Schätzergebnisse im vorherigen Ausgabeprotokoll festgehalten wurden. Gesucht wird nun der optimale ARMA(p,q)-Term. Getestet werden alle Koeffizientenkombinationen für p und q von 0 bis 3. Für jede Kombination wird das SC

berechnet. Modelle, die zu nicht invertierbaren Prozessen führen, werden vorab aus dem Modellportfolio entfernt.

Reutlingen		MA(q)			
		0	1	2	3
AR(p)	0	4,542	4,531	4,517	4,592
	1	4,614	4,852	4,880	5,090
	2	4,504	4,754	4,908	4,806
	3	4,591	4,819	4,915	4,861

Zur Unterstützung der Modellentscheidung wird der Test von Poskitt und Tremayne durchgeführt. Es gilt: $R = \exp\left[-\frac{1}{2}N\{SC(p_1; q_1) - SC(p; q)\}\right]$. Für $SC(p_1; q_1)$ wird die

Kombination mit dem geringsten SC-Wert in der Matrix ausgewählt.

Das Portfolio bilden alle Modelle, deren R-Werte zwischen $1 < R < \sqrt{10} = 3,16$ liegen.²⁰³

Die Entscheidung fällt auf jenes Modell, das robuste Ergebnisse bei der Stabilität der Koeffizienten erzielt, dessen Residuen zufällig verteilt sind und der Normalverteilung genügen und das gemessen am RMSE eine gute mittelfristige Prognoseleistung aufweist.

Für den Test von Poskitt und Tremayne gilt das Grundmodell: Linearer Trend plus SARIMA(p, 0, q)(1, 0, 1)

Reutlingen		MA(q)			
		0	1	2	3
AR(p)	0	2,69	2,02	1,40	9,86
	1	17,46	>100	>100	>100
	2	1,00	>100	>100	>100
	3	9,60	>100	>100	>100

²⁰³ Mills 1990, 140-142.

Neben dem ARMA(2, 0)-Term stellen die (0, 0), (0, 1) und (0, 2) mögliche Alternativen eines Modellportfolios dar, da gilt: $R < 3,16$.

Die Modelle mit einem ARMA(0, 1) und (0, 2) Term weisen deutlich signifikante Autokorrelationen der Residuen für lag 1 der ACF und PACF auf. Das Modell mit dem ARMA(0, 0)-Term besitzt dagegen signifikante Werte der ACF auf lag 2. Am geeignetsten erscheint das Modell mit dem ARMA(2, 0)-Term, es besitzt lediglich auf lag 7 der PACF eine leichte negative Autokorrelation der Residuen. Darüber hinaus erfüllen die Residuen die Normalverteilungsannahme.

Reutlingen (Kossmann)				
LS // Dependent Variable is VERKAUF				
Sample(adjusted): 1993:03 1996:12				
Included observations: 46 after adjusting endpoints				
Convergence achieved after 14 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	210.018	86.752	2.421	0.020
NUMMER	-1.592	0.860	-1.851	0.072
AR(1)	-0.098	0.152	-0.644	0.524
AR(2)	0.378	0.149	2.538	0.015
SAR(12)	0.750	0.097	7.694	0.000
MA(12)	-0.873	0.042	-20.565	0.000
R-squared	0.653	Mean dependent var		97.326
Adjusted R-squared	0.610	S.D. dependent var		12.719
S.E. of regression	7.943	Akaike info criterion		4.266
Sum squared resid	2523.390	Schwarz criterion		4.504
Log likelihood	-157.380	F-statistic		15.080
Durbin-Watson stat	2.019	Prob(F-statistic)		0.000
Inverted AR Roots	0.98	.85+.49i	.85 -.49i	0.57
	.49+.85i	.49 -.85i	-.00 -.98i	-.00+.98i
	-.49 -.85i	-.49+.85i	-0.67	-.85+.49i
	-.85 -.49i	-0.98		
Inverted MA Roots	0.99	.86+.49i	.86 -.49i	.49+.86i
	.49 -.86i	-.00 -.99i	-.00+.99i	-.49 -.86i
	-.49+.86i	-.86+.49i	-.86 -.49i	-0.99

Mit dem Modell lassen sich gut 60% der Variation der Zeitreihenwerte erklären, die Koeffizientenschätzer sind bis auf den AR(1)-Koeffizienten mit hoher Wahrscheinlichkeit von Null verschieden.

Bei der Interpretation der Ergebnisse ist zu beachten, dass ein Entwicklungszeitraum von fünf Jahren sehr kurz ist. In der Literatur findet man die Empfehlung, zum Beispiel im SPSS User Guide Trends, zur Schätzung saisonaler ARIMA-Terme eine Saisonlänge von mindestens acht Jahren zu verwenden, um stabile Parameterschätzer zu erhalten.

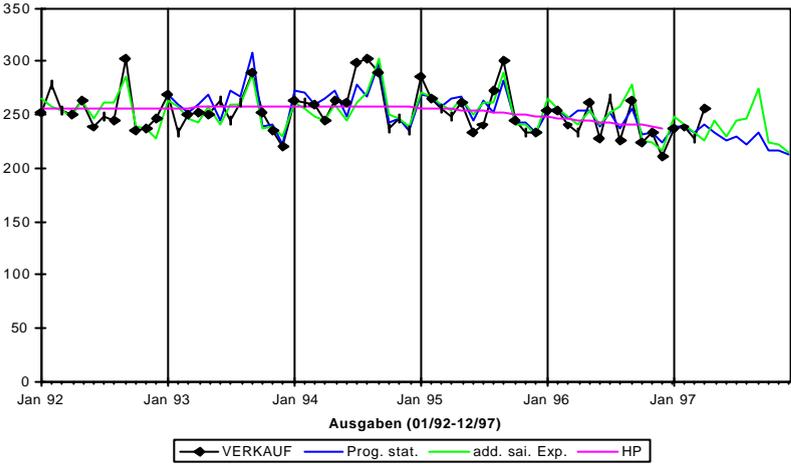
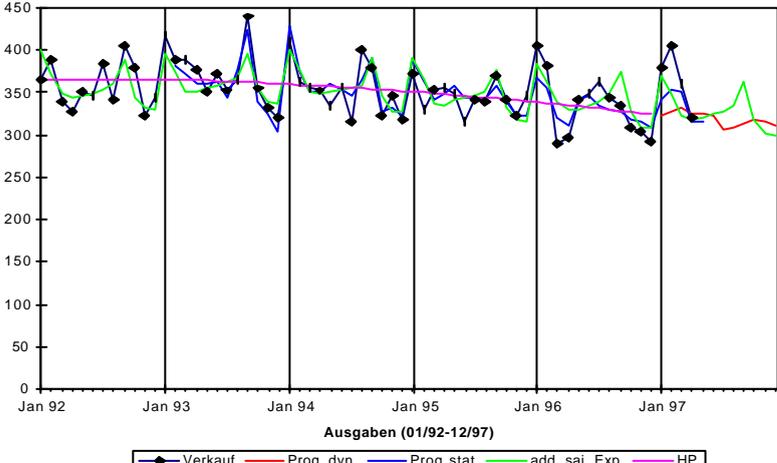
Alternativ wurde auch die Modellierung der Saison durch saisonale Dummies untersucht. Als Ergebnis lässt sich dabei festhalten, dass der Erklärungsgehalt deutlich geringer ist als beim obigen saisonalen ARIMA(2, 0, 0)(1, 0, 1)-Modell. Die Residuen des Modells mit saisonalen Dummies besitzen einen deutlich negativen Ausschlag für lag 12 der ACF und PACF. Viele der Dummy-Schätzer weisen eine sehr große Varianz auf, was zur Folge hat, dass die meisten Schätzer nicht signifikant von Null verschieden sind. Der Verdacht liegt nahe, dass das Dummy-Modell für die kurze Zeitreihe überparametrisiert ist.

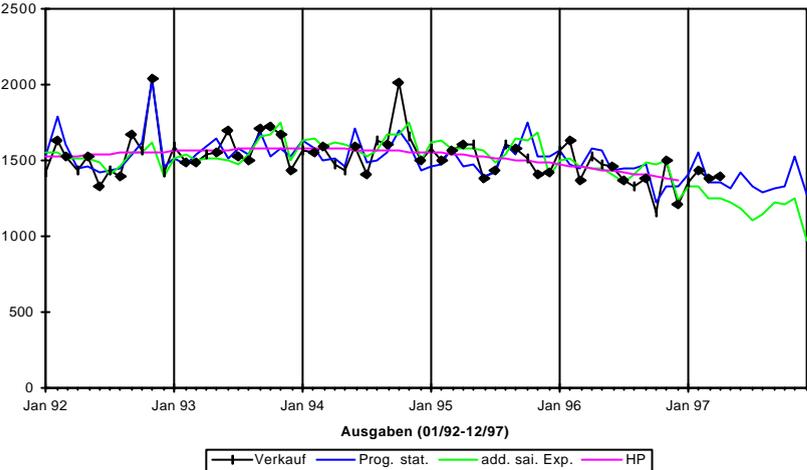
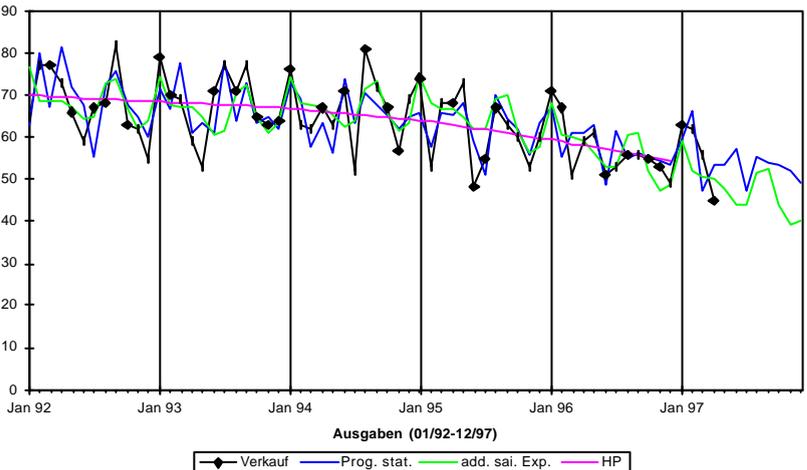
Die Modelle der übrigen fünf Grossisten, die dem Modelltyp 2 angehören, enthalten alle neben der saisonalen ARIMA-Komponente eine lineare Trendkomponente. Unterschiede treten jedoch bei dem nicht saisonalen ARIMA-Teil auf. Lediglich die Grossisten Schmitz Gelsenkirchen und Kossmann Reutlingen weisen einen nicht saisonalen ARIMA-Teil in ihren Modellgleichungen auf.

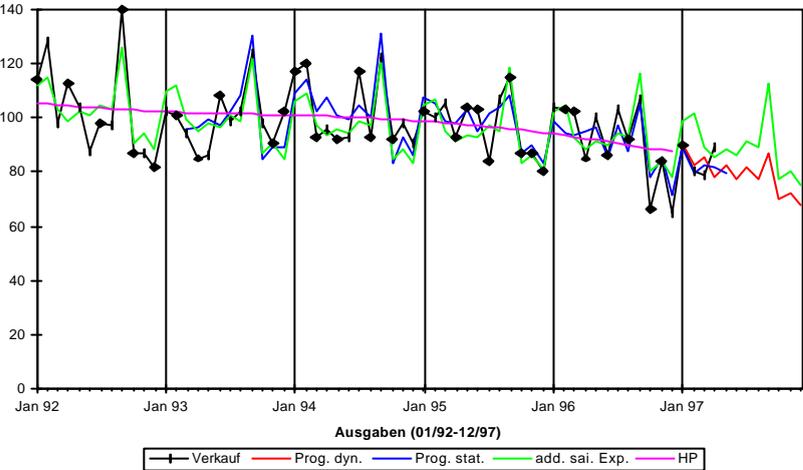
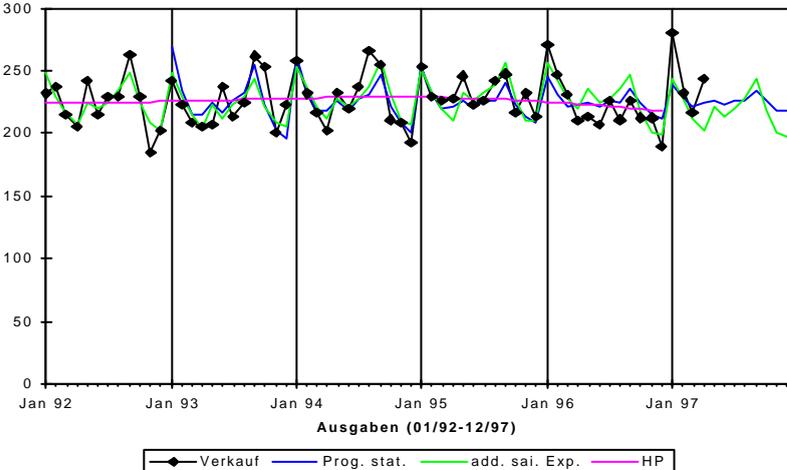
Sehr gute Anpassungen aber auch Prognosen, erzielt man mit der exponentiellen Glättung. Dabei wurde das Verfahren nach Holt-Winter mit Berücksichtigung einer additiven Saison favorisiert, da es neben der Trendentwicklung auch die saisonalen Schwankungen berücksichtigt.

Als Vergleichsmaß zwischen den geschätzten SARIMA-Modellen und den Verfahren der exponentiellen Glättung nach Holt-Winters mit additiver Saison werden die RMSE-Werte ausgewiesen.

Die RMSE-Werte der beiden Prognosemethoden unterscheiden sich nur geringfügig voneinander. Eine eindeutige Empfehlung für eine Methode lässt sich somit nicht abgeben. Vielmehr sollten beide Methoden zuerst parallel zur Anwendung kommen. Erst nach intensiver Validierung kann eine Entscheidung getroffen werden.

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
PVP Frankenthal	$\hat{y}_t = 400,2 - 2,255 t$ $+ 0,694 u_{t-12} - 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 237 ; 238 ; 228 ; 256 alle im Intervall RMSE = 13,26	Exp. Glättung Holt-Winters mit add. Saison RMSE = 13,28
<u>Modellprotokoll:</u> M.D. = 253 S.D. = 21,3 S.E. = 13,4 DW = 2,10 $R_A^2 = 0,60$ F-ST = 24,9 W(F) = 0,000			
Kaschewitz Gelsenkirchen	$\hat{y}_t = 398,6 - 1,202 t$ $+ 0,396 u_{t-1} + 0,490 u_{t-12}$ $- 0,194 u_{t-13} - 0,285 e_{t-1}$ $- 0,245 e_{t-2} - 0,856 e_{t-12}$ $+ 0,244 e_{t-13} + 0,210 e_{t-14}$ (Linearer Trend + SARIMA(1, 0, 2)(1, 0, 1))	Realisationen: 381 ; 405 ; 362 ; 320 Wert 97:2 u. 97:3 <u>nicht</u> im Intervall RMSE = 23,7	Exp. Glättung Holt-Winters mit add. Saison RMSE = 21,4
<u>Modellprotokoll:</u> M.D. = 350 S.D. = 31,7 S.E. = 18,4 DW = 1,79 $R_A^2 = 0,66$ F-ST = 16,2 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
B & B Hamburg	$\hat{y}_t = 1657,9 - 3,920 t + 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 1357 ; 1440 ; 1382 ; 1392 alle im Intervall RMSE = 98,1	Exp. Glättung Holt-Winters mit add. Saison RMSE = 118,3
<u>Modellprotokoll:</u> M.D. = 1525 S.D. = 146,6 S.E. = 101,3 DW = 1,68 $R_A^2 = 0,52$ F-ST = 33,3 W(F) = 0,000			
Schmitz Remscheid	$\hat{y}_t = 73,4 - 0,281 t + 0,879 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 63 ; 62 ; 56 ; 45 alle im Intervall RMSE = 5,9	Exp. Glättung Holt-Winters mit add. Saison RMSE = 6,4
<u>Modellprotokoll:</u> M.D. = 64 S.D. = 8,7 S.E. = 6,1 DW = 2,43 $R_A^2 = 0,51$ F-ST = 31,2 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Kossmann Reutlingen	$\hat{y}_t = 210,0 - 1,592 t$ $-0,098 u_{t-1} + 0,378 u_{t-2}$ $+0,750 u_{t-12} + 0,074 u_{t-13}$ $-0,284 u_{t-14} - 0,873 e_{t-12}$ (Linearer Trend + SARIMA(2, 0, 0)(1, 0, 1))	Realisationen: 90 ; 80 ; 79 ; 89 alle im Intervall RMSE = 7,6	Exp. Glättung Holt-Winters mit add. Saison RMSE = 8,4
<u>Modellprotokoll:</u> M.D. = 97 S.D. = 12,7 S.E. = 7,9 DW = 2,02 $R_A^2 = 0,61$ F-ST = 15,1 W(F) = 0,000			
Siegerland Scheuerfeld	$\hat{y}_t = 226,8 + 0,744 u_{t-12}$ $- 0,839 e_{t-12}$ (Linearer Trend + SARIMA(0; 0; 0)(1; 0; 1))	Realisationen: 280 ; 232 ; 217 ; 244 Wert 97:1 <u>nicht</u> im Intervall RMSE = 14,6	Exp. Glättung Holt-Winters add. Saison RMSE = 12,8
<u>Modellprotokoll</u> M.D. = 227 S.D. = 19,3 S.E. = 14,0 DW = 1,41 $R_A^2 = 0,47$ F-ST = 22,0 W(F) = 0,000			

Es gilt: 1) $t = 1$ für 01/92

$$2) e_{t-12} = y_{t-12} - \hat{y}_{t-12}$$

$$3) u_{t-12} = y_{t-12} - (c(1) - c(2)t) \quad \text{oder} \quad u_{t-12} = y_{t-12} - c(1)$$

(Linearer Trend) (Intercept)

Im Vergleich zu den Prognoseverfahren der exponentiellen Glättung (Holt-Winters mit additiver Saison) muss die Frage gestellt werden, ob sich die Implementierung der Modelle (linearer Trend plus saisonalem ARIMA-Term) überhaupt lohnt, da die Prognoseleistung (gemessen am RMSE) der beiden Methoden nur geringfügig voneinander abweicht. Eine Antwort kann erst in ein paar Jahren durch eine Validierung der Modelle gegeben werden, wenn deutlich mehr Beobachtungswerte vorliegen. Bis dahin ist es sinnvoll, beide Modelle zu verwenden.

Fraglich ist zum Beispiel die Stabilität des verwendeten linearen Trends im Modell des Grossisten B&P Hamburg, die Trendfilterung mit Hilfe des HP-Filters ergibt einen nicht linearen Verlauf der Zeitreihe, sie enthält einen Wendepunkt. Bis Anfang 1994 steigt die HP-Kurve minimal an, danach stagniert sie, um ab Anfang 1995 leicht zu sinken. Das Problem ließe sich dadurch umgehen, dass lediglich die Zeitreihenwerte von 94 bis 96 bei der Modellbildung berücksichtigt werden. Der Zeitraum von drei Jahren ist aber zu kurz, um einen MA(12)-Koeffizienten in die Modellschätzung aufzunehmen. Der Schätzwert wäre recht instabil.

Klasse 2 - Modelltyp 3 (Mit einfacher Differenzenbildung)

Zu diesem Typ werden die Zeitreihen der zwei Grossisten Jost Ingolstadt und Mügge Stade zusammengefasst, die erst durch Bildung von Differenzen der ersten Ordnung die Stationaritätsbedingung erfüllen. Zur Modellierung der Zusammenhänge bietet sich die Klasse der ARIMA(p,1,q)-Modelle an, da die beobachteten Zeitreihenwerte annähernd normalverteilt sind und einen symmetrischen Verlauf aufweisen.

Die Bestimmung der ARIMA(p,1,q)-Ordnung erfolgt recht pragmatisch mit dem Informationskriterium von Schwarz (SC). Dabei werden wiederum alle 16 Kombinationen der Parameter p und q von 0 bis 3 getestet. Auf die Matrix der SC Werte wird dann der Test von Poskitt und Tremayne angewandt. Als Ergebnis des Tests erhält man ein Modellportfolio, aus dem das geeignete Modell ausgewählt wird. Das ausgewählte Modell muss invertierbar und plausibel sein und die Parameterschätzer sollten signifikant von Null verschieden sein.

In den ARIMA-Gleichungsmodellen für die differenzierten Zeitreihen weicht der Intercept nicht signifikant von Null ab und wird daher aus den Gleichungen ausgeschlossen.

Mügge Stade

Als erstes werden die Ergebnisse des Grossisten Mügge Stade dargestellt. Die Identifikation der Ordnung des ARIMA(p,1,q)-Modells gestaltet sich recht einfach. Das Korrelogramm der differenzierten Zeitreihe verdeutlicht, dass die Reihe keinerlei saisonale Einflüsse aufweist, signifikante Abweichungen der ACF und PACF gibt es aber für die lags 1, 3 und 7.

Auch für diesen Grossisten werden alle ARIMA-Modelle bis zur dritten Ordnung berechnet. Als Selektionskriterium gilt wiederum das SC. Der minimalste Wert des SC liegt für das ARIMA(0,1,1)-Modell vor.

Stade		MA(q)			
		0	1	2	3
AR(p)	0	/	5,423	5,480	5,530
	1	5,692	5,480	5,504	5,480
	2	5,746	5,560	5,467	5,081 ¹⁾
	3	5,481	5,550	5,517	5,496

zu 1) Prozess ist nicht invertierbar und damit nicht stationär.

Als zusätzliche Entscheidungshilfe wird der Poskitt-Tremayne-Test durchgeführt. Das Modellportfolio enthält lediglich das ARIMA(0; 1; 1)-Modell, da für alle anderen Modelle der Wert $R > 3,162$ ist.

Stade		MA(q)			
		0	1	2	3
AR(p)	0	/	1,00	5,374	23,488
	1	>100	5,374	10,908	5,374
	2	>100	56,912	3,662	/
	3	5,534	42,373	16,007	8,615

Die Residuen des berechneten ARIMA(0,1,1)-Modells genügen der Normalverteilung ($J.B. = 2,84$ ($W(J.B.) = 0,24 \geq \alpha = 0,05$)). Das Korrelogramm der Residuen besitzt noch leichte positive Korrelation für die ACF und PACF des lags 4 und negative Korrelation für lag 7 der ACF. Das Ergebnis ist aber durchaus akzeptabel, da alternative Modelle nicht existieren. Bei der Betrachtung der Tabelle mit den SC-Werten fällt das ARIMA(2; 1; 3)-Modell ins Auge. Der Wert des SC ist deutlich der geringste, aber das Modell liefert Koeffizienten, die zu einem nicht invertierbaren Prozess führen.

Jost Ingolstadt

Die Zeitreihe des Grossisten Jost Ingolstadt erfordert ebenfalls zur Erfüllung der Stationaritätsbedingung die Differenz der Ordnung 1.

Das Korrelogramm der differenzierten Zeitreihe besitzt besonders deutliche Ausschläge für die ersten lags. Signifikant negative AC- und PAC-Werte werden für lag 1 und 3 erzielt. Lag 4 besitzt nur für die ACF einen signifikant positiven Wert. Hinweise auf saisonale Einflüsse lassen sich nicht erkennen.

Mit dem Test von Poskitt und Tremayne gelangt man zu dem Ergebnis, dass ein ARIMA(3,1,3)-Modell zu einer recht guten Anpassung führt.

Ingolstadt				
LS // Dependent Variable is D(VERKAUF)				
Sample(adjusted): 1992:05 1996:12				
Included observations: 56 after adjusting endpoints				
Convergence achieved after 40 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.737	0.129	-5.716	0.000
AR(2)	-0.866	0.106	-8.138	0.000
AR(3)	-0.491	0.129	-3.797	0.000
MA(1)	-0.039	0.084	-0.467	0.643
MA(2)	0.426	0.103	4.156	0.000
MA(3)	-0.749	0.001	-899.462	0.000
R-squared	0.657	Mean dependent var		-0.339
Adjusted R-squared	0.623	S.D. dependent var		21.823
S.E. of regression	13.395	Akaike info criterion		5.291
Sum squared resid	8971.396	Schwarz criterion		5.508
Log likelihood	-221.601	F-statistic		19.196
Durbin-Watson stat	1.884	Prob(F-statistic)		0.000
Inverted AR Roots	-.06+.89i	-.06 -.89i		-0.62
Inverted MA Roots	0.76	-.36 -.92i		-.36+.92i

Bis auf den MA(1)-Parameter sind alle Parameter des ARIMA(3,1,3)-Modells hoch signifikant von Null verschieden. Die Residuen der Modellschätzung genügen der Normalverteilung ($J.B. = 0,70$ ($W(J.B.) = 0,71 \geq \alpha = 0,05$)) und besitzen keine signifikanten AC- und PAC-Parameter.

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Jost Ingolstadt	$D(\hat{y}_t)_{1;0} = -0,737 u_{t-1} - 0,866 u_{t-2} - 0,491 u_{t-3} - 0,039 e_{t-1} + 0,426 e_{t-2} - 0,749 e_{t-3}$ (Diff. Δ^1 + ARIMA(3, 1, 3))	Realisationen: 123 ; 138 ; 125 ; 116 alle im Intervall RMSE = 13,36	Exp. Glättung Holt-Winters ohne Saison RMSE = 15,64
<u>Modellprotokoll:</u> M.D. = -0,34 S.D. = 21,8 S.E. = 13,9 DW = 1,88 $R_A^2 = 0,62$ F-ST = 19,2 W(F) = 0,000			
Mügge Stade	$D(\hat{y}_t)_{1;0} = -0,884 e_{t-1}$ (Diff. Δ^1 + ARIMA(0, 1, 1))	Realisationen: 189 ; 164 ; 168 ; 201 alle im Intervall RMSE = 14,64	Exp. Glättung Holt-Winters ohne Saison RMSE = 14,2
<u>Modellprotokoll:</u> M.D. = -0,07 S.D. = 18,5 S.E. = 14,7 DW = 1,77 $R_A^2 = 0,37$			

5.2.3 Klasse 3 - Signifikante Ausschläge der ACF und PACF auf lag 1

Die Zeitreihen, die zur Klasse drei zusammengefasst wurden, lassen kaum systematische Strukturen in ihrer graphischen Darstellung erkennen, besitzen aber alle ein ähnliches Profil in den Korrelogrammen. Alle Zeitreihen weisen einen signifikant positiven Wert auf lag 1 der ACF und der PACF auf. Darüber hinaus wurde bei einem Teil der Zeitreihen eine leichte positive signifikante Abweichung auf dem lag 12 der ACF festgestellt.

Der Haupteffekt im Korrelogramm liegt aber auf lag 1, was sich auch in der Q-Statistik zeigt. Die meisten der Zeitreihen besitzen deutlich signifikante Werte schon für das erste lag, die zur Verwerfung der Nullhypothese auf Unabhängigkeit der Zeitreihenwerte führen.

Bei den Zeitreihen der Klasse 3 handelt es sich, bis auf die Zeitreihe für den Grossisten Wehling Bielefeld, um stationäre Zeitreihen.

Zwei der Zeitreihen sind trendstationär, die restlichen genügen schon mit Berücksichtigung des Intercepts der Stationaritätsbedingung. Interessant ist dabei die Zeitreihe des Grossisten NPV Würzburg. Um einen stationären Prozess zu erhalten, ist der Einbau eines verzögerten Terms für die differenzierten Zeitreihenwerte in der Testgleichung des ADF-Tests mit einer lag Länge von 9 erforderlich. Nur so erhält man eine Testgleichung, deren Residuen keinerlei systematische Strukturen mehr enthalten. Für die anderen Zeitreihen genügt ein verzögerter Term der lag Länge von höchstens 1. Die Autokorrelationsproblematik der Residuen ist bei ihnen von untergeordneter Bedeutung.

Neben der Stationaritätsbedingung erfüllen fast alle Zeitreihen der Klasse 3 die Annahme auf Normalverteilung. Lediglich für den Grossisten Umbreit Bietigheim muss die Annahme der Normalverteilung verworfen werden. Die Realisationen der Prüfgrößen für die Schiefe, Wölbung und Jarque-Bera-Statistik liegen eindeutig im Ablehnungsbereich der Normalverteilungshypothese.

Der Test von Neftci führt lediglich für den Grossisten Wehling Bielefeld zu einer Verwerfung der Hypothese auf Symmetrie der Zeitreihenwerte.

Bei vielen Zeitreihen der Klasse 3 weichen die Ergebnisse der beiden Unabhängigkeitstests (Box-Ljung- und Runs-Test) sehr stark voneinander ab. Mit der Ljung-Box Q-Statistik gelangt man bis auf den Grossisten Umbreit Bietigheim zur Verwerfung der Nullhypothese auf Unabhängigkeit der Zeitreihenwerte. Mit dem Runs-Test hingegen lassen sich nur für drei der vierzehn Zeitreihen die Ergebnisse des Box-Ljung-Tests bestätigen.

Klasse 3	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig		H ₀ : Symmetrie H ₁ : keine Symmetrie
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	Matrix der geschätzten Übergangswahrsch.
Falter Aachen	ADF = -5,45 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		$ \vartheta_1 = 1,24 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,14 \leq t_{\alpha} = 1,96$ $S = 2,84 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,84 ≥ α = 0,05 ⇒ H ₀	Für die meisten lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,002 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,33 & 0,67 \\ 0,71 & 0,29 \end{pmatrix}$ ⇒ H ₀
Stemmler Aachen	ADF = -5,11 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 4 u. 8 signif.		$ \vartheta_1 = 0,654 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,046 \leq t_{\alpha} = 1,96$ $S = 0,43 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,69 ≥ α = 0,05 ⇒ H ₀	Für lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,002 ≤ α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,35 & 0,65 \\ 0,63 & 0,37 \end{pmatrix}$ ⇒ H ₀
Wehling Bielefeld	ADF = -5,36 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		$ \vartheta_1 = 0,98 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,19 \leq t_{\alpha} = 1,96$ $S = 1,00 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,97 ≥ α = 0,05 ⇒ H ₀	Für lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,30 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,49 & 0,51 \\ 0,74 & 0,26 \end{pmatrix}$ ⇒ H ₁
Umbreit Bietigheim	ADF = -5,51 < k _(1%) = -3,54 ⇒ H ₁ (lag 0)		$ \vartheta_1 = 2,32 > t_{\alpha} = 1,96$ $ \vartheta_2 = 4,97 > t_{\alpha} = 1,96$ $S = 30,1 > \chi^2_k = 5,99 \Rightarrow H_1$	W(K-S) = 0,15 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 1 gilt: W(Q-Stat.) ≥ α = 0,05 ⇒ H ₀	W(RT) = 0,94 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,32 & 0,68 \\ 0,66 & 0,34 \end{pmatrix}$ ⇒ H ₀
Pest Bonn	ADF = -5,60 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+		$ \vartheta_1 = 0,08 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,72 \leq t_{\alpha} = 1,96$ $S = 0,52 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,72 ≥ α = 0,05 ⇒ H ₀	Für lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,12 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,36 & 0,64 \\ 0,67 & 0,33 \end{pmatrix}$ ⇒ H ₀

Klasse 3	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	
Grossist	ADF-Test					Matrix der geschätzten Übergangswahrsch.
Muggenthaler Cham	ADF = -5,69 < $k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0)	$ \vartheta_1 = 0,30 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,72 \leq t_{\alpha} = 1,96$ $S = 0,60 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,69 $\geq \alpha = 0,05 \Rightarrow H_0$	Für lag 1, 2, 3, 4, 6 gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,07 $\geq \alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,45 & 0,55 \\ 0,75 & 0,25 \end{pmatrix}$ $\Rightarrow H_0$ (mit HP)
Oechelhaeuser Denkendorf	ADF = -4,33 < $k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0)	$ \vartheta_1 = 0,94 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,11 \leq t_{\alpha} = 1,96$ $S = 2,18 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,43 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags außer 23, 24 gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,19 $\geq \alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,28 & 0,72 \\ 0,70 & 0,30 \end{pmatrix}$ $\Rightarrow H_0$ (mit HP)
Zöttl Ergolding	ADF = -5,91 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 1 u. det. Trend)	$ \vartheta_1 = 0,06 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,77 \leq t_{\alpha} = 1,96$ $S = 0,60 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,52 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags außer 3 gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,48 $\geq \alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,55 & 0,45 \\ 0,57 & 0,43 \end{pmatrix}$ $\Rightarrow H_0$
PVG Frankfurt	ADF = -5,77 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 1 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 1,04 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,19 \leq t_{\alpha} = 1,96$ $S = 1,13 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,58 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,02 < $\alpha = 0,05 \Rightarrow H_1$	$\begin{pmatrix} 0,44 & 0,56 \\ 0,66 & 0,34 \end{pmatrix}$ $\Rightarrow H_0$ (mit HP)
PV-Saar Saarbrücken	ADF = -5,09 < $k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0)	$ \vartheta_1 = 1,10 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,05 \leq t_{\alpha} = 1,96$ $S = 1,22 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,32 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,48 $\geq \alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,34 & 0,66 \\ 0,65 & 0,35 \end{pmatrix}$ $\Rightarrow H_0$
Esser Hürth	ADF = -5,69 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 2 u. det. Trend)	$ \vartheta_1 = 1,34 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,41 \leq t_{\alpha} = 1,96$ $S = 1,96 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,77 $\geq \alpha = 0,05 \Rightarrow H_0$	Für alle lags außer 3 gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,09 $\geq \alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,36 & 0,64 \\ 0,84 & 0,16 \end{pmatrix}$ $\Rightarrow H_0$

Klasse 3	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 15)	Runs-Test (RT) (Berechnung mit arith. Mittel)	
Grossist	ADF-Test					Matrix der geschätzten Übergangswahrsch.
Ifoton Limburgerhof	ADF = -3,68 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 0,87 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,36 \leq t_{\alpha} = 1,96$ $S = 2,62 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,64 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,04 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,46 & 0,54 \\ 0,56 & 0,44 \end{pmatrix}$ ⇒ H ₀
Lehmann Oldenburg	ADF = -3,83 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 1) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 0,75 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,08 \leq t_{\alpha} = 1,96$ $S = 0,57 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,90 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,61 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,38 & 0,62 \\ 0,74 & 0,26 \end{pmatrix}$ ⇒ H ₀
Wehling Paderborn	ADF = -5,29 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0)	$ \vartheta_1 = 1,94 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,70 \leq t_{\alpha} = 1,96$ $S = 4,26 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,89 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 4, 5, 23, 24 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,02 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,41 & 0,59 \\ 0,58 & 0,42 \end{pmatrix}$ ⇒ H ₀
Schiessl Regensburg	ADF = -5,80 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend)	$ \vartheta_1 = 0,58 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,09 \leq t_{\alpha} = 1,96$ $S = 0,34 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,77 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 3 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,61 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,38 & 0,62 \\ 0,70 & 0,30 \end{pmatrix}$ ⇒ H ₀
Haberer Schopfheim	ADF = -5,20 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0)	$ \vartheta_1 = 0,32 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,16 \leq t_{\alpha} = 1,96$ $S = 0,13 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,66 ≥ α = 0,05 ⇒ H ₀	Für alle lags außer 8, 9, 10 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,10 ≥ α = 0,05 ⇒ H ₀	$\begin{pmatrix} 0,46 & 0,54 \\ 0,65 & 0,35 \end{pmatrix}$ ⇒ H ₀
NPV Würzburg	ADF = -4,16 < $k_{(1\%)} = -3,57$ ⇒ H ₁ (lag 9)	$ \vartheta_1 = 1,74 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,95 \leq t_{\alpha} = 1,96$ $S = 3,93 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,34 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,49 & 0,51 \\ 0,53 & 0,47 \end{pmatrix}$ ⇒ H ₀

Die Modelle dieser Klasse lassen sich in zwei Typen unterteilen, Modelltyp 1 ohne und Modelltyp 2 mit Berücksichtigung der Saison.

Klasse 3 - Modelltyp 1 (Ohne Saison)

Zu diesem Typ werden die Zeitreihen der sechs Grossisten Falter Aachen, Stemmler Aachen, Wehling Bielefeld, Umbreit Bietigheim, Muggenthaler Cham und Schiessl Regensburg zusammengefasst. Alle Zeitreihen besitzen einen positiven signifikanten Wert auf lag 1 der ACF und PACF.

Keine der sechs Zeitreihen enthält in ihrer ACF und PACF Hinweise auf einen saisonalen Einfluss.

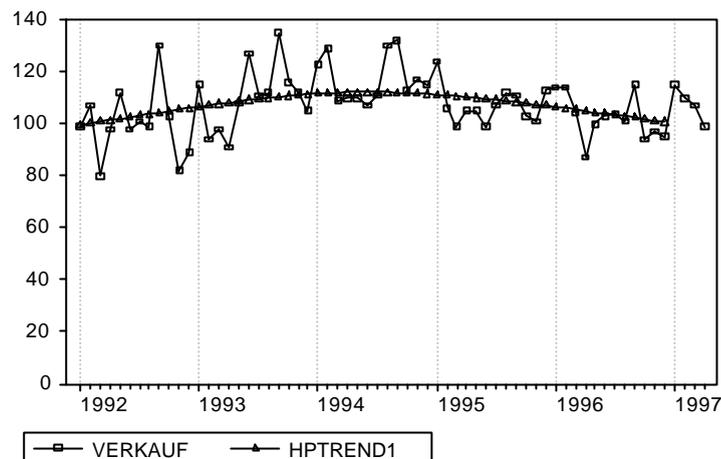
Vier der sechs Zeitreihen lassen einen Wendepunkt in der mittelfristigen Entwicklung der Verkaufszahlen vermuten. Die Identifikation der Wendepunkte erfolgte anhand des HP-Filters, der sich unabhängig von dem Modellkonzept sehr gut zur Beschreibung der Trendentwicklung von Zeitreihen eignet. An dieser Stelle sei noch einmal auf die Arbeiten von Hillinger²⁰⁴ verwiesen, der herausfand, dass unabhängig vom Modellkonzept, der HP-Filter zu sehr guten Ergebnissen in der Trendbeschreibung führt.

Bei allen vier Zeitreihen, bei denen ein Wendepunkt identifiziert wurde, fällt dieser zeitlich in die erste Hälfte des Jahres 1994.

Stemmler Aachen

Beispielhaft für die Grossisten, deren Verkaufszahlen einen Wendepunkt aufweisen, wird die Modellentwicklung für den Grossisten Stemmler Aachen ausführlich dargestellt. Die folgende Graphik enthält neben den Verkaufswerten die um den HP-Filter geglätteten Werte.

²⁰⁴ Hillinger/Reiter/Woitek 1992.



Der Trend steigt für die Jahre 92 und 93 konstant an. Anfang bis Mitte 94 kehrt er sich dann um, die Verkaufszahlen nehmen seitdem konstant ab. Der Stützbereich für die Modellentwicklung wird daher auf die Jahre 94 bis 96 eingeschränkt. Der Wendepunkt kann bei der Modellberechnung nicht modelliert werden, da sich aus dem kurzen Zeitraum von fünf Jahren keine Gesetzmäßigkeit über das zukünftige Auftreten weiterer Wendepunkte ableiten lässt.

Die Zeitreihe ist im Stützbereich von 94 bis 96 trendstationär, die Normalverteilungshypothese für die Verkaufswerte wird nicht verworfen ($J.B. = 1,02$ ($W(J.B.) = 0,60 \geq \alpha = 0,05$)) und das Korrelogramm weist hohe signifikant positive Werte für lag 1 der ACF und der PACF auf.

Ausgangspunkt der Modellentwicklung ist das deterministische Trendmodell. Da seine Residuen aber noch systematische Strukturen aufweisen, wird es um einen ARMA(p, q)-Fehlerterm erweitert. Berechnet werden die SC-Werte für alle Modellkombinationen bis zu einem ARMA(3, 3)-Fehlerterm:

$$\hat{y} = c(1) + c(2)t + \text{ARMA}(p, q)$$

Stemmler Aachen		MA(q)			
		0	1	2	3
AR(p)	0	4,345	4,334	4,433	4,254
	1	4,381	4,433	4,532	4,054 ¹⁾
	2	4,389	4,486	4,470	3,669 ¹⁾
	3	4,484	4,575	3,673 ¹⁾	4,435

zu 1) MA-Prozess ist nicht invertierbar.

Test von Poskitt Tremayne:

Stemmler Aachen		MA(q)			
		0	1	2	3
AR(p)	0	5,15	4,22	25,08	1,00
	1	9,84	25,08	149,01	/
	2	11,36	65,11	48,81	/
	3	62,80	323,11	/	26,00

Die drei Kombinationen, die die niedrigsten SC-Werte aufweisen, sind als Modell leider nicht geeignet, da die MA-Teile zu nicht invertierbaren Prozessen führen.

Als invertierbarer Prozess mit geringem SC-Wert kommt der ARMA(0,3)-Prozess zur Beschreibung des Fehlerterms in Frage. Der Test von Poskitt Tremayne bestätigt die signifikanten Unterschiede für den Wert des ARMA(0,3)-Fehlerterms gegenüber den anderen Kombinationen.

Aachen (Stemmler)				
LS // Dependent Variable is VERKAUF				
Sample: 1994:01 1996:12				
Included observations: 36				
Convergence achieved after 14 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	133.045	2.599	51.181	0.000
NUMMER	-0.571	0.060	-9.541	0.000
MA(1)	0.137	0.134	1.024	0.314
MA(2)	-0.501	0.112	-4.456	0.000
MA(3)	-0.608	0.142	-4.279	0.000
R-squared	0.579	Mean dependent var		108.861
Adjusted R-squared	0.524	S.D. dependent var		10.221
S.E. of regression	7.050	Akaike info criterion		4.034
Sum squared resid	1540.796	Schwarz criterion		4.254
Log likelihood	-118.699	F-statistic		10.641
Durbin-Watson stat	1.953	Prob(F-statistic)		0.000
Inverted MA Roots	0.99	-.56 -.54i		-.56+.54i

Bis auf den MA(1)-Parameter sind alle Koeffizientenschätzer signifikant von Null verschieden. Die MA-Wurzeln sind alle invertierbar und die DW-Statistik weicht nur geringfügig vom Wert 2 ab, die Residuen besitzen keinerlei signifikante Auto-korrelationswerte in den Korrelogrammen der ACF und PACF.

Auch genügt die Verteilung der Residuen mit hinreichender Genauigkeit der Normalverteilung (J.B. = 0,43 (W(J.B.) = 0,81 \geq α = 0,05)).

Letztendlich entscheidend für die praktische Qualität des Modells ist dessen Prognosefähigkeit. Dabei stellt sich heraus, dass eine Reduzierung des obigen Modells auf einen ARMA(0, 1)-Fehlerterm zu deutlich besseren Prognoseergebnissen führt.

Aachen Stemmler (deter.Trend + ARMA(0, 1))	
Actual: VERKAUF Forecast: VERK_EQ2S	
Sample: 1994:01 1997:12	
Include observations: 40	
Root Mean Squared Error	7.898
Mean Absolute Error	6.356
Mean Absolute Percentage Error	5.800
Theil Inequality Coefficient	0.036
Bias Proportion	0.011
Variance Proportion	0.118
Covariance Proportion	0.870

Aachen Stemmler (deter.Trend + ARMA(0, 3))	
Actual: VERKAUF Forecast: VERK_EQ2S	
Sample: 1994:01 1997:12	
Include observations: 40	
Root Mean Squared Error	10.109
Mean Absolute Error	8.642
Mean Absolute Percentage Error	8.204
Theil Inequality Coefficient	0.045
Bias Proportion	0.402
Variance Proportion	0.000
Covariance Proportion	0.597

Alle Fehlermaße besitzen für das Modell mit dem ARMA(0,1)-Term geringere Werte und unterstreichen damit die bessere Prognosefähigkeit des reduzierten Modells.

Aachen (Stemmler)				
LS // Dependent Variable is VERKAUF				
Sample: 1994:01 1996:12				
Included observations: 36				
Convergence achieved after 5 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	134.407	7.325	18.350	0.000
NUMMER	-0.602	0.167	-3.603	0.001
MA(1)	0.347	0.165	2.105	0.043
R-squared	0.443	Mean dependent var		108.861
Adjusted R-squared	0.409	S.D. dependent var		10.221
S.E. of regression	7.854	Akaike info criterion		4.202
Sum squared resid	2035.718	Schwarz criterion		4.334
Log likelihood	-123.713	F-statistic		13.135
Durbin-Watson stat	1.990	Prob(F-statistic)		0.000
Inverted MA Roots	-0.350			

Neben der voraussichtlich besseren Prognosefähigkeit und der höheren Stabilität durch Reduzierung der Anzahl der Variablen auf der rechten Seite der Schätzgleichung besitzt das Modell zufällig verteilte Residuen. Lediglich lag 10 der PACF hat einen leicht signifikant negativen Wert. Mit hoher Wahrscheinlichkeit genügen die Residuen der Normalverteilung. Die Realisation des Jarque-Bera-Tests liegt bei 0,741 und damit klar unterhalb der kritischen Grenze von 5,99.

Zusätzlich zu den Modellprognosen wurden die Verfahren der exponentiellen Glättung angewandt. Gemessen am mittleren quadratischen Fehler liefert das Verfahren der exponentiellen Glättung nach der Holt-Winter-Methode mit additiver Saison besonders gute Anpassungen, obwohl das Korrelogramm keinerlei Hinweise auf einen saisonalen Einfluss enthielt. Der Wert für den RMSE liegt mit 7.967 nur geringfügig über dem Wert für das Modell mit dem ARMA(0, 1)-Fehlerterm. Dabei wurde die exponentielle Glättung nach der Holt-Winter-Methode über den gesamten Zeitbereich der Jahre 92 bis 96 berechnet. Würde man hingegen den Zeitraum auf die Jahre 94 bis 96 einengen, so reduziert sich der RMSE auf 4,751.

Auch hier zeigt sich wiederum die hervorragende kurzfristige Prognosefähigkeit der Methoden der exponentiellen Glättung für Zeitreihen mit geringen systematischen Einflussfaktoren.

Die drei anderen Zeitreihen, die einen Wendepunkt in den Daten aufweisen, sind die Grossisten Falter Aachen, Wehling Bielefeld und Schiessl Regensburg. Bei allen dreien wird der Analysezeitraum ebenfalls auf die Jahre 94 bis 96 eingengt. Aus der genannten Gruppe werden die Analyseergebnisse der Grossisten Falter Aachen und Wehling Bielefeld ausführlicher vorgestellt.

Falter Aachen

Die Identifikation des Wendepunktes erfolgt ebenfalls mit Hilfe des HP-Filters. Bis Ende 1993 ist ein stetiger Anstieg der Verkaufswerte zu beobachten. Ab 1994 schwächt sich der Anstieg ab, die Verkaufswerte sind ab Mitte 94 schwach rückläufig. Hier ergeben sich die gleichen Probleme wie für den Grossisten Stemmler Aachen, über den gesamten Zeitraum von 92 bis 96 kann für die Zeitreihe keine stabile Schätzung ermittelt werden. Der Stützbereich wird daher auf die Jahre 94 bis 96 eingeschränkt. Inwieweit diese Vorgehensweise richtig ist, lässt sich nur an der späteren Validierung des entwickelten Modells feststellen.

Die Berechnungen der ACF und PACF für den verkleinerten Stützbereich weisen lediglich auf lag 1 einen schwach signifikanten Ausschlag auf, alle anderen Werte sind nicht signifikant von Null verschieden. Die Werte der Box-Ljung Q-Statistik liegen alle im Nicht-Ablehnungsbereich der Nullhypothese auf Unabhängigkeit, das deutet darauf hin, dass die Zeitreihe keine weiteren linearen Abhängigkeitsstrukturen aufweist.

Auch kann von einer Normalverteilung der Zeitreihenwerte ausgegangen werden, die Realisation der Prüfgröße der Jarque-Bera-Statistik liegt deutlich im Annahmehbereich der Nullhypothesen ($J.B. = 1,32$ ($0,52 \geq \alpha = 0,05$)).

Für den Grossisten Falter Aachen wird als Ausgangsmodell ebenfalls eine Gleichung mit deterministischem Trend favorisiert. Im Gegensatz zum Grossisten Stemmler Aachen bringt die Erweiterung des deterministischen Trendmodells um einen ARMA-Fehlerterm keine Verbesserung des Modells. Die schrittweise Überprüfung aller Fehlerterme bis zu einem ARMA(3, 3)-Fehlerterm führt zu keiner Reduzierung des SC gegenüber dem Ausgangsmodell.

Der Vergleich der Korrelogramme der Zeitreihen der Grossisten Falter Aachen und Stemmler Aachen bringt schon erste entscheidende Hinweise auf das obige Ergebnis. Die Korrelogramme der beiden Grossisten unterscheiden sich für lag 1 der ACF und PACF schon deutlich voneinander.

Der Grossist Stemmler Aachen weist hoch signifikante Werte für lag 1 der ACF und PACF auf. Für den Grossisten Falter Aachen hingegen ist die Signifikanz nur knapp erfüllt. Dieses Ergebnis bestätigt sich auch in den beiden Box-Ljung Q-Statistiken. Alle Realisationen der Q-Statistiken liegen für den Grossisten Falter Aachen im Nicht-Ablehnungsbereich der Nullhypothese. Für Stemmler Aachen liegen aufgrund der starken Autokorrelation des ersten lags die Realisationen der Q-Statistik von lag 1 bis lag 10 deutlich im Bereich der Alternativhypothese auf Abhängigkeit. Das Resultat der unterschiedlichen Abhängigkeitsstruktur spiegelt sich folglich in den jeweilig gewählten Modellen wider.

Wehling Bielefeld

Der ADF-Test für die Zeitreihe des Grossisten Wehling Bielefeld führte zum Ergebnis, dass die Reihe nicht stationär ist. Folglich wurde die Differenz der Zeitreihenwerte überprüft.

Der ADF-Test für die um die Ordnung 1 differenzierten Zeitreihe führt ebenfalls zu keinem befriedigenden Ergebnis auf Stationarität. Das Korrelogramm der Residuen weist auf lag 12 der ACF und der PACF einen starken positiven Ausschlag auf.

Die Untersuchung des langfristigen Verlaufs der Zeitreihe mittels HP-Filter verdeutlicht den Grund für die Stationaritätsprobleme. Die Zeitreihe besitzt 94 einen Wendepunkt. Bis Ende 93 ist ein klarer Aufwärtstrend zu beobachten. Ab 94 kehrt sich der Aufwärtstrend um in einen Abwärtstrend.

Der für die weitere Betrachtung relevante Stützbereich der Zeitreihe wird daher auf die Jahre 94 bis 96 eingengt. Wendet man auf die Verkaufswerte dieses Zeitraums den ADF-Test an, so erzielt man als Testergebnis eine klare Annahme der Stationaritätshypothese.

Bielefeld (Wehling)				
ADF Test Statistic	-5.369097	1% Critical Value*		-4.2324
		5% Critical Value		-3.5386
		10% Critical Value		-3.2009
*MacKinnon critical values for rejection of hypothesis of a unit root.				
Augmented Dickey-Fuller Test Equation LS // Dependent Variable is D(VERKAUF) Sample: 1994:01 1996:12 Included observations: 36				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
VERKAUF(-1)	-0.940	0.175	-5.369	0.000
C	582.042	108.782	5.351	0.000
@TREND(1:1994)	-3.214	0.897	-3.585	0.001
R-squared	0.469	Mean dependent var		-3.528
Adjusted R-squared	0.437	S.D. dependent var		60.380
S.E. of regression	45.321	Akaike info criterion		7.707
Sum squared resid	67781.500	Schwarz criterion		7.839
Log likelihood	-186.811	F-statistic		14.562
Durbin-Watson stat	1.759	Prob(F-statistic)		0.000

Auf Basis des obigen Ergebnisses wurde ein Modell entwickelt, das den abnehmenden Trendverlauf und den beobachtbaren Anstieg der Verkaufszahlen zu Beginn eines jeden Jahres beschreiben kann. Die Wahl fiel auf ein Modell mit deterministischem Trend und zwei Dummy-Variablen zur Erfassung der Verkaufssprünge in den Monaten Januar und Februar.

Bielefeld (Wehling)				
LS // Dependent Variable is VERKAUF				
Sample: 1994:01 1996:12				
Included observations: 36				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	667.045	25.465	26.195	0.000
NUMMER	-2.813	0.567	-4.960	0.000
DUMMY1	101.380	21.224	4.777	0.000
DUMMY2	43.194	21.133	2.044	0.049
R-squared	0.662	Mean dependent var		559.528
Adjusted R-squared	0.630	S.D. dependent var		56.763
S.E. of regression	34.517	Akaike info criterion		7.187
Sum squared resid	38126.390	Schwarz criterion		7.363
Log likelihood	-176.454	F-statistic		20.884
Durbin-Watson stat	2.011	Prob(F-statistic)		0.000

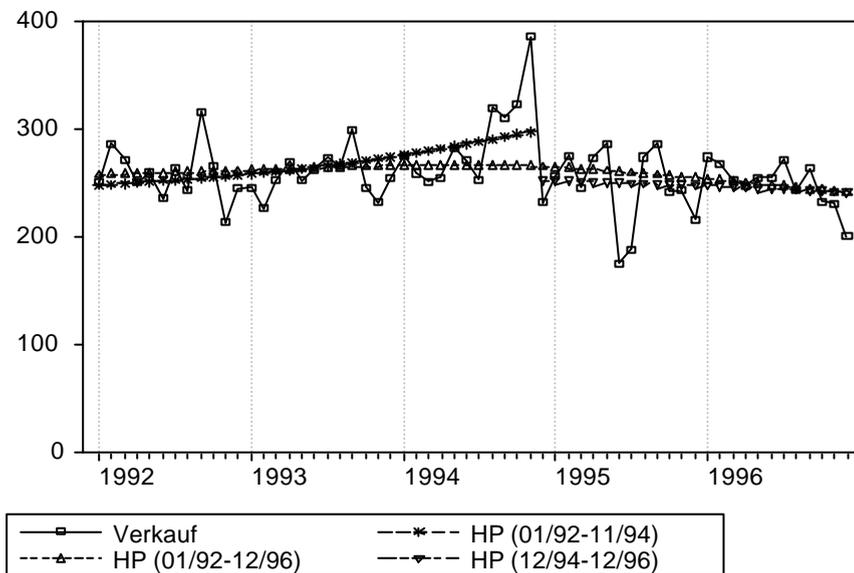
Das Modell führt im Vergleich zu den anderen Modellschätzungen der Klasse drei zu einem recht guten Ergebnis. Das bereinigte $R_A^2 = 0,63$ liegt deutlich über den Werten der meisten anderen Modellschätzungen. Die einzelnen Modellparameter sind alle mit hoher Wahrscheinlichkeit signifikant von Null verschieden. Die Residuen weisen keinerlei systematische Strukturen auf. Sie sind mit hoher Aussagesicherheit normalverteilt (J.B. = 1,267 (W(J.B.) = 0,531 $\geq \alpha = 0,05$)). Alle bis zum lag 16 untersuchten Werte der ACF und PACF der Residuen sind nicht signifikant von Null verschieden.

Bietigheim

Zum Schluss wird noch der Grossist Bietigheim näher untersucht, er nimmt eine Sonderstellung unter den Grossisten dieses Modelltyps ein. Bei den Identifikationstests kommt als Ergebnis heraus, dass die Zeitreihe stationär, abhängig und symmetrisch aber nicht normalverteilt ist. Die Zeitreihe besitzt mehrere sehr starke Schwankungen und Sprünge (siehe Graph auf Seite 188). Ein besonders starker Sprung tritt zwischen den Ausgaben 11/94 und 12/94 auf. Der Verkaufswert der Ausgabe 11/94 stellt sich als Ausreißer dar. Dieses Phänomen lässt sich in keinem Modell erfassen. Man hat daher nur zwei Möglichkeiten. Entweder betrachtet man die gesamte Zeitreihe von 1/92 bis 12/96. Dies bedeutet, dass der Werte von 11/94 als Ausreißer zu betrachten und dementsprechend zu bereinigen ist. Die andere Möglichkeit besteht in der Einschränkung des Stützbereichs auf den Zeitraum 12/94 bis 12/96. Dieser Zeitraum ist

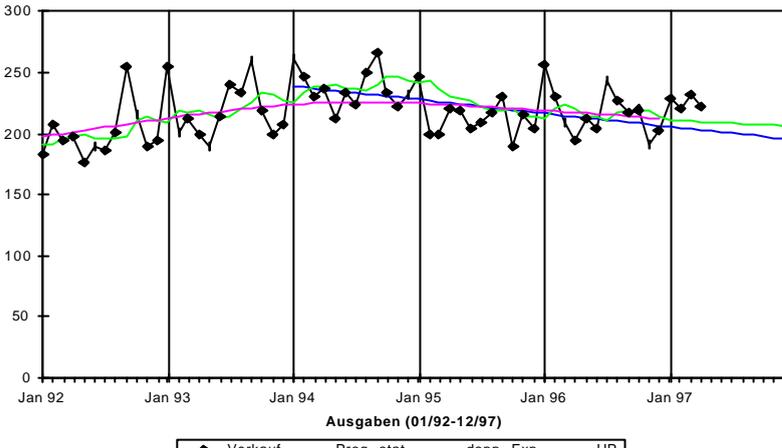
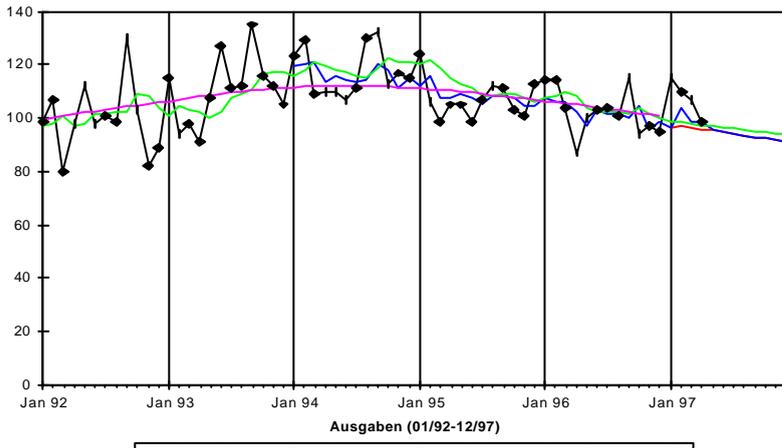
zwar sehr kurz, die Reduzierung des Stützbereichs könnte aber eine mögliche Alternative darstellen. Der Ausreißer ist ein tatsächlich realisierter Verkaufswert und sollte deshalb nicht so einfach geglättet werden. In der folgenden Graphik wird die Problematik der drastischen Niveauveränderung sehr deutlich. Neben dem HP-Filter für den gesamten Zeitraum von 01/92 bis 12/96 werden die HP-Filterwerte für die Stützbereiche 01/92 bis 11/94 und 12/94 bis 12/96 berechnet. Die unterschiedlichen Verläufe der HP-Filterwerte fallen sofort auf. Für den Zeitraum 01/92 bis 11/94 liegt ein positiv steigender Trend vor und für den Zeitraum 12/94 bis 12/96 ein fallender Trend. Weitere starke Schwankungen treten zwischen den Ausgaben 05/95 und 8/95 auf.

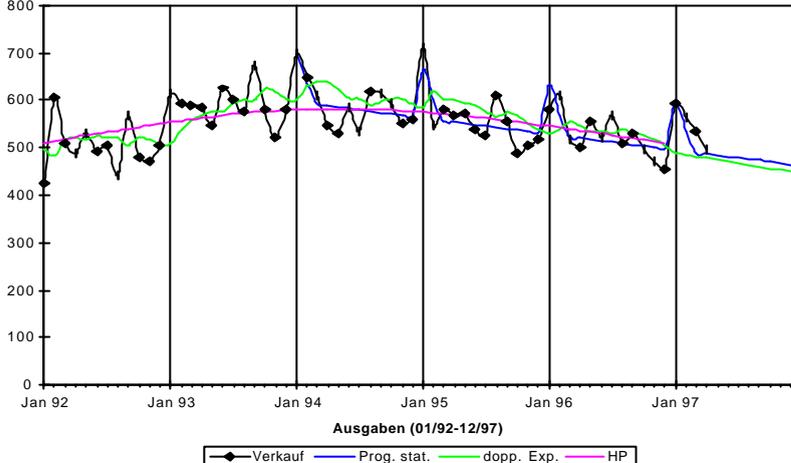
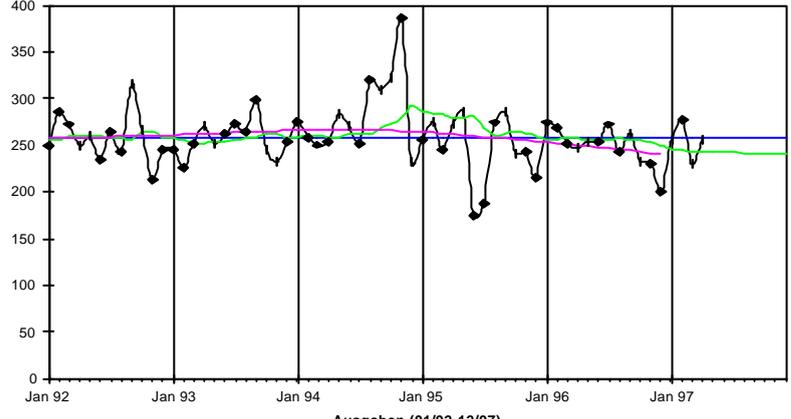
Für den Grossisten Bietigheim lässt sich kein vernünftiges Modell finden. Zur Prognose wird daher nur das arithmetische Mittel über alle Zeitreihenwerte verwendet.

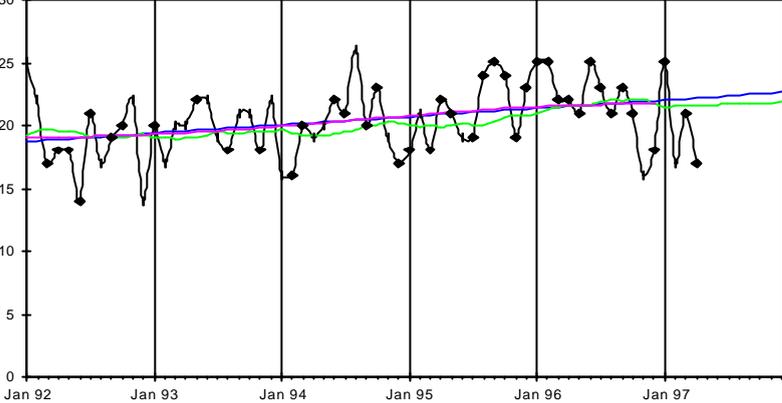
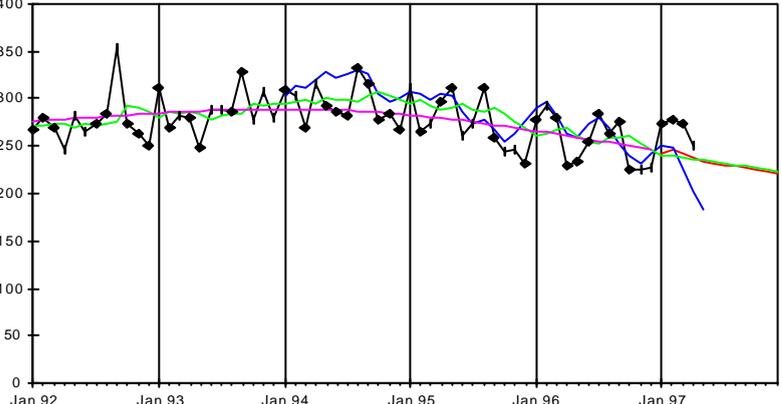


(EViews 2.0)

Die Tabellen auf den nächsten Seiten enthalten die Modellschätzungen aller Zeitreihen der Klasse 3, die keine saisonalen Komponenten aufweisen.

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Falter Aachen	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 261,1 - 0,902 t$	Realisationen: 228 ; 221 ; 232 ; 222 alle im Intervall RMSE = 17,4	Doppelte exp. Glättung ähnlich Trendmodell RMSE = 21,1
<u>Modellprotokoll:</u> M.D. = 223 S.D. = 19,5 S.E. = 17,3 DW = 1,61 $R_A^2 = 0,21$ F-ST = 10,5 W(F) = 0,003	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — dopp. Exp. — HP </p>		
Stemmler Aachen	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 134,4 - 0,602 t$ $+ 0,347 e_{t-1}$ (Linearer Trend + ARIMA(0, 0, 1))	Realisationen: 115 ; 110 ; 107 ; 99 Wert 97:1 <u>nicht</u> im Intervall RMSE = 7,9	Doppelte exp. Glättung ähnlich Modell RMSE = 11,2
<u>Modellprotokoll:</u> M.D. = 109 S.D. = 10,2 S.E. = 7,9 DW = 1,99 $R_A^2 = 0,41$ F-ST = 13,1 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. dyn. — Prog. stat. — dopp. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Wehling Bielefeld	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 667,0 - 2,813 t$ $+ 101,4 d_{Jan} + 43,2 d_{Feb}$ (Linearer Trend + Dummies: d_{Jan} , d_{Feb})	Realisationen: 594 ; 565 ; 536 ; 496 alle im Intervall RMSE = 32,1	Doppelte exp. Glättung ähnlich Modell RMSE = 53,0
<u>Modellprotokoll:</u> M.D. = 560 S.D. = 56,8 S.E. = 34,5 DW = 2,01 $R_A^2 = 0,63$ F-ST = 20,9 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — dopp. Exp. — HP </p>		
Umbreit Bietigheim	$\hat{y}_t = 259,1$	Realisationen: 257 ; 277 ; 230 ; 257 alle im Intervall RMSE = 31,6	Doppelte exp. Glättung liegt unterhalb der Modellprognose RMSE = 33,0
<u>Modellprotokoll:</u> M.D. = 259 S.D. = 32,6 S.E. = 32,6 DW = 1,42	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — dopp. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Muggenthaler Cham	$\hat{y}_t = 18,7 - 0,054 t$	Realisationen: 25 ; 17 ; 21 ; 17 alle im Intervall RMSE = 2,7	Doppelte exp. Glättung ähnlich Trendmodell RMSE = 2,7
<u>Modellprotokoll:</u> M.D. = 20 S.D. = 2,8 S.E. = 2,6 DW = 1,54 $R_A^2 = 0,10$ F-ST = 7,6 W(F) = 0,008	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—●— Verkauf — Prog. stat. — dopp. Exp. — HP</p>		
Schiessl Regensburg	<u>Stützb.: (01/94-12/96)</u> $\hat{y}_t = 355,1 - 1,865 t + 0,746 u_{t-1} + 0,380 u_{t-2} - 0,973 e_{t-1}$ (Linearer Trend + (ARIMA(2, 0, 1))	Realisationen: 274 ; 277 ; 274 ; 250 alle im Intervall RMSE = 24,7	Doppelte exp. Glättung RMSE = 24,8
<u>Modellprotokoll:</u> M.D. = 275 S.D. = 29,1 S.E. = 19,0 DW = 1,95 $R_A^2 = 0,57$ F-ST = 12,7 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;">—●— Verkauf — Prog. dyn. — Prog. stat. — dopp. Exp. — HP</p>		

Klasse 3 - Modelltyp 2 (Mit Saison)

Alle Zeitreihen, die zum Typ 2 zusammengefasst wurden, besitzen in den hier favorisierten Modellgleichungen einen saisonalen MA(12)-Term. Bei allen Modellgleichungen führt er zu einer deutlichen Verbesserung der Modellschätzung und Prognose, obwohl die ersten Identifikationsschritte nur auf recht geringe saisonale Effekte schließen ließen. Die graphischen Darstellungen der Zeitreihen des Typs 2 gaben keine erkennbaren Hinweise auf einen saisonalen Effekt und im Korrelogramm sind nur leicht signifikante Ausschläge auf lag 12 der ACF zu beobachten. In der Trenddarstellung mit Hilfe des HP-Filters treten in den Zeitreihen keine Wendepunkte auf, so dass eine Reduzierung des Stützbereichs bei keiner der Zeitreihen notwendig war. Bei sechs der zehn Zeitreihen wird ein linearer deterministischer Trend in die Modellgleichungen implementiert. Neben der Trendkomponente gibt es Zeitreihen, die zu sehr guten Ergebnissen durch Aufnahme eines zusätzlichen ARMA(p, q)-Fehlerterms gelangen. Bei zwei Zeitreihen gelangt man durch zusätzliche Implementierung eines AR(12)-Terms zu signifikanten Verbesserungen der jeweiligen Modelle. Exemplarisch werden die Grossisten Pest Bonn und PV-Saar Saarbrücken etwas ausführlicher vorgestellt.

Pest Bonn

Die Zeitreihe der Verkaufswerte des Grossisten Pest Bonn ist stationär und normalverteilt und besitzt eine eindeutige Abhängigkeitsstruktur. Für alle untersuchten lags von 1 bis 25 der Box-Ljung Q-Statistik liegen die Realisationen im Bereich der Alternativhypothese auf Abhängigkeit.

Die Analyse des Trendverlaufs der Verkaufszahlen mit Hilfe des HP-Filters weist einen konstanten Anstieg bis Anfang 94 auf. Danach flacht der Anstieg immer mehr ab, bis die geglätteten Werte ab 95 parallel zur Zeitachse verlaufen.

Analog der Vorgehensweise beim Typ 1 bietet sich eine Reduzierung des Stützbereichs auf den Zeitraum 94 bis 96 an. Aus zwei Gründen wird aber auf diese Vorgehensweise verzichtet. Der erste Grund liegt in dem geringen Erklärungsgehalt, den die getesteten Modelle aufweisen. Getestet wurden verschiedene ARMA(p,q) mit Intercept, mit oder ohne Hinzunahme eines deterministischen linearen Trends.

Der zweite Grund: Die Betrachtung des Korrelogramms weist für die Zeitreihe mit dem reduzierten Stützbereich lediglich auf lag 12 der ACF einen positiven signifikanten Ausschlag auf. Ein möglicher saisonaler Effekt lässt sich bei einer Zeitreihe, die lediglich drei Jahre umfasst, aber nicht stabil modellieren.

Bei der Betrachtung des Korrelogramms für die Zeitreihenwerte von 92 bis 96 lässt sich der signifikante Ausschlag auf lag 12 der ACF ebenfalls beobachten. Darüber hinaus gibt es noch weitere Ausschläge auf lag 1 (+), lag 4 (+), lag 5 (+) der ACF. Die PACF weist signifikante Abweichungen von Null auf lag 1 (+), lag 4 (+) und lag 14 (-) auf. Selbst der Zeitraum von fünf Jahren ist sehr kurz, um saisonale Effekte in die entwickelten Modelle aufnehmen zu können. Bei der Interpretation der Ergebnisse ist es daher nicht verwunderlich, wenn die saisonalen Schätzer recht instabil sind. Zur Modellierung des saisonalen Effektes werden zwei Kategorien von Modellen getestet, saisonale Dummies und saisonale ARIMA-Modelle, deterministischer versus stochastischer Ansatz.

Bonn (Pest)				
LS // Dependent Variable is VERKAUF				
Sample: 1992:01 1996:12				
Included observations: 60				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	280.200	10.798	25.949	0.000
DUMMY2	-23.400	15.271	-1.532	0.132
DUMMY3	-26.800	15.271	-1.755	0.086
DUMMY4	-36.400	15.271	-2.384	0.021
DUMMY5	-20.800	15.271	-1.362	0.180
DUMMY6	-19.800	15.271	-1.297	0.201
DUMMY7	-16.000	15.271	-1.048	0.300
DUMMY8	-1.800	15.271	-0.118	0.907
DUMMY9	2.600	15.271	0.170	0.866
DUMMY10	-29.200	15.271	-1.912	0.062
DUMMY11	-40.400	15.271	-2.646	0.011
DUMMY12	-35.600	15.271	-2.331	0.024
R-squared	0.293	Mean dependent var		259.567
Adjusted R-squared	0.132	S.D. dependent var		25.910
S.E. of regression	24.146	Akaike info criterion		6.545
Sum squared resid	27984.800	Schwarz criterion		6.964
Log likelihood	-269.489	F-statistic		1.813
Durbin-Watson stat	1.081	Prob(F-statistic)		0.078

Das Modell ist ausgesprochen schlecht, die meisten Dummy-Parameter sind nicht signifikant von Null verschieden, der Erklärungsgehalt der Regression fällt mit einem $R_A^2 = 0,132$ sehr gering aus. Bei einer vorgegebenen Wahrscheinlichkeit für den Fehler 1. Art fällt der F-Test in den Nicht-Ablehnungsbereich der Nullhypothese, das heißt, die Hypothese, dass alle Parameter mit Ausnahme des Intercepts nicht signifikant von Null abweichen, kann nicht verworfen werden.

Die Residuen enthalten noch sehr starke positive Korrelationen. Die Werte der ACF sind für lag 1 bis 9 und die Werte der PACF für lag 1 und 2 deutlich signifikant von Null verschieden. Die Modellierung mit saisonalen Dummies führt erwartungsgemäß zu einem sehr schlechten Modell.

Als andere Alternative empfiehlt sich die Modellierung eines SARIMA(p,d,q) (P,D,Q)₁₂-Modells. Da ein leichter saisonaler Effekt im Korrelogramm der Zeitreihe zu beobachten ist, wird mit der Bestimmung des saisonalen Terms begonnen. Dabei wird recht pragmatisch vorgegangen. Getestet werden die beiden Schätzer MA(12) und AR(12). Zuerst jeweils einzeln und dann gemeinsam. Bei allen drei Modellkombinationen wird als ein Parameter der Intercept verwendet. Die beste Modellanpassung erzielt man mit einem MA(12)-Term. Zusätzlich wurden ARMA-Kombinationen bis zum ARMA(3, 3)-Term getestet. Keine der ARMA(p,q)-Kombinationen konnte einen zusätzlichen Beitrag liefern. Somit ergibt sich das folgende Modell zur Schätzung der Verkaufszahlen für den Grossisten Pest Bonn.

Bonn (Pest)				
LS // Dependent Variable is VERKAUF				
Sample: 1992:01 1996:12				
Included observations: 60				
Convergence achieved after 41 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	265.004	4.524	58.579	0.000
MA(12)	0.886	0.000	8405.454	0.000
R-squared	0.514	Mean dependent var		259.567
Adjusted R-squared	0.506	S.D. dependent var		25.910
S.E. of regression	18.219	Akaike info criterion		5.838
Sum squared resid	19251.230	Schwarz criterion		5.907
Log likelihood	-258.266	F-statistic		61.333
Durbin-Watson stat	1.661	Prob(F-statistic)		0.000
Inverted MA Roots	.96+.26i	.96 -.26i	.70 -.70i	.70+.70i
	.26 -.96i	.26+.96i	-.26+.96i	-.26 -.96i
	-.70 -.70i	-.70 -.70i	-.96 -.26i	-.96+.26i

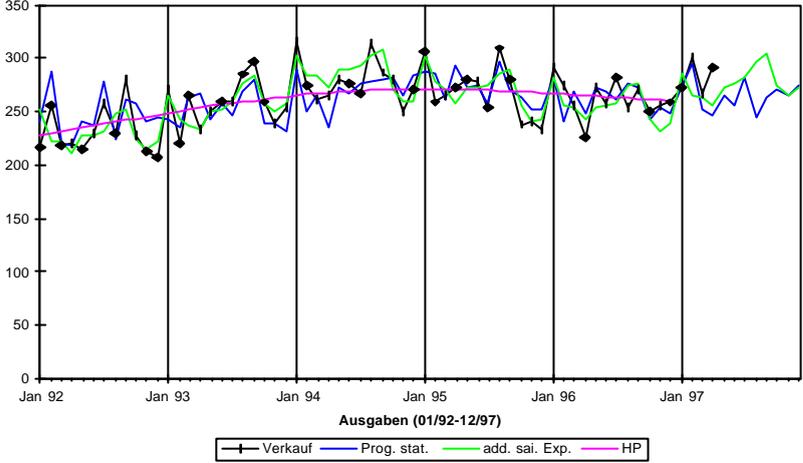
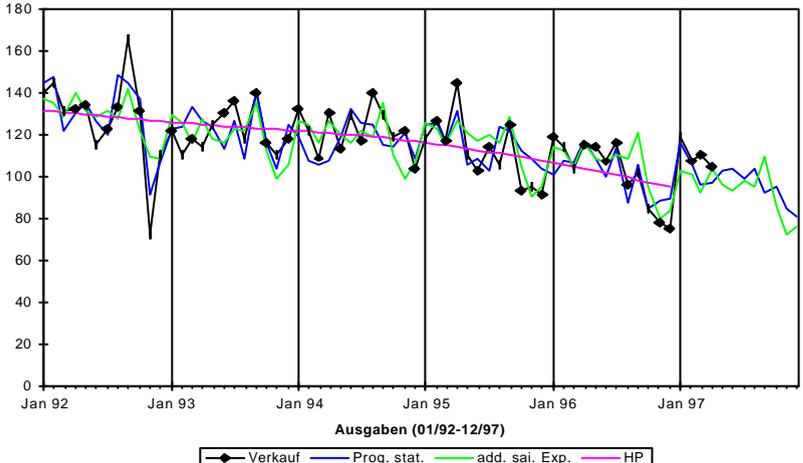
Die Residuen des Modells genügen der Normalverteilung (J.B. = 1,50 und (W(J.B.) = 0,472 $\geq \alpha = 0,05$)) und das Korrelogramm besitzt nur leichte positive signifikante Ausschläge auf lag 4 und 5 der ACF und PACF.

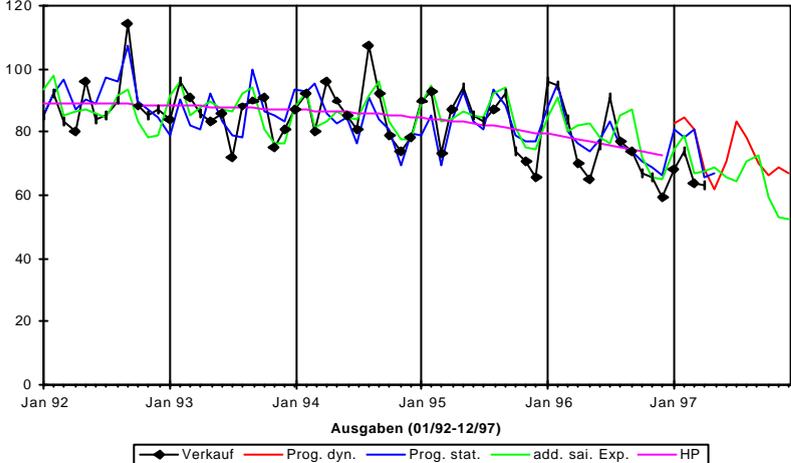
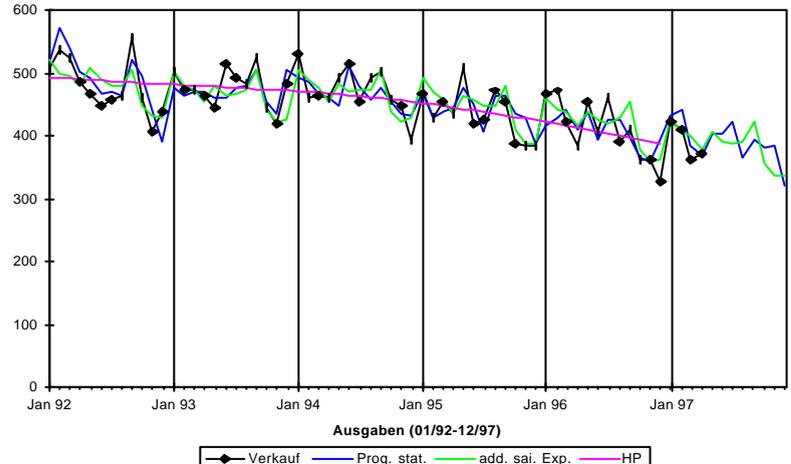
PV-Saar Saarbrücken

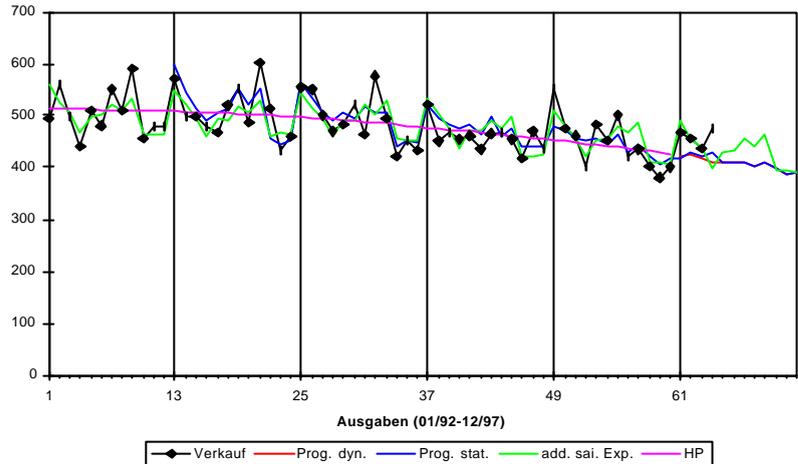
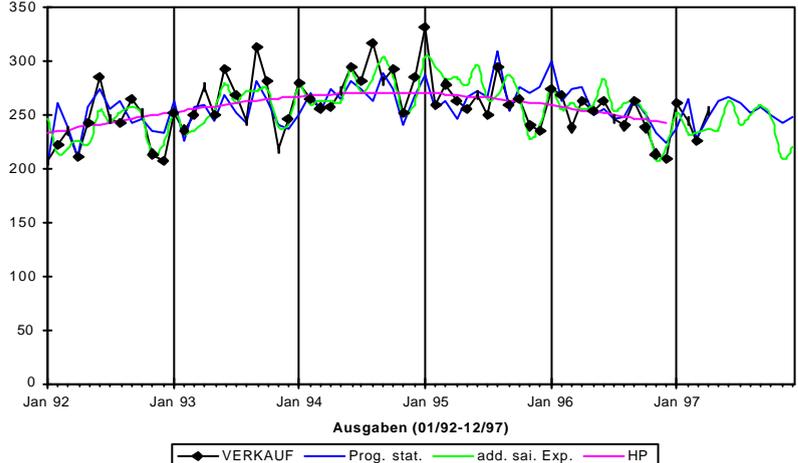
Die Zeitreihe für den Grossisten PV-Saar erfüllt die folgenden Bedingungen: Die Zeitreihe ist stationär, normalverteilt, besitzt eine klare Abhängigkeitsstruktur, die durch ein lineares Modell adäquat beschrieben werden kann, und der HP-Filter offenbart einen leichten negativen Trendverlauf der Werte. Analog der Vorgehensweise beim Grossisten Pest Bonn wurden drei Kombinationen des saisonalen ARIMA-Ansatzes getestet (AR(12), MA(12) und die Kombination von beiden). Als Selektionskriterium wurde zum einen die Signifikanz der jeweiligen Parameter und zum anderen die Höhe des SC verwendet. Das folgende Modell erwies sich unter den getesteten Modellen als optimal. Es besitzt Parameter, die sich signifikant von Null unterscheiden. Es weist den geringsten Wert für das SC aller getesteten Modelle auf und erzielt darüber hinaus eine gute Prognosequalität.

Saarbrücken PV Saar				
LS // Dependent Variable is VERKAUF				
Sample(adjusted): 1993:01 1996:12				
Included observations: 48 after adjusting endpoints				
Convergence achieved after 16 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	339.158	12.033	28.186	0.000
NUMMER	-1.997	0.261	-7.644	0.000
AR(12)	0.367	0.068	5.403	0.000
MA(12)	-0.886	0.000	-6838.168	0.000
R-squared	0.691	Mean dependent var		253.688
Adjusted R-squared	0.670	S.D. dependent var		29.083
S.E. of regression	16.698	Akaike info criterion		5.710
Sum squared resid	12268.720	Schwarz criterion		5.866
Log likelihood	-201.156	F-statistic		32.858
Durbin-Watson stat	1.853	Prob(F-statistic)		0.000
Inverted AR Roots	0.92	.80+.46i	.80 -.46i	.46 -.80i
	.46+.80i	.00 -.92i	-.00+.92i	-.46+.80i
	-.46 -.80i	-.80 -.46i	-.80+.46i	-0.92
Inverted MA Roots	0.99	.86+.49i	.86 -.49i	.49+.86i
	.49 -.86i	.00 -.99i	-.00+.99i	-.49 -.86i
	-.49+.86i	-.86 -.49i	-.86+.49i	-0.99

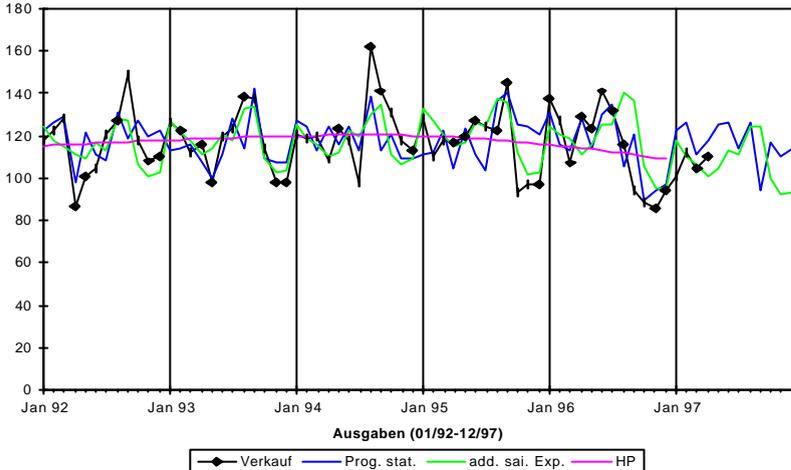
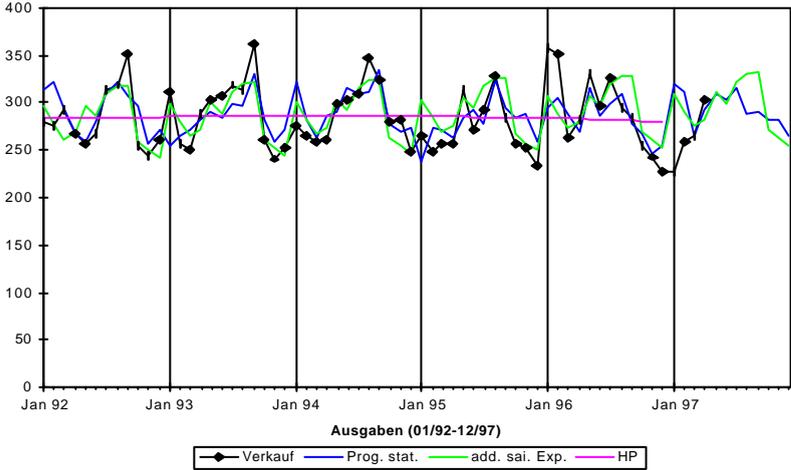
Die Ergebnisse der Überprüfung der Residuen bestätigen die Qualität der gefundenen Schätzung. Erstens besitzen die untersuchten Korrelogramme der ACF und der PACF für die untersuchten lags von $k = 1$ bis 25 keinerlei signifikante Abweichungen von 0 und zweitens genügen die Residuen mit hinreichender Genauigkeit der Normalverteilung. ($J.B. = 0,61$ und ($W(J.B.) = 0,737 \geq \alpha = 0,05$)).

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Pest Bonn	$\hat{y}_t = 265,0 + 0,886e_{t-12}$ (SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 272 ; 301 ; 268 ; 292 Wert 97:4 <u>nicht</u> im Intervall RMSE = 18,9	Exp. Glättung Holt-Winters add. Saison RMSE = 15,4
<u>Modellprotokoll:</u> M.D. = 260 S.D. = 25,9 S.E. = 18,2 DW = 1,66 $R_A^2 = 0,51$ F-ST = 61,3 W(F) = 0,000			
Oechelhaeuser Denkendorf	$\hat{y}_t = 134,0 - 0,556 t + 0,885 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 119; 107 ; 111 ; 105 alle im Intervall RMSE = 10,2	Exp. Glättung Holt-Winters add. Saison RMSE = 10,9
<u>Modellprotokoll:</u> M.D. = 117 S.D. = 17,5 S.E. = 10,1 DW = 1,83 $R_A^2 = 0,67$ F-ST = 59,9 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Zöttl Ergolding	$\hat{y}_t = 93,8 - 0,307 t$ $+ 0,313 u_{t-1} - 0,391 u_{t-2}$ $+ 0,869 e_{t-12}$ (Linearer Trend + SARIMA(2, 0, 0)(0, 0, 1))	Realisationen: 68 ; 74 ; 64 ; 64 Wert 97:3 <u>nicht</u> im Intervall RMSE = 7,2	Exp. Glättung Holt-Winters add. Saison RMSE = 7,4
<u>Modellprotokoll:</u> M.D. = 84 S.D. = 10,3 S.E. = 6,7 DW = 1,96 $R_A^2 = 0,58$ F-ST = 20,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ● Verkauf — Prog. dyn. — Prog. stat. — add. sai. Exp. — HP </p>		
PVG Frankfurt	$\hat{y}_t = 515,1 - 1,858 t$ $+ 0,166 e_{t-1} + 0,863 e_{t-12}$ $+ 0,143 e_{t-13}$ (Linearer Trend + SARIMA(0, 0, 1)(0, 0, 1))	Realisationen: 424; 410 ; 363 ; 371 alle im Intervall RMSE = 26,1	Exp. Glättung Holt-Winters add. Saison RMSE = 26,7
<u>Modellprotokoll:</u> M.D. = 455 S.D. = 47,4 S.E. = 27,2 DW = 1,80 $R_A^2 = 0,67$ F-ST = 41,0 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ● Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Esser Hürth	$\hat{y}_t = 628,9 - 3,210 t$ $+ 0,606 u_{t-12} - 0,864 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0) (1, 0, 1))	Realisationen 467 ; 457 ; 437 ; 476 alle im Intervall RMSE = 29,8	Exp. Glättung Holt- Winters add. Saison RMSE = 31,6
<u>Modellprotokoll:</u> M.D. = 477 S.D. = 49,6 S.E. = 29,3 DW = 2,19 $R_A^2 = 0,65$ F-ST = 30,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. dyn. — Prog. stat. — add. sai. Exp. — HP </p>		
Lehmann Oldenburg	$\hat{y}_t = 260,5 + 0,885 e_{t-12}$ SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 261;245; 226; 254 alle im Intervall RMSE = 19,0	Exp. Glättung Holt- Winters add. Saison RMSE = 17,7
<u>Modellprotokoll:</u> M.D. = 258 S.D. = 27,3 S.E. = 19,1 DW = 1,56 $R_A^2 = 0,51$ F-ST = 62,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ VERKAUF — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Wehling Paderborn	$\hat{y}_t = 155,8 + 0,227 u_{t-1} + 0,883 e_{t-12}$ (SARIMA(1, 0, 0)(0, 0, 1))	Realisationen: 209; 176 ; 173 ; 162 Wert 97:1 <u>nicht</u> im Intervall RMSE = 13,2	Exp. Glättung Holt-Winters add. Saison RMSE = 11,0
<u>Modellprotokoll:</u> M.D. = 154 S.D. = 15,9 S.E. = 12,5 DW = 1,88 $R_A^2 = 0,39$ F-ST = 19,3 W(F) = 0,000			
PV-Saar Saarbrücken	$\hat{y}_t = 339,2 - 1,997 t + 0,367 u_{t-12} + 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 233 ; 228 ; 223 ; 237 alle im Intervall RMSE = 16,6	Exp. Glättung Holt-Winters add. Saison RMSE = 20,7
<u>Modellprotokoll:</u> M.D. = 254 S.D. = 29,1 S.E. = 16,7 DW = 1,85 $R_A^2 = 0,67$ F-ST = 32,9 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Haberer Schopfheim	$\hat{y}_t = 117,3 + 0,846 e_{t-12}$ SARIMA(0, 0, 0)(0, 0, 1)	Realisationen: 101 ; 112 ; 105 ; 111 alle im Intervall RMSE = 13,4	Exp. Glättung Holt-Winters add. Saison RMSE = 12,4
<u>Modellprotokoll:</u> M.D. = 118 S.D. = 16,1 S.E. = 13,4 DW = 1,81 $R_A^2 = 0,30$ F-ST = 26,8 W(F) = 0,000			
NPV Würzburg	$\hat{y}_t = 289,9 + 0,392 e_{t-1} + 0,789 e_{t-12} + 0,309 e_{t-13}$ SARIMA(0, 0, 1)(0, 0, 1)	Realisationen: 227 ; 260 ; 266 ; 302 Wert 97:1 <u>nicht</u> im Intervall RMSE = 27,1	Exp. Glättung Holt-Winters add. Saison RMSE = 22,2
<u>Modellprotokoll:</u> M.D. = 285 S.D. = 33,6 S.E. = 24,0 DW = 1,87 $R_A^2 = 0,49$ F-ST = 29,4 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Ifoton Limburgerhof	$\hat{y}_t = 204,0 + 0,572 u_{t-1} + 0,885 e_{t-12}$ SARIMA(1, 0, 0)(0, 0, 1)	Realisationen: 193 ; 191 ; 155 ; 182 alle im Intervall RMSE = 15,4	Exp. Glättung Holt-Winters add. Saison RMSE = 15,6
<u>Modellprotokoll:</u> M.D. = 207 S.D. = 24,9 S.E. = 15,1 DW = 2,26 $R_A^2 = 0,63$ F-ST = 50,4 W(F) = 0,000			

5.2.4 Klasse 4 - Trendverlauf, ACF läuft mit zunehmender lag Länge aus

Ausschlaggebend für die Zuordnung der Zeitreihen zu dieser Klasse waren die Plots der ACF und der PACF der Verkaufszahlen. Bei allen Zeitreihen dieser Klasse laufen die ACF mit zunehmender lag Länge langsam aus und die PACF besitzen hoch signifikante Werte auf dem ersten lag.

Die untersuchten Werte der Box-Ljung Q-Statistik liegen alle im Ablehnungsbereich der Nullhypothese auf Unabhängigkeit. Alle Zeitreihen weisen somit eine deutliche Abhängigkeitsstruktur auf.

Diese Ergebnisse decken sich mit denen der graphischen Darstellung der Verkaufszahlen. Fast alle Zeitreihen lassen einen linearen Trendverlauf erkennen.

Die meisten Zeitreihen erfüllen die Stationaritätsbedingung, wenn in der Testgleichung neben dem Intercept auch der lineare Trend mit einbezogen wird. Bei den Grossisten Weidmann Göppingen, Wehling Hamm und Molk Osnabrück ist die Bedingung auf Stationarität auch ohne linearen Trend in der Testgleichung erfüllt.

Nur für den Grossisten Mauch & Dettling Tuttlingen kann die Stationarität nur durch Differenzenbildung der Ordnung 1 erzielt werden.

Für diese Klasse zeigt sich die Wichtigkeit der Überprüfung der Stationarität. Aufgrund der Verläufe der ACF und PACF könnte man zu dem Schluss kommen, dass die Zeitreihen einen stochastischen Trend besitzen und erst durch Differenzenbildung die Stationaritätsbedingung erfüllen. Viele nicht stationäre Zeitreihen weisen nämlich mit steigendem lag ein sehr langsames Auslaufen der signifikant von Null abweichenden AC-Werte auf. Die PACF besitzt dabei einen signifikanten positiven Wert auf lag 1.

Bei der Interpretation der ACF und der PACF muss beachtet werden, dass der Trend die beiden Funktionen stark dominiert. Erst eine trendbereinigte Zeitreihe ermöglicht eine Interpretation der ACF und PACF zum Zweck der Entdeckung weiterer Abhängigkeitsstrukturen.

Die Tabellen auf den folgenden Seiten liefern einen guten Überblick über die Ergebnisse der Identifikationstests der Klasse 4.

Für alle Zeitreihen führen der Box-Ljung- und der Runs-Test zu einer Annahme der Alternativhypothese auf Abhängigkeit. Bis auf zwei Ausnahmen lassen sich die Abhängigkeiten durch lineare Modelle beschreiben. Die Zeitreihen für die Grossisten Voigt Stuttgart und Schmitz Dortmund führen im Test von Neftci zu einer Ablehnung der Hypothese auf Symmetrie und damit zur Favorisierung nichtlinearer Modelltypen.

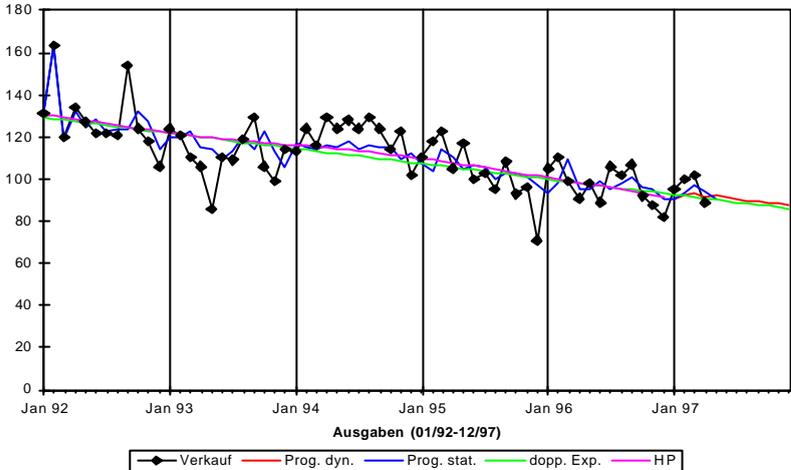
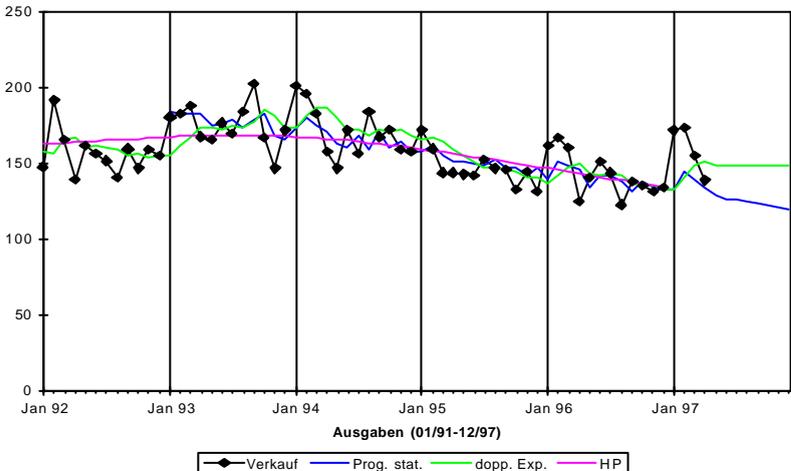
Die entwickelten Modelle wurden in die Modelltypen ohne und mit Saison unterteilt. Bei den saisonalen Modelltypen erfolgt die Erfassung der Saison mit geeigneten saisonalen AR- und MA-Koeffizienten.

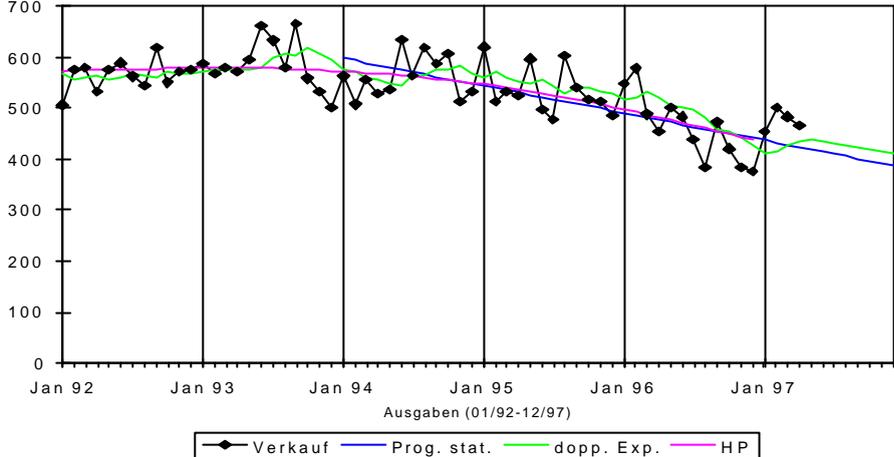
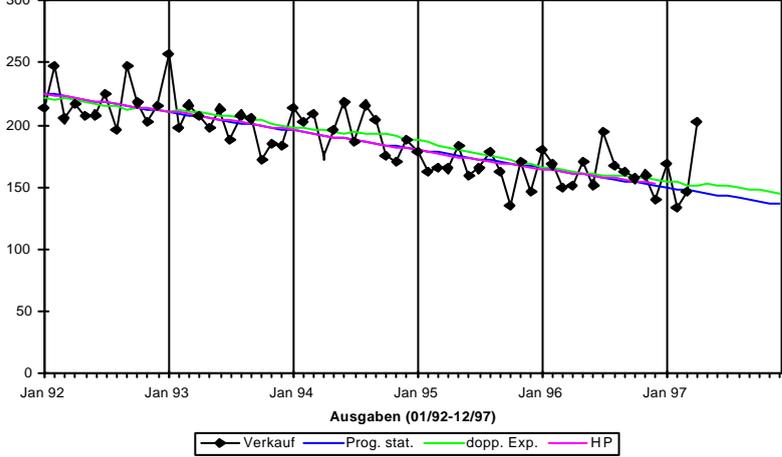
Klasse 4	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist Stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig		H ₀ : Symmetrie H ₁ : keine Symmetrie
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)	Matrix der geschätzten Übergangswahrsch.
PVB Berlin	ADF = -6,44 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend)		$ \vartheta_1 = 0,91 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,37 \leq t_{\alpha} = 1,96$ $S = 0,96 > \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,90 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,35 & 0,65 \\ 0,63 & 0,37 \end{pmatrix}$ ⇒ H ₀ (mit HP)
Schmitz Dortmund	ADF = -7,54 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		$ \vartheta_1 = 0,41 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,19 \leq t_{\alpha} = 1,96$ $S = 0,20 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,89 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,43 & 0,57 \\ 0,79 & 0,21 \end{pmatrix}$ ⇒ H ₁
Schwarz Fallingbostel	ADF = -5,17 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+		$ \vartheta_1 = 0,81 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,62 \leq t_{\alpha} = 1,96$ $S = 1,05 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,60 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,43 & 0,57 \\ 0,64 & 0,36 \end{pmatrix}$ ⇒ H ₀
Weidmann Göppingen	ADF = -5,70 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend)		$ \vartheta_1 = 0,85 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,45 \leq t_{\alpha} = 1,96$ $S = 2,83 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,78 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,34 & 0,66 \\ 0,84 & 0,16 \end{pmatrix}$ ⇒ H ₀ (mit HP)
Wehling Hamm	ADF = -4,76 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend)		$ \vartheta_1 = 1,25 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,74 \leq t_{\alpha} = 1,96$ $S = 2,10 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,63 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,01 < α = 0,05 ⇒ H ₁	$\begin{pmatrix} 0,41 & 0,59 \\ 0,66 & 0,34 \end{pmatrix}$ ⇒ H ₀

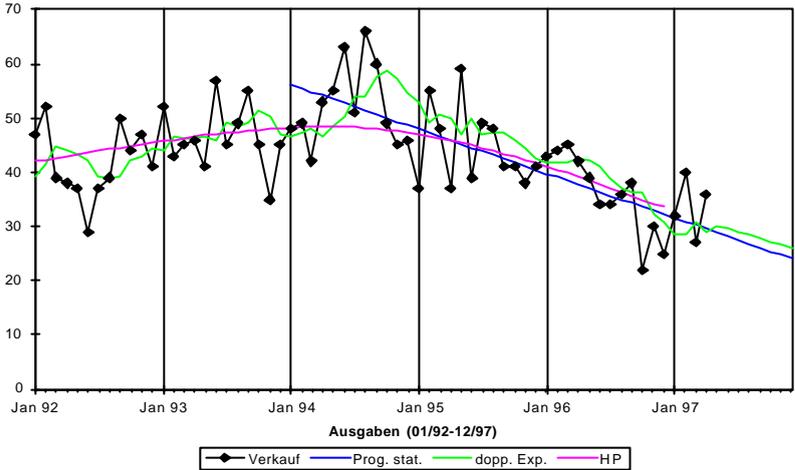
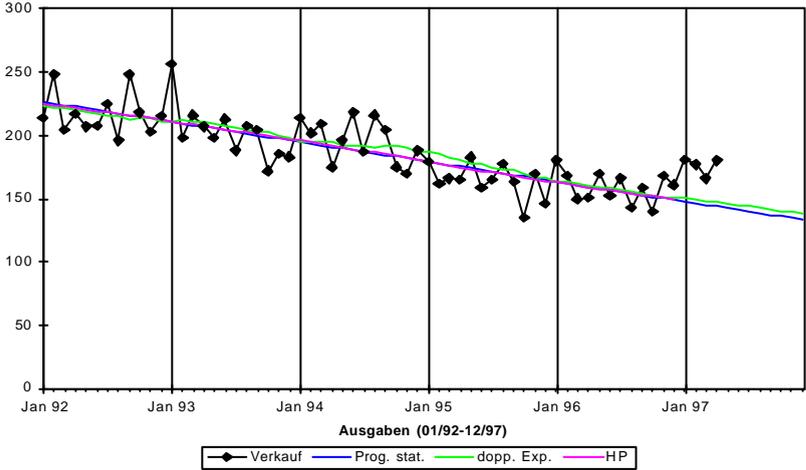
Klasse 4	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 15)	Runs-Test (RT) (Berechnung mit arith. Mittel)	Matrix der ge- schätzten Über- gangswahrsch.
Crämer Hannover	ADF = -5,13 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 0 u. det. Trend)		$ \vartheta_1 = 1,95 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,57 \leq t_{\alpha} = 1,96$ $S = 4,13 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,87 $\geq \alpha$ = 0,05 $\Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,00 < $\alpha =$ 0,05 $\Rightarrow H_1$	$\begin{pmatrix} 0,41 & 0,59 \\ 0,70 & 0,30 \end{pmatrix}$ $\Rightarrow H_0$
Schmidt & Hampe Hannover	ADF = -6,86 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 1 u. det. Trend) Resid. lag 12: AC+		$ \vartheta_1 = 0,29 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,24 \leq t_{\alpha} = 1,96$ $S = 1,62 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,84 $\geq \alpha$ = 0,05 $\Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,00 < $\alpha =$ 0,05 $\Rightarrow H_1$	$\begin{pmatrix} 0,51 & 0,49 \\ 0,71 & 0,29 \end{pmatrix}$ $\Rightarrow H_0$ (mit HP)
Jost München	ADF = -6,95 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		$ \vartheta_1 = 0,25 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,28 \leq t_{\alpha} = 1,96$ $S = 0,14 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 1,00 $\geq \alpha$ = 0,05 $\Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,02 < $\alpha =$ 0,05 $\Rightarrow H_1$	$\begin{pmatrix} 0,49 & 0,51 \\ 0,65 & 0,35 \end{pmatrix}$ $\Rightarrow H_0$
Mölk Osnabrück	ADF = -6,07 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		$ \vartheta_1 = 0,10 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,50 \leq t_{\alpha} = 1,96$ $S = 2,26 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,87 $\geq \alpha$ = 0,05 $\Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,00 < $\alpha =$ 0,05 $\Rightarrow H_1$	$\begin{pmatrix} 0,43 & 0,57 \\ 0,64 & 0,36 \end{pmatrix}$ $\Rightarrow H_0$
Voigt Stuttgart	ADF = -6,92 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		$ \vartheta_1 = 0,39 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,63 \leq t_{\alpha} = 1,96$ $S = 0,55 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,44 $\geq \alpha$ = 0,05 $\Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,00 < $\alpha =$ 0,05 $\Rightarrow H_1$	$\begin{pmatrix} 0,55 & 0,45 \\ 0,72 & 0,28 \end{pmatrix}$ $\Rightarrow H_1$
Becker & Winarek Trier	ADF = -8,14 < $k_{(1\%)} = -4,12$ $\Rightarrow H_1$ (lag 0 u. det. Trend)		$ \vartheta_1 = 0,81 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,66 \leq t_{\alpha} = 1,96$ $S = 1,09 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,77 $\geq \alpha$ = 0,05 $\Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ $\Rightarrow H_1$	W(RT) = 0,00 < $\alpha =$ 0,05 $\Rightarrow H_1$	$\begin{pmatrix} 0,32 & 0,68 \\ 0,81 & 0,19 \end{pmatrix}$ $\Rightarrow H_0$

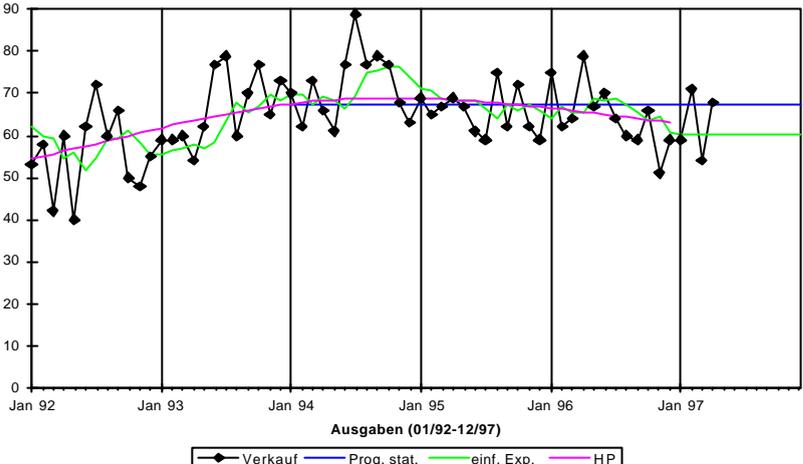
Klasse 4	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit		Test von Neftci
		Schiefe; Wölbung; Jarque Bera	Kolmogorov- Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 15)	Runs-Test (RT) (Berechnung mit arith. Mittel)	
Grossist	ADF-Test					Matrix der geschätzten Übergangswahrsch.
Fergg Tübingen	ADF = -7,51 < $k_{(1\%)} = -4,12$ ⇒ H_1 (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 0,74 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,56 \leq t_{\alpha} = 1,96$ $S = 0,87 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,97 ≥ $\alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,00 < $\alpha = 0,05 \Rightarrow H_1$	$\begin{pmatrix} 0,32 & 0,68 \\ 0,63 & 0,37 \end{pmatrix}$ ⇒ H_0
Mauch & Dettling Tuttlingen	ADF = -2,08 ≥ $k_{(1\%)} = -3,54$ ⇒ H_0 (lag 1) <u>Differenzenbildung (d = 1):</u> ADF = -13,5 < $k_{(1\%)} = -2,60$ ⇒ H_1 (lag 0)	$ \vartheta_1 = 0,21 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,43 \leq t_{\alpha} = 1,96$ $S = 0,23 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,92 ≥ $\alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,07 ≥ $\alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,44 & 0,56 \\ 0,58 & 0,42 \end{pmatrix}$ ⇒ H_0
Heuser Velbert	ADF = -8,58 < $k_{(1\%)} = -4,12$ ⇒ H_1 (lag 0 u. det. Trend)	$ \vartheta_1 = 0,83 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,73 \leq t_{\alpha} = 1,96$ $S = 1,22 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,72 ≥ $\alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,00 < $\alpha = 0,05 \Rightarrow H_1$	$\begin{pmatrix} 0,26 & 0,74 \\ 0,82 & 0,18 \end{pmatrix}$ ⇒ H_0
Küpper Wrestedt	ADF = -4,99 < $k_{(1\%)} = -3,54$ ⇒ H_1 (lag 0)	$ \vartheta_1 = 0,45 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,47 \leq t_{\alpha} = 1,96$ $S = 0,42 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,37 ≥ $\alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,12 ≥ $\alpha = 0,05 \Rightarrow H_0$	$\begin{pmatrix} 0,33 & 0,67 \\ 0,71 & 0,29 \end{pmatrix}$ ⇒ H_0
Probst Wuppertal	ADF = -5,10 < $k_{(1\%)} = -4,12$ ⇒ H_1 (lag 2 u. det. Trend)	$ \vartheta_1 = 0,52 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 1,30 \leq t_{\alpha} = 1,96$ $S = 1,97 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,73 ≥ $\alpha = 0,05 \Rightarrow H_0$	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,00 < $\alpha = 0,05 \Rightarrow H_1$	$\begin{pmatrix} 0,46 & 0,54 \\ 0,69 & 0,31 \end{pmatrix}$ ⇒ H_0

Klasse 4 - Modelltyp 1 (Ohne Saison)

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Weidmann Göppingen	$\hat{y}_t = 129,2 - 0,575t - 0,541 u_{t-1} + 0,858 e_{t-1} + 0,385 e_{t-2}$ (Linearer Trend + ARIMA(1, 0, 2))	Realisationen: 95 ; 100 ; 102 ; 89 alle im Intervall RMSE = 10,1	Dopp. exp. Glättung ähnlich Modell RMSE = 12,1
<u>Modellprotokoll:</u> M.D. = 112 S.D. = 16,2 S.E. = 10,8 DW = 1,94 $R_A^2 = 0,56$ F-ST = 19,5 W(F) = 0,000			
Wehling Hamm	<u>Stütz.: (01/93-12/96)</u> $\hat{y}_t = 199,1 - 1,094 t + 0,339 e_{t-1}$ (Linearer Trend + ARIMA(0; 0; 1))	Realisationen: 172 ; 174 ; 156 ; 139 Wert 97:1 <u>nicht</u> im Intervall RMSE = 13,8	Dopp. exp. Glättung weicht vom Modell ab RMSE = 15,2
<u>Modellprotokoll:</u> M.D. = 159 S.D. = 20,2 S.E. = 12,7 DW = 2,02 $R_A^2 = 0,60$ F-ST = 36,9 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Crämer Hannover	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 709,6 - 4,466 t$	Realisationen: 249 ; 240 ; 235 ; 256 alle im Intervall RMSE = 47,0	Doppelte exp. Glättung RMSE = 46,7
<u>Modellprotokoll:</u> M.D. = 520 S.D. = 66,8 S.E. = 48,1 DW = 1,58 $R_A^2 = 0,48$ F-ST = 33,5 W(F) = 0,000			
Becker & Winarek Trier	$\hat{y}_t = 226,9 - 1,258 t$	Realisationen: 169 ; 134 ; 147 ; 202 Wert 97:4 <u>nicht</u> im Intervall RMSE = 17,2	Doppelte exp. Glättung ähnlich Modell RMSE = 17,7
<u>Modellprotokoll:</u> M.D. = 189 S.D. = 27,2 S.E. = 16,2 DW = 2,15 $R_A^2 = 0,65$ F-ST = 108,8 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Mauch & Dettling Tuttlingen	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 73,3 - 0,683 t$	Realisationen: 32 ; 40 ; 27 ; 36 alle im Intervall RMSE = 6,5	Doppelte exp. Glättung. weicht vom Modell ab RMSE = 7,2
<u>Modellprotokoll:</u> M.D. = 44 S.D. = 9,8 S.E. = 6,8 DW = 1,78 $R_A^2 = 0,52$ F-ST = 39,2 W(F) = 0,000			
Heuser Velbert	$\hat{y}_t = 227,9 - 1,314 t$	Realisationen: 181 ; 177 ; 166 ; 180 Wert 97:1 und 97:4 <u>nicht im Intervall</u> RMSE = 16,7	Doppelte exp. Glättung. ähnlich Modell RMSE = 16,0
<u>Modellprotokoll:</u> M.D. = 188 S.D. = 27,7 S.E. = 15,6 DW = 2,25 $R_A^2 = 0,68$ F-ST = 127,7 W(F) = 0,000			

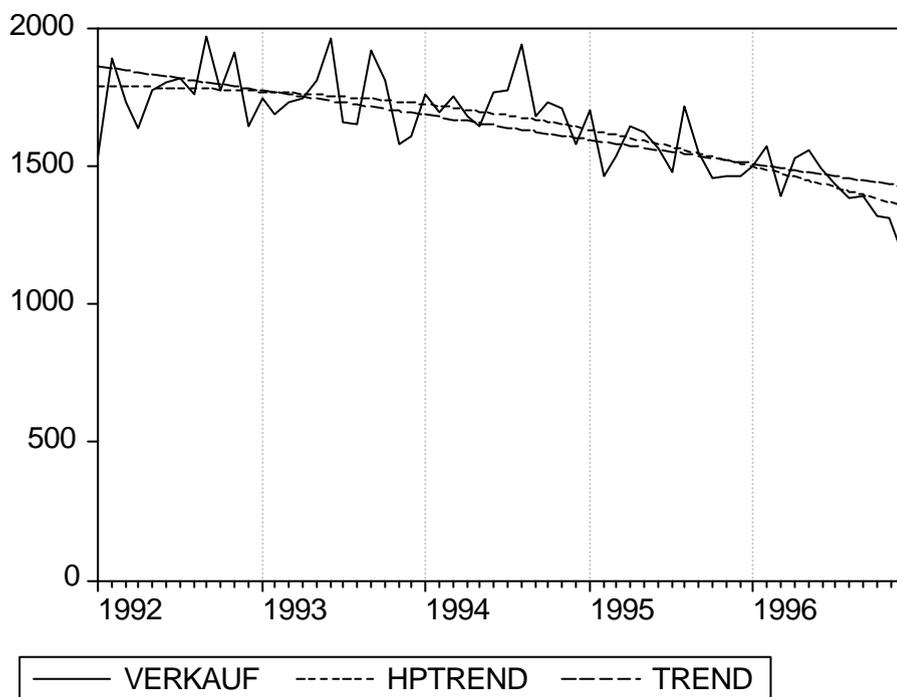
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Küpper Wrestedt	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 67,4$	Realisationen: 59 ; 71 ; 54 ; 68 alle im Intervall RMSE = 7,6	Einfache exp. Glättung. weicht vom Modell ab RMSE = 8,4
<u>Modellprotokoll:</u> M.D. = 67 S.D. = 7,7 S.E. = 7,7 DW = 1,39			

Klasse 4 - Modelltyp 2 (Mit Saison)

Die Modellentwicklung dieses Typs wird am Beispiel der Verkaufszahlen von Berlin erörtert. Im ehemaligen West-Berlin erfolgte der Vertrieb bis Ende 1996 über den Grossisten VV Berlin. Danach übernahm der Grossist BPV Berlin den Vertrieb. Zum Zweck der Analyse wurden die Daten beider Grossisten zusammengespielt.

Die Verkaufszahlen für West-Berlin sind trendstationär, normalverteilt und besitzen eine Abhängigkeitsstruktur, die sich durch ein lineares Modell adäquat beschreiben lässt.

Schon die graphische Darstellung der Zeitreihe verdeutlicht den klaren Abwärtstrend der Verkaufszahlen im Beobachtungszeitraum. Die mit dem HP-Filter geglättete Zeitreihe für Berlin weicht nur leicht von der linearen Trendgeraden ab.



(EViews 2.0)

Als erstes Modell wird ein einfaches Regressionsmodell zur Beschreibung der linearen Trendentwicklung geschätzt. Die beiden Koeffizienten der Trendgerade sind hoch signifikant von Null verschieden. Mit einem bereinigten R^2_A von 0,561 erfasst der deterministische Trend schon einen recht hohen Teil der Variation in den Verkaufszahlen.

Mit einem Wert von 1,443 liegt die Realisation der DW-Statistik eindeutig im unteren Ablehnungsbereich $[0; 1,549]$ ²⁰⁵ der Nullhypothese, bei einem vorgegebenen Signifikanzniveau von 5%, basierend auf 60 Beobachtungswerten und einem Freiheitsgrad von 2 (Anzahl der zu schätzenden Regressionskoeffizienten einschließlich der Konstante C). Der Test führt somit zu der Entscheidung, dass die Residuen eine signifikant positive Autokorrelation der Ordnung 1 besitzen. Der Plot der ACF der Residuen bestätigt das Ergebnis des DW-Tests.

BERLIN (VV und BPV)				
LS // Dependent Variable is VERKAUF				
Sample: 1992:01 1996:12				
Included observations: 60				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1869.537	29.658	63.036	0.000
NUMMER	-7.390	0.846	-8.739	0.000
R-squared	0.568	Mean dependent var		1644.150
Adjusted R-squared	0.561	S.D. dependent var		171.186
S.E. of regression	113.434	Akaike info criterion		9.495
Sum squared resid	746298.200	Schwarz criterion		9.565
Log likelihood	-367.992	F-statistic		76.371
Durbin-Watson stat	1.443	Prob(F-statistic)		0.000

Eine deutliche Verbesserung der Modellanpassung und der Autokorrelation in den Residuen erhält man durch Hinzunahme der um ein Jahr verzögerten Verkaufszahlen. Ein solches Modell lässt sich analog durch den saisonalen AR(12)-Term formulieren.

Zwar weisen ACF und PACF der Verkaufszahlen keine hohen Ausschläge für lag 12 auf. Die Qualität der Schätzung verbessert sich aber nachhaltig. Das bereinigte R_A^2 steigt von 0,561 auf 0,651, die Standardabweichung des erweiterten Modells sinkt von einem mittleren Wert von 113,4 auf 98,7. Auch der Wert für das SC reduziert sich von 9,565 auf 9,362.

Die Residuen der Modellschätzung genügen einem reinen Zufallsprozess. Sie weisen keine erkennbaren systematischen Zusammenhänge mehr auf, die Normalverteilungshypothese lässt sich nicht verwerfen und die Box-Ljung Q-Statistik führt zu einer Ablehnung der Hypothese auf Abhängigkeiten in den Residuen.

²⁰⁵ Judge/Hill/Griffiths/Lütkepohl/Lee 1988, 992.

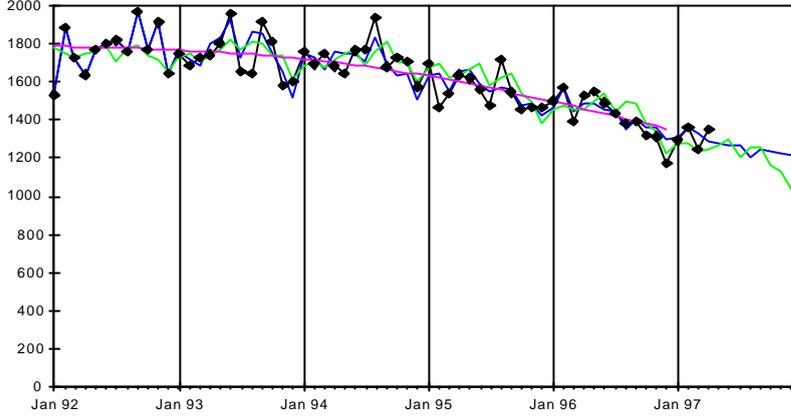
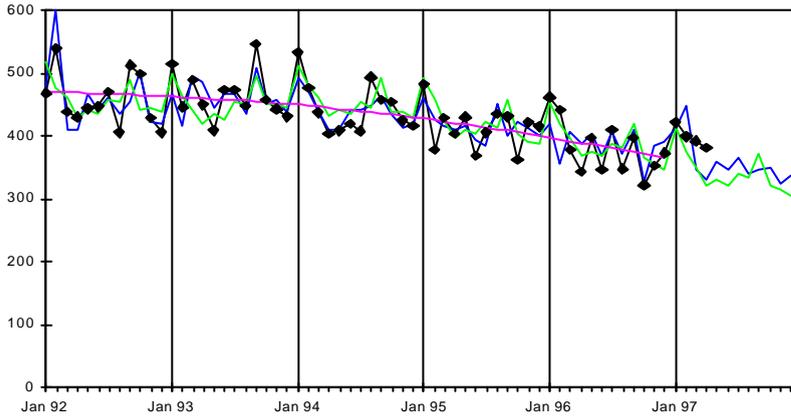
BERLIN (VV und BPV)				
LS // Dependent Variable is VERKAUF				
Sample(adjusted): 1993:01 1996:12				
Included observations: 48 after adjusting endpoints				
Convergence achieved after 3 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2015.822	70.648	28.533	0.000
NUMMER	-10.749	1.582	-6.795	0.000
AR(12)	0.216	0.129	1.669	0.102
R-squared	0.666	Mean dependent var		1612.000
Adjusted R-squared	0.651	S.D. dependent var		167.153
S.E. of regression	98.704	Akaike info criterion		9.245
Sum squared resid	438411.100	Schwarz criterion		9.362
Log likelihood	-286.982	F-statistic		44.895
Durbin-Watson stat	1.647	Prob(F-statistic)		0.000
Inverted AR Roots	0.88	.76+.44i	.76 -.44i	.44 -.76i
	.44+.76i	.00+.88i	-.00 -.88i	-.44+.76i
	-.44 -.76i	-.76+.44i	-.76 -.44i	-0.88

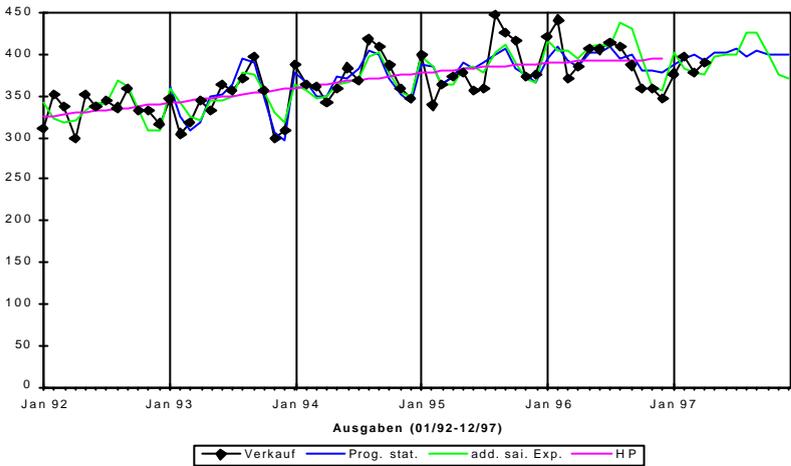
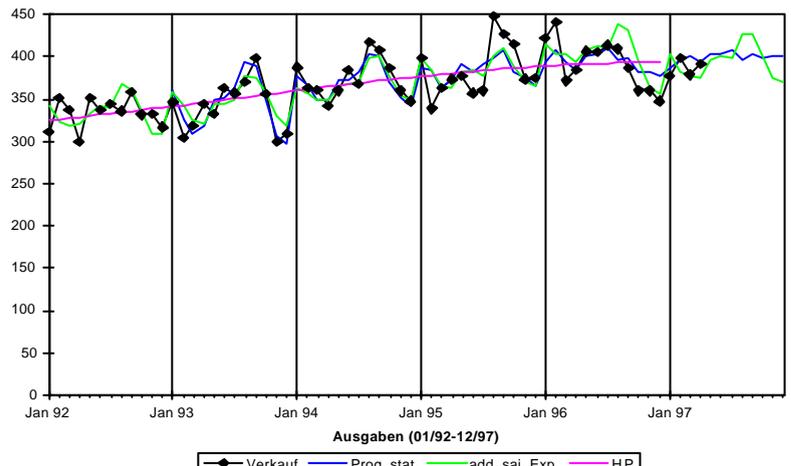
Bei einem vorab gewählten α -Fehler von 5% sind die beiden ersten Koeffizienten mit sehr hoher Wahrscheinlichkeit von Null verschieden. Problematisch ist der dritte, um eine Periode verzögerte Koeffizient. Dieser Koeffizient liegt im Nicht-Ablehnungsbereich der Nullhypothese und ist somit nicht signifikant von Null verschieden.

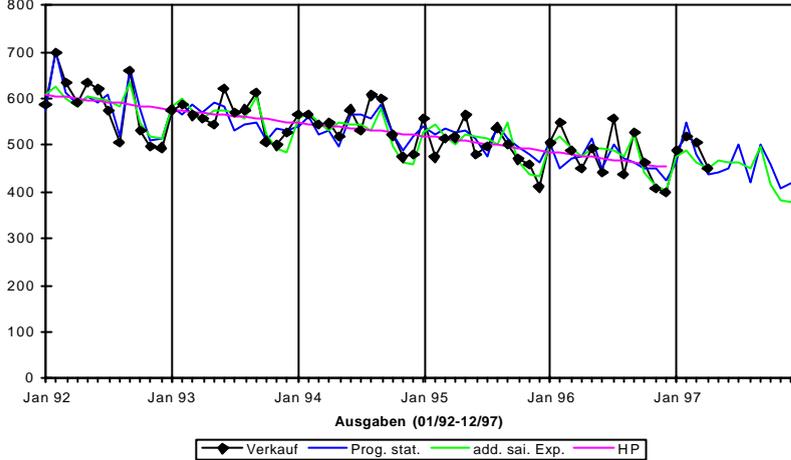
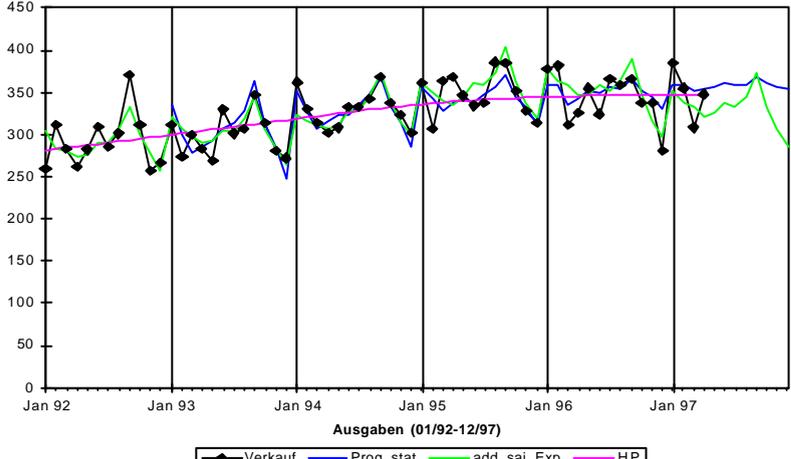
Alternativ wurde eine Erweiterung der obigen Modellvariante um einen SMA-Term getestet. Das erweiterte Modell liefert eine hervorragende Modellanpassung und Koeffizienten, die alle hoch signifikant von Null verschieden sind.

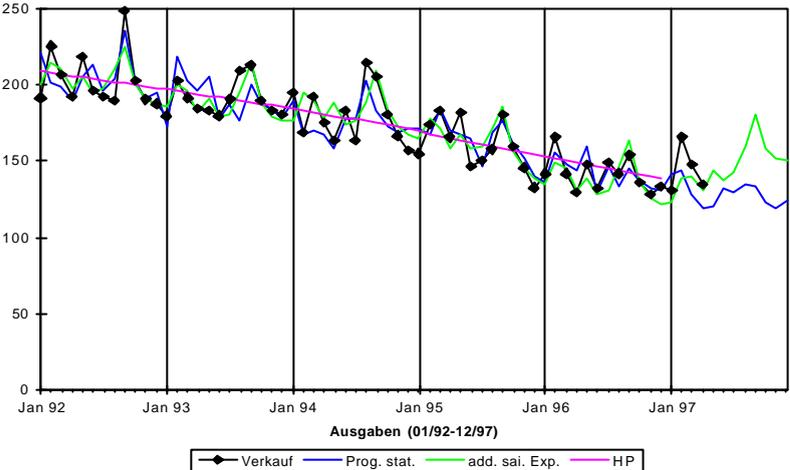
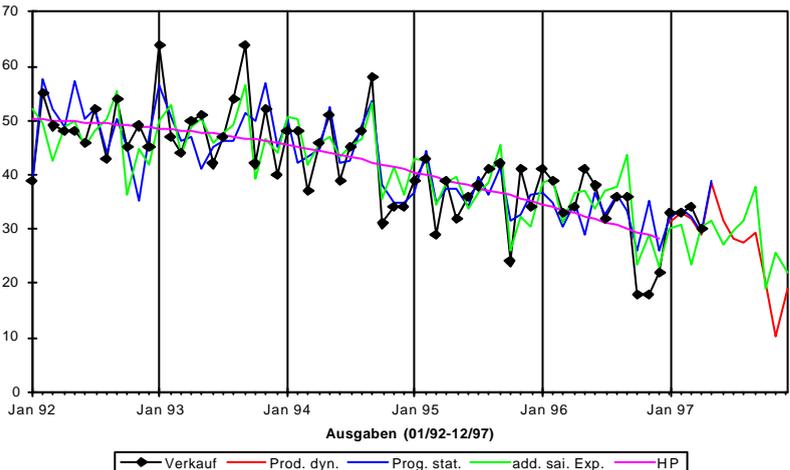
Die Residuen genügen der Normalverteilung ($J.B. = 3,75$ ($W(J.B.) = 0,153 \geq \alpha = 0,05$)) und besitzen keine signifikanten Werte in der ACF und PACF.

BERLIN (VV und BPV)				
LS // Dependent Variable is VERKAUF				
Sample(adjusted): 1993:01 1996:12				
Included observations: 48 after adjusting endpoints				
Convergence achieved after 25 iterations				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2210.583	88.947	24.853	0.000
NUMMER	-14.115	1.672	-8.442	0.000
AR(12)	0.441	0.067	6.607	0.000
MA(12)	-0.886	0.000	-6690.607	0.000
R-squared	0.819	Mean dependent var		1612.000
Adjusted R-squared	0.807	S.D. dependent var		167.153
S.E. of regression	73.502	Akaike info criterion		8.674
Sum squared resid	237709.200	Schwarz criterion		8.830
Log likelihood	-272.292	F-statistic		66.357
Durbin-Watson stat	1.882	Prob(F-statistic)		0.000
Inverted AR Roots	0.93	.81 -.47i	.81+.47i	.47 -.81i
	.47+.81i	.00+.93i	.00 -.93i	-.47 -.81i
	-.47+.81i	-.81+.47i	-.81 -.47i	-0.93
Inverted MA Roots	0.99	.86 -.49i	.86+.49i	.49 -.86i
	.49+.86i	.00+.99i	-.00 -.99i	-.49+.86i
	-.49 -.86i	-.86+.49i	-.86 -.49i	-0.99

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
PVB Berlin	$\hat{y}_t = 2210,6 - 14,115 t$ $+ 0,441 u_{t-12}$ $- 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 1297 ; 1363 ; 1247 ; 1355 alle im Intervall RMSE = 69,8	Exp. Glättung Holt-Winters add. Saison RMSE = 95,3
<u>Modellprotokoll:</u> M.D. = 1612 S.D. = 167,2 S.E. = 73,5 DW = 1,88 $R_A^2 = 0,81$ F-ST = 66,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Schmitz Dortmund	$\hat{y}_t = 500,2 - 2,046 t$ $+ 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 421 ; 399 ; 392 ; 381 alle im Intervall RMSE = 29,2	Exp. Glättung Holt-Winters add. Saison RMSE = 30,0
<u>Modellprotokoll:</u> M.D. = 432 S.D. = 49,0 S.E. = 29,4 DW = 2,06 $R_A^2 = 0,64$ F-ST = 53,2 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Schwarz Fallingbostel	$\hat{y}_t = 408,2 + 0,590 t$ $+ 0,590 u_{t-12} + 0,155 e_{t-1}$ $- 0,829 e_{t-12} - 0,129 e_{t-13}$ (Linearer Trend + SARIMA(0, 0, 1)(1, 0, 1))	Realisationen: 377 ; 398 ; 379 ; 391 alle im Intervall RMSE = 18,3	Exp. Glättung Holt-Winters add. Saison RMSE = 19,8
<u>Modellprotokoll:</u> M.D. = 373 S.D. = 34,0 S.E. = 20,1 DW = 1,61 $R_A^2 = 0,65$ F-ST = 30,1 W(F) = 0,000			
Schmidt & Hampe Hannover	$\hat{y}_t = 156,7 - 0,691 t$ $+ 0,619 u_{t-12} - 0,854 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 113 ; 122 ; 120 ; 114 alle im Intervall RMSE = 6,4	Exp. Glättung Holt-Winters add. Saison RMSE = 6,5
<u>Modellprotokoll:</u> M.D. = 135 S.D. = 15,5 S.E. = 7,0 DW = 2,25 $R_A^2 = 0,80$ F-ST = 62,6 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Jost München	$\hat{y}_t = 600,9 - 2,212 t - 0,876 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 489 ; 520 ; 505 ; 449 alle im Intervall RMSE = 30,9	Exp. Glättung Holt-Winters add. Saison RMSE = 30,4
<u>Modellprotokoll:</u> M.D. = 533 S.D. = 62,6 S.E. = 31,2 DW = 1,93 $R_A^2 = 0,75$ F-ST = 90,2 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Mölk Osnabrück	$\hat{y}_t = 369,9 + 0,657 u_{t-12} - 0,854 e_{t-12}$ SARIMA(0, 0, 0)(1, 0, 1)	Realisationen: 384 ; 355 ; 308 ; 348 Wert 97:3 <u>nicht</u> im Intervall RMSE = 18,6	Exp. Glättung Holt-Winters add. Saison RMSE = 19,6
<u>Modellprotokoll:</u> M.D. = 330 S.D. = 31,4 S.E. = 18,8 DW = 1,70 $R_A^2 = 0,64$ F-ST = 43,0 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Voigt Stuttgart	$\hat{y}_t = 215,7 - 1,306 t$ $+ 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 131 ; 166 ; 148 ; 135 alle im Intervall RMSE = 12,2	Exp. Glättung Holt- Winters add. Saison RMSE = 10,9
<u>Modellprotokoll:</u> M.D. = 176 S.D. = 26,7 S.E. = 11,4 DW = 1,82 $R_A^2 = 0,82$ F-ST = 132,4 W(F) = 0,000			
Fergg Tübingen	$\hat{y}_t = 55,6 - 0,415 t$ $+ 0,221 u_{t-1} + 0,849 e_{t-12}$ (Linearer Trend + SARIMA(1, 0, 0)(0, 0, 1))	Realisationen: 33 ; 33 ; 34 ; 30 alle im Intervall RMSE = 5,4	Exp. Glättung Holt- Winters add. Saison RMSE = 5,0
<u>Modellprotokoll:</u> M.D. = 42 S.D. = 9,7 S.E. = 5,8 DW = 1,94 $R_A^2 = 0,64$ F-ST = 35,4 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Probst Wuppertal	$\hat{y}_t = 212,7 - 1,482 t$ $+ 0,659 u_{t-12} - 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 136 ; 132 ; 117 ; 125 alle im Intervall RMSE = 12,0	Exp. Glättung Holt-Winters add. Saison RMSE = 13,0
<u>Modellprotokoll:</u> M.D. = 148 S.D. = 24,0 S.E. = 12,6 DW = 1,84 $R_A^2 = 0,72$ F-ST = 42,3 W(F) = 0,000			

5.2.5 Klasse 5 - Ausgeprägte Saisonfigur, ACF mit wellenförmigen Verlauf

Die Zeitreihen, die zur Klasse 5 zusammengefasst wurden, weisen sehr ausgeprägte saisonale Verläufe auf, die im zeitlichen Ablauf recht stabil bleiben. Neben der graphischen Darstellung der Verkaufszahlen spiegelt sich der saisonale Effekt in den Plots der ACF wieder. Die ACF verlaufen wellenförmig. Auf lag 1 ist die AC stark signifikant positiv. Mit zunehmender lag Länge verringern sich die AC-Werte. Für lag 5 oder 6 weisen sie den höchsten negativen signifikanten Wert auf. Danach steigen die Werte wiederum an, um ein erneutes Maximum auf lag 12 zu erreichen. Für die folgende Periode (lag 13 bis lag 24) wiederholt sich diese Wellenbewegung, wobei das absolute Niveau der Wellenbewegung mit zunehmender lag Länge zurück geht.

Alle Zeitreihen der Klasse 5 besitzen folglich eine sehr starke Abhängigkeitsstruktur, die sich in den hoch signifikanten Realisationen der Prüfgrößen der Ljung-Box Q-Statistik und des Runs-Tests wiederfindet.

Die Zeitreihen der beiden Grossisten Carlsen Flensburg und SWV Konstanz verletzen die Annahme auf Normalverteiltheit. Für die Modellschätzung wird diese Problematik aber vernachlässigt.

Im Kapitel 4.7 wurden verschiedene Testverfahren zur simultanen Entscheidung über die Bestimmung der Differenzgrade $\Delta^d \Delta_S^D$ von saisonalen Zeitreihen vorgestellt. Auf die Anwendung der vorgestellten Testverfahren muss leider verzichtet werden, da der Beobachtungszeitraum nur 64 Beobachtungswerte umfasst. Zur stabilen Berechnung der kritischen Testgrenzen mittels Monte-Carlo-Simulation ist aber eine deutlich längere Zeitreihe erforderlich. Dickey, Hasza und Fuller²⁰⁶, aber auch Franses²⁰⁷ berechnen die kritischen Grenzen bei Monatsdaten erst für Zeitreihen, die mindestens 120 Beobachtungswerte aufweisen. Beaulieu und Miron²⁰⁸ weisen die kritischen Grenzen bei Monatsdaten erst für mindestens 240 Beobachtungswerte aus.

Zur Überprüfung des Differenzgrades wurde daher ein pragmatischer Ansatz verwendet. Zuerst werden die Zeitreihen mit Hilfe des Augmented-Dickey-Fuller-Tests auf die nicht-saisonale Stationarität getestet. Wie der Tabelle auf Seite 222-223 zu entnehmen ist, erfüllen alle Zeitreihen der Klasse 5 die Bedingung der nicht saisonalen Stationarität, ohne dass eine Differenzenbildung der Ordnung 1 erforderlich wäre. Wie zu erwarten, besitzen die Residuen der ADF-Testgleichungen auf lag 12 der ACF und PACF hoch signifikant positive Ausschläge.

²⁰⁶ Dickey/Hasza/Fuller 1984.

²⁰⁷ Franses 1991.

²⁰⁸ Beaulieu/Miron 1993.

Zur Prüfung des saisonalen Differenzengrades werden die saisonalen Differenzen Δ_{12}^1 der Zeitreihen gebildet. Auf die differenzierte Zeitreihe wird der einfache Dicky-Fuller-Test angewandt. Eine Entscheidung auf H_1 bedeutet, dass die saisonale Differenzenbildung zu einer stationären Zeitreihe führt und einen möglichen Ansatz zur Erfassung der Saisonalität darstellt. Darüber hinaus sollte geprüft werden, ob die saisonal differenzierte Zeitreihe der Normalverteilung genügt und ob die ACF und PACF noch signifikante Werte, speziell auf lag 12 und 24, aufweisen.

Alternativ wird die Erfassung der Saisonalität durch ein Regressionsmodell mit saisonalen Dummies überprüft. Bei einigen Zeitreihen kommt es vor, dass beide Konzepte zur Erfassung der Saisonalität, stochastisches und deterministisches, zu akzeptablen Modellschätzungen führen. In solchen Fällen wird dann jener Modellansatz gewählt, der die beste Prognosefähigkeit besitzt.

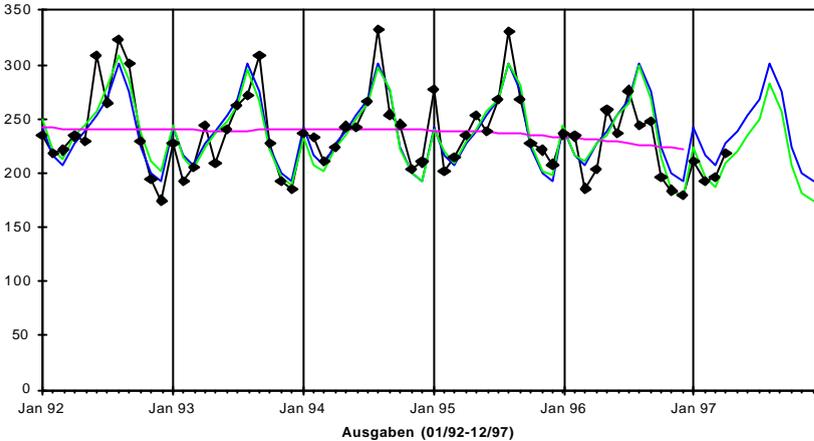
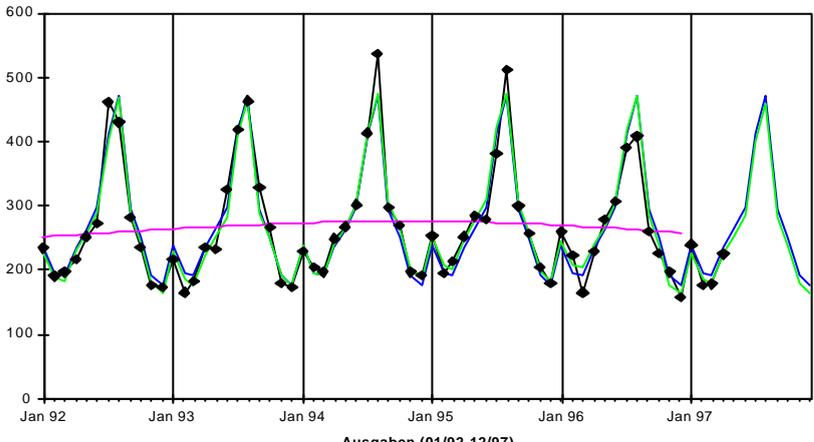
Interessant wird die Beurteilung der Stationarität, wenn zusätzlich zur Saison der HP-Filter einen Verlauf aufweist, der auf eine nichtlineare Trendentwicklung hindeutet. In diesen Fällen wird alternativ die Doppeldifferenzenbildung ($\Delta^1 \Delta_{12}^1$) geprüft. Die Überprüfung erfolgt wiederum durch Verwendung des DF-Tests und durch Überprüfung der Normalverteilungsannahme sowie der ACF und PACF der Residuen.

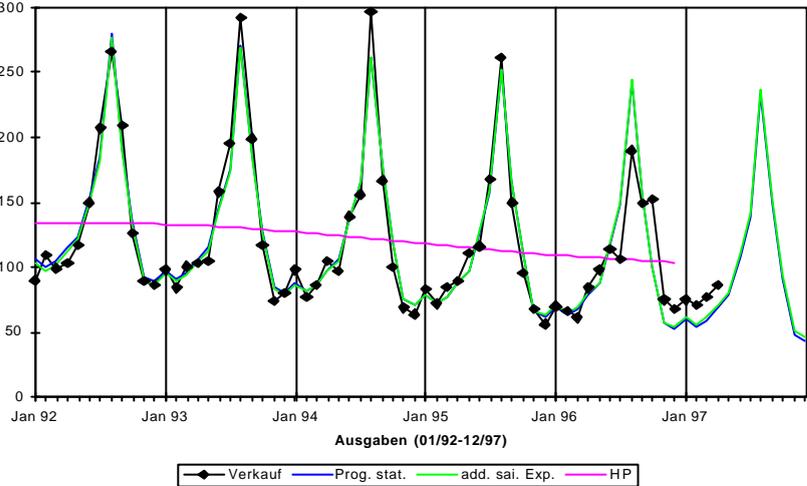
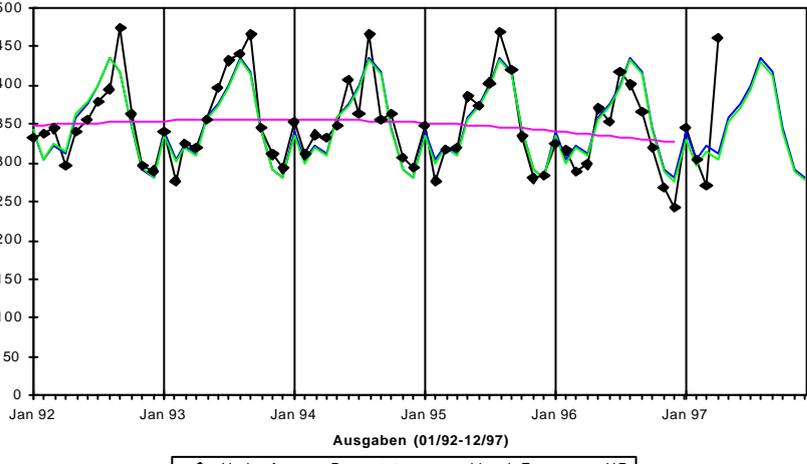
Bei den meisten Zeitreihen der Klasse 5 führt der Regressionsansatz mit saisonalen Dummies zu sehr guten Prognosemodellen. Nicht so bei den Grossisten Carlsen Kiel, Maurer Lübeck und Beutz Wilhelmshaven, hier sind die Ergebnisse unbefriedigend. Die Korrelogramme der Residuen weisen hoch signifikant von Null abweichende Werte in den ACF und PACF auf. Für den Grossisten Kiel wird zusätzlich die Normalverteilungshypothese der Residuen deutlich verletzt. Als Modelle werden daher SARIMA-Modelle für die zuvor saisonal- (Δ_{12}^1) bzw. doppeltdifferenzierten ($\Delta^1 \Delta_{12}^1$) Zeitreihen entwickelt.

Klasse 5	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit	
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig	
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)
Nolte Bremerhaven	ADF = -4,47 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 2,27 > t _α = 1,96 ϑ ₂ = 0,63 ≤ t _α = 1,96 S = 5,28 ≤ χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,40 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁
Carlsen Flensburg	ADF = -5,45 < k _(1%) = -3,55 ⇒ H ₁ (lag 3) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 3,86 > t _α = 1,96 ϑ ₂ = 1,23 ≤ t _α = 1,96 S = 16,41 > χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,08 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁
SWV Friedrichshafen	ADF = -4,07 < k _(1%) = -3,55 ⇒ H ₁ (lag 3) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 4,62 > t _α = 1,96 ϑ ₂ = 2,45 > t _α = 1,96 S = 27,33 > χ _k ² = 5,99 ⇒ H ₁	W(K-S) = 0,01 < α = 0,05 ⇒ H ₁	Für alle lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁
Carlsen Kiel	ADF = -5,11 < k _(1%) = -3,55 ⇒ H ₁ (lag 3) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 3,88 > t _α = 1,96 ϑ ₂ = 1,17 ≤ t _α = 1,96 S = 16,41 > χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,07 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁
Keppel Koblenz	ADF = -4,64 < k _(1%) = -3,55 ⇒ H ₁ (lag 2) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 1,80 ≤ t _α = 1,96 ϑ ₂ = 0,30 ≤ t _α = 1,96 S = 3,34 ≤ χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,66 ≥ α = 0,05 ⇒ H ₀	Für alle lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁

Klasse 5	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit	
		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov- Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)
Grossist	ADF-Test				
SWV Konstanz	ADF = -4,03 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 5,22 > t_{\alpha} = 1,96$ $ \vartheta_2 = 3,79 > t_{\alpha} = 1,96$ $S = 41,59 > \chi^2_k = 5,99 \Rightarrow H_1$	W(K-S) = 0,01 < $\alpha = 0,05$ ⇒ H ₁	Für alle lags k gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H ₁	W(RT) = 0,00 < $\alpha = 0,05$ ⇒ H ₁
Maurer Lübeck	ADF = -5,39 < $k_{(1\%)} = -3,55$ ⇒ H ₁ (lag 3) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 3,90 > t_{\alpha} = 1,96$ $ \vartheta_2 = 1,23 \leq t_{\alpha} = 1,96$ $S = 16,72 > \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,04 < $\alpha = 0,05$ ⇒ H ₁	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H ₁	W(RT) = 0,00 < $\alpha = 0,05$ ⇒ H ₁
Olsson Tinum	ADF = -5,36 < $k_{(1\%)} = -3,55$ ⇒ H ₁ (lag 3) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 1,63 \leq t_{\alpha} = 1,96$ $ \vartheta_2 = 0,45 \leq t_{\alpha} = 1,96$ $S = 2,87 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,39 ≥ $\alpha = 0,05$ ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H ₁	W(RT) = 0,00 < $\alpha = 0,05$ ⇒ H ₁
Beutz Wilhelmshaven	ADF = -4,96 < $k_{(1\%)} = -3,55$ ⇒ H ₁ (lag 3) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 2,30 > t_{\alpha} = 1,96$ $ \vartheta_2 = 0,77 \leq t_{\alpha} = 1,96$ $S = 5,89 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,81 ≥ $\alpha = 0,05$ ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H ₁	W(RT) = 0,00 < $\alpha = 0,05$ ⇒ H ₁

Klasse 5 - Modelltyp 1 (Mit saisonalen Dummies)

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Nolte Bremerhaven	$\hat{y}_t = 242 - 26,6 d_{\text{Feb}} - 35,2 d_{\text{Mrz}} - 14,6 d_{\text{Apr}} - 4,0 d_{\text{Mai}} + 10,6 d_{\text{Jun}} + 24,8 d_{\text{Jul}} + 57,8 d_{\text{Aug}} + 33,2 d_{\text{Sep}} - 17,8 d_{\text{Okt}} - 43,6 d_{\text{Nov}} - 51,0 d_{\text{Dez}}$	Realisationen: 211 ; 192 ; 196 ; 218 alle im Intervall. RMSE = 19,6	Exp. Glättung Holt-Winters mit add. Saison RMSE = 18,8
<u>Modellprotokoll:</u> M.D. = 237 S.D. = 37,2 S.E. = 21,7 DW = 1,94 $R_A^2 = 0,66$ F-ST = 11,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Carlsen Flensburg	$\hat{y}_t = 238,4 - 42,4 d_{\text{Feb}} - 47,4 d_{\text{Mrz}} - 1,8 d_{\text{Apr}} + 24,8 d_{\text{Mai}} + 58,8 d_{\text{Jun}} + 174,8 d_{\text{Jul}} + 231,8 d_{\text{Aug}} + 55,4 d_{\text{Sep}} + 12,8 d_{\text{Okt}} - 47,6 d_{\text{Nov}} - 63,2 d_{\text{Dez}}$	Realisationen: 240 ; 176 ; 178 ; 225 alle im Intervall RMSE = 21,8	Exp. Glättung Holt-Winters mit add. Saison RMSE = 21,4
<u>Modellprotokoll:</u> M.D. = 268 S.D. = 90,8 S.E. = 24,9 DW = 1,76 $R_A^2 = 0,9$ F-ST = 67,1 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
SWV Friedrichshafen	$\hat{y}_t = 106,7 - 0,756 t - 5,4 d_{\text{Feb}} + 0,1 d_{\text{Mrz}} + 11,3 d_{\text{Apr}} + 20,8 d_{\text{Mai}} + 51,4 d_{\text{Jun}} + 83,1 d_{\text{Jul}} + 178,7 d_{\text{Aug}} + 93,0 d_{\text{Sep}} + 37,0 d_{\text{Okt}} - 5,2 d_{\text{Nov}} - 8,7 d_{\text{Dez}}$	Realisationen: 75 ; 71 ; 77 ; 86 alle im Intervall RMSE = 15,7	Exp. Glättung Holt-Winters mit add. Saison RMSE = 15,7
<u>Modellprotokoll:</u> M.D. = 122 S.D. = 57,5 S.E. = 17,6 DW = 1,56 $R_A^2 = 0,91$ F-ST = 48,3 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Keppel Koblenz	$\hat{y}_t = 339,6 - 36,0 d_{\text{Feb}} - 17,4 d_{\text{Mrz}} - 26,4 d_{\text{Apr}} + 20,0 d_{\text{Mai}} + 37,2 d_{\text{Jun}} + 59,2 d_{\text{Jul}} + 94,6 d_{\text{Aug}} + 76,4 d_{\text{Sep}} + 5,2 d_{\text{Okt}} - 47,2 d_{\text{Nov}} - 59,2 d_{\text{Dez}}$	Realisationen: 345 ; 305 ; 271 ; 461 Wert 97:4 <u>nicht</u> im Intervall RMSE = 30,3	Exp. Glättung Holt-Winters mit add. Saison RMSE = 30,9
<u>Modellprotokoll:</u> M.D. = 348 S.D. = 53,7 S.E. = 26,7 DW = 1,90 $R_A^2 = 0,75$ F-ST = 17,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
SWV Konstanz	$\hat{y}_t = 73,3 - 0,435 t - 3,0 d_{\text{Feb}} + 1,3 d_{\text{Mrz}} + 0,9 d_{\text{Apr}} + 18,1 d_{\text{Mai}} + 31,8 d_{\text{Jun}} + 46,0 d_{\text{Jul}} + 113,0 d_{\text{Aug}} + 54,3 d_{\text{Sep}} + 14,7 d_{\text{Okt}} + 2,2 d_{\text{Nov}} - 1,2 d_{\text{Dez}}$	Realisationen: 74 ; 63 ; 66 ; 71 Wert 97:1 <u>nicht</u> im Intervall RMSE = 11,2	Exp. Glättung Holt-Winters mit add. Saison RMSE = 11,2
<u>Modellprotokoll:</u> M.D. = 83 S.D. = 35,1 S.E. = 11,3 DW = 1,94 $R_A^2 = 0,90$ F-ST = 43,8 W(F) = 0,000	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Olsson Tinum	$\hat{y}_t = 93,4 - 44,4 d_{\text{Feb}} - 44,4 d_{\text{Mrz}} - 19,6 d_{\text{Apr}} - 30,4 d_{\text{Mai}} - 1,2 d_{\text{Jun}} + 21,0 d_{\text{Jul}} + 42,0 d_{\text{Aug}} + 11,2 d_{\text{Sep}} + 0,0 d_{\text{Okt}} - 43,8 d_{\text{Nov}} - 49,0 d_{\text{Dez}}$	Realisationen: 79 ; 42 ; 36 ; 74 alle im Intervall RMSE = 10,6	Exp. Glättung Holt-Winter mit add. Saison RMSE = 10,7
<u>Modellprotokoll:</u> M.D. = 80 S.D. = 30,8 S.E. = 11,9 DW = 1,80 $R_A^2 = 0,85$ F-ST = 31,4 W(F) = 0,000	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Klasse 5 - Modelltyp 2 (Mit saisonaler Differenzenbildung)

Grossist	Prognosemodell (1997:01 - 1997:12)	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Carlsen Kiel	$D(\hat{y}_t)_{0;12} = + 0,266 u_{t-1}$ $+ 0,409 u_{t-2} - 0,886 e_{t-12}$ (Saisonale Diff. Δ^1_{12} ; SARIMA(2, 0, 0)(0, 1, 1))	Realisationen: 328 ; 308 ; 295 ; 377 alle im Intervall RMSE = 43,0	Exp. Glättung Holt- Winter mit mult. Saison RMSE = 34,2
<u>Modellprotokoll:</u> M.D. = -0,30 S.D. = 64,2 S.E. = 46,1 DW = 2,13 $R^2_A = 0,48$ F-ST = 22,1 W(F) = 0,000			
Maurer Lübeck	$D(\hat{y}_t)_{1;12} = - 0,527 e_{t-1}$ $- 0,886 e_{t-12} + 0,467 e_{t-13}$ (Doppelte Diff. $\Delta^1 \Delta^1_{12}$; SARIMA(0, 1, 1)(0, 1, 1))	Realisationen: 355 ; 296 ; 288 ; 395 alle im Intervall RMSE = 46,7	Exp. Glättung Holt- Winters mit add. Saison RMSE = 38,2
<u>Modellprotokoll:</u> M.D. = -0,64 S.D. = 74,0 S.E. = 49,3 DW = 2,30 $R^2_A = 0,56$ F-ST = 58,7 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Beutz Wilhelmshaven	$D(\hat{y}_t)_{1;12} = -0,845e_{t-1}$ (Doppelte Diff. $\Delta^1\Delta^1_{12}$; SARIMA(0, 1, 1)(0, 1, 0))	Realisationen: 498 ; 441 ; 395 ; 522 alle im Intervall RMSE = 50,1	Exp. Glättung Holt-Winters mit add. Saison RMSE = 39,6
<u>Modellprotokoll:</u> M.D. = -3,30 S.D. = 71,4 S.E. = 51,3 DW = 2,17 $R^2_A = 0,48$	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. dyn. — Prog. stat. — add. sai. Exp. — HP </p>		

5.2.6 Klasse 6 - Saisonverlauf, signifikante Ausschläge der ACF und PACF auf den ersten lags und auf lag 12

Die graphische Darstellung der Zeitreihen zeigt stärkere zum Teil periodisch schwankende Verläufe über die Zeit. Die Saisonfiguren sind aber nicht so eindeutig und konstant, wie die der Klasse 5.

Eindeutiger fällt die Identifikation der Klasse 6 anhand der ACF, der PACF und der Box-Ljung Q-Statistik aus. Eine Reihe von lags k (mit $k = 1, 2, \dots, 25$) sind deutlich von Null verschieden. Besonders stark fällt der Effekt für lag 12 aus. Hier liegt durchweg eine signifikant positive Abweichung von der Nullhypothese vor.

Schon ab sehr kleinem lag, vielfach ab lag 1, sind die Werte der Box-Ljung Q-Statistik signifikant von Null verschieden, d.h. alle Zeitreihen der Klasse 6 besitzen eine deutliche Abhängigkeitsstruktur. Der Runs-Test führt zu einer nicht so eindeutigen Entscheidung auf Abhängigkeit der Zeitreihenwerte. Nur für 5 der 13 Zeitreihen wird auf die Abhängigkeitshypothese entschieden.

Bis auf zwei Ausnahmen genügen alle Zeitreihen der Normalverteilungshypothese.

Besondere Aufmerksamkeit verdient der ADF-Test. Alle Zeitreihen erfüllen die Bedingung der nicht saisonalen Stationarität.

Die Residuen der ADF-Regressionsgleichung besitzen aber auf lag 12 der ACF und PACF deutlich signifikante Ausschläge.

Die saisonale Stationarität wird analog der bei der Klasse 5 verwendeten Vorgehensweise überprüft.

Als Ergebnis lässt sich festhalten, dass nur bei 2 der 13 Zeitreihen eine saisonale Differenzenbildung vor der Modellbildung zu akzeptablen Ergebnissen in der Prognose führt. Unter Modelltyp 2 werden die beiden Zeitreihen aufgeführt.

Bei den übrigen Zeitreihen wurde ein SARIMA($q; 0; q$) ($Q; 0; P$)₁₂-Modell verwendet (Modelltyp 1), wobei bei einigen Zeitreihen zusätzlich ein linearer deterministischer Trend in die Modellgleichung implementiert wurde. Regressionsmodelle mit saisonalen Dummies führten zu Modellen mit geringem Erklärungsgehalt.

Es soll aber nicht verschwiegen werden, dass bei dieser pragmatischen Vorgehensweise eine Prämisse verletzt wurde, die Zeitreihen sind saisonal nicht stationär. Die Prognoseergebnisse sind aber so überzeugend, dass diese Verletzung akzeptiert werden kann.

Klasse 6	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit	
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist Stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig	
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)
Schmitz Bochum	ADF = -9,06 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 0,55 ≤ t _α = 1,96 ϑ ₂ = 0,68 ≤ t _α = 1,96 S = 0,77 ≤ χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,77 ≥ α = 0,05 ⇒ H ₀	Für lags ab k > 1 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁
Salzmann Braunschweig	ADF = -6,87 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 0,17 ≤ t _α = 1,96 ϑ ₂ = 0,27 ≤ t _α = 1,96 S = 0,10 ≤ χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,99 ≥ α = 0,05 ⇒ H ₀	Für lags k gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,19 ≥ α = 0,05 ⇒ H ₀
Giesdorf Detmold	ADF = -6,64 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend). Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 4,11 > t _α = 1,96 ϑ ₂ = 5,55 > t _α = 1,96 S = 47,73 > χ ² _k = 5,99 ⇒ H ₁	W(K-S) = 0,30 ≥ α = 0,05 ⇒ H ₀	Für lags ab k > 3 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,00 < α = 0,05 ⇒ H ₁
Merkur Frankfurt	ADF = -7,37 < k _(1%) = -4,12 ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 1,91 ≤ t _α = 1,96 ϑ ₂ = 1,95 ≤ t _α = 1,96 S = 7,47 > χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,68 ≥ α = 0,05 ⇒ H ₀	Für lags k = 1 und k > 3: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,20 ≥ α = 0,05 ⇒ H ₀
SWV Freiburg	ADF = -5,48 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 2,47 > t _α = 1,96 ϑ ₂ = 0,05 ≤ t _α = 1,96 S = 6,12 > χ ² _k = 5,99 ⇒ H ₀	W(K-S) = 0,20 ≥ α = 0,05 ⇒ H ₀	Für lags k ≤ 3 und k > 11: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,40 ≥ α = 0,05 ⇒ H ₀

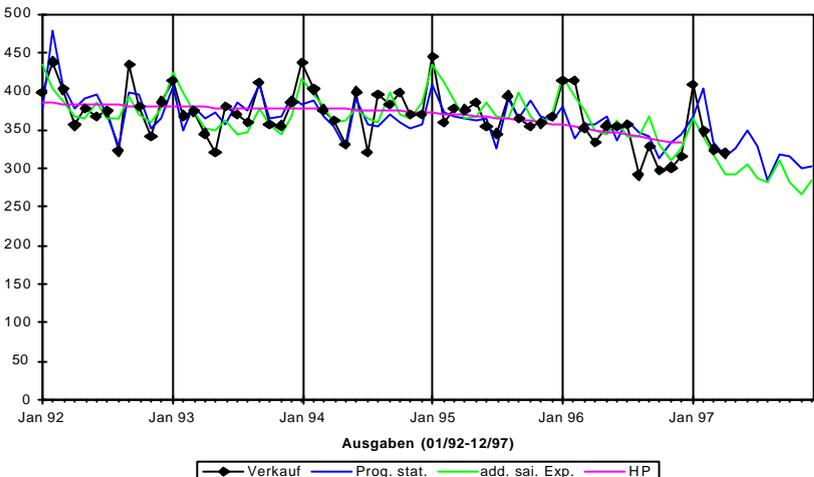
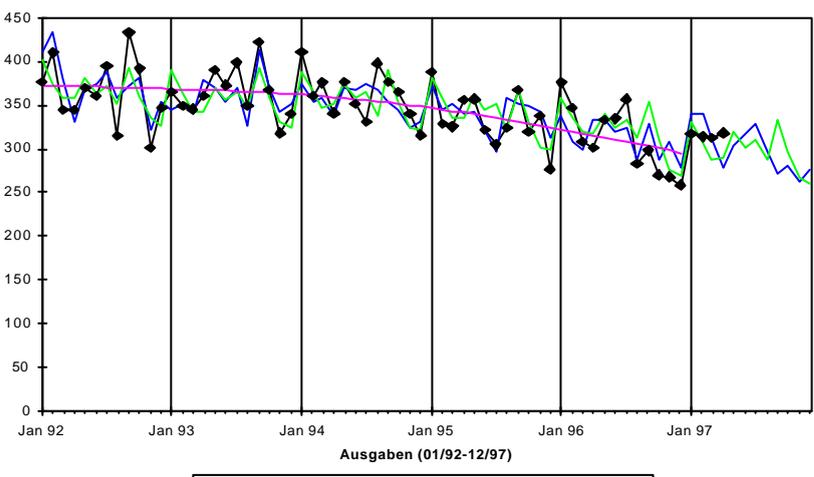
Klasse 6	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit	
		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov- Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)
Grossist	ADF-Test				
Könemann Hagen	ADF = -6,22 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 0,06 \leq t_{\alpha} = 1,96$ $ \hat{\vartheta}_2 = 0,18 \leq t_{\alpha} = 1,96$ $S = 0,04 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,56 ≥ α = 0,05 ⇒ H ₀	Für alle lags k > 2 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,43 ≥ α = 0,05 ⇒ H ₀
Dittmann Kassel	ADF = -6,08 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 1,32 \leq t_{\alpha} = 1,96$ $ \hat{\vartheta}_2 = 0,42 \leq t_{\alpha} = 1,96$ $S = 1,93 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,53 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,02 < α = 0,05 ⇒ H ₁
Doll Köln	ADF = -7,31 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 0,59 \leq t_{\alpha} = 1,96$ $ \hat{\vartheta}_2 = 0,41 \leq t_{\alpha} = 1,96$ $S = 0,51 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,99 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,19 ≥ α = 0,05 ⇒ H ₀
Liebig Kolbermoor	ADF = -4,80 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 1,26 \leq t_{\alpha} = 1,96$ $ \hat{\vartheta}_2 = 0,00 \leq t_{\alpha} = 1,96$ $S = 1,59 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,69 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,01 < α = 0,05 ⇒ H ₁
Lütkemeyer Münster	ADF = -6,16 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 1,28 \leq t_{\alpha} = 1,96$ $ \hat{\vartheta}_2 = 0,46 \leq t_{\alpha} = 1,96$ $S = 1,85 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,82 ≥ α = 0,05 ⇒ H ₀	Für alle lags k > 4 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,12 ≥ α = 0,05 ⇒ H ₀
Hebeisen Offenbach	ADF = -5,96 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+	$ \hat{\vartheta}_1 = 0,69 \leq t_{\alpha} = 1,96$ $ \hat{\vartheta}_2 = 0,68 \leq t_{\alpha} = 1,96$ $S = 0,94 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,92 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,85 ≥ α = 0,05 ⇒ H ₀

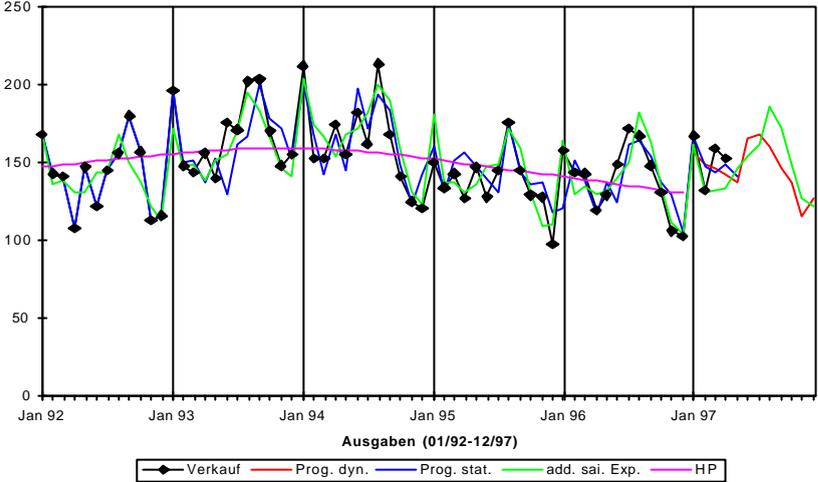
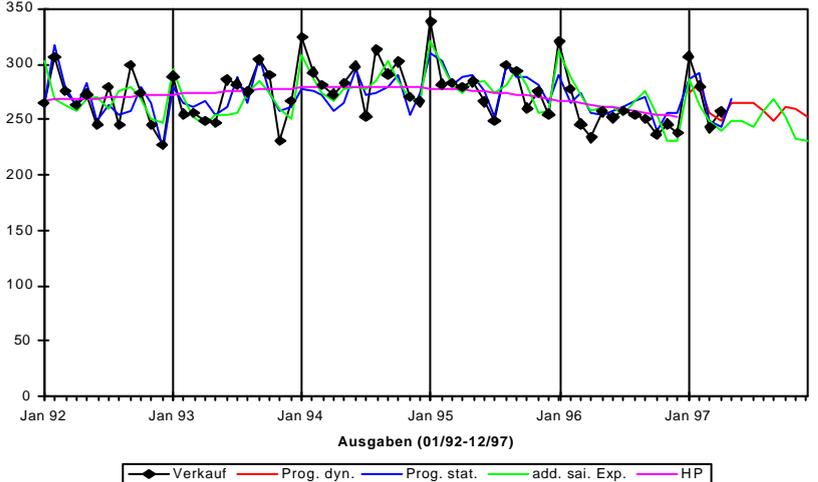
Klasse 6	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit	
		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 15)	Runs Test (RT) (Berechnung mit arith. Mittel)
Grossist	ADF-Test				
VPV-Lamich Rendsburg	ADF = -5,42 < $k_{(1\%)} = -3,54$ ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 1,55 \leq t_\alpha = 1,96$ $ \hat{\vartheta}_2 = 0,27 \leq t_\alpha = 1,96$ $S = 2,49 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,55 ≥ α = 0,05 ⇒ H ₀	Für lags k = 1 und k > 7: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,01 < α = 0,05 ⇒ H ₁
Strobel Sindelfingen	ADF = -5,84 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 1 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 2,16 > t_\alpha = 1,96$ $ \hat{\vartheta}_2 = 2,91 > t_\alpha = 1,96$ $S = 13,2 > \chi^2_k = 5,99 \Rightarrow H_1$	W(K-S) = 0,47 ≥ α = 0,05 ⇒ H ₀	Für lag k = 1 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁ ?	W(RT) = 0,22 ≥ α = 0,05 ⇒ H ₀
Bümmer Weiterstadt	ADF = -4,68 < $k_{(1\%)} = -4,12$ ⇒ H ₁ (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \hat{\vartheta}_1 = 0,61 \leq t_\alpha = 1,96$ $ \hat{\vartheta}_2 = 1,29 \leq t_\alpha = 1,96$ $S = 2,03 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,59 ≥ α = 0,05 ⇒ H ₀	Für alle lags gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,33 ≥ α = 0,05 ⇒ H ₀

Klasse 6 - Modelltyp 1 (Mit saisonalem ARMA-Teil)

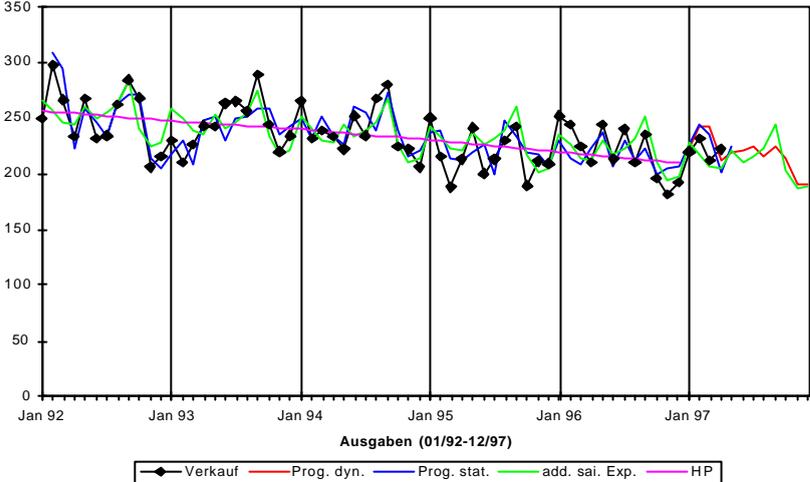
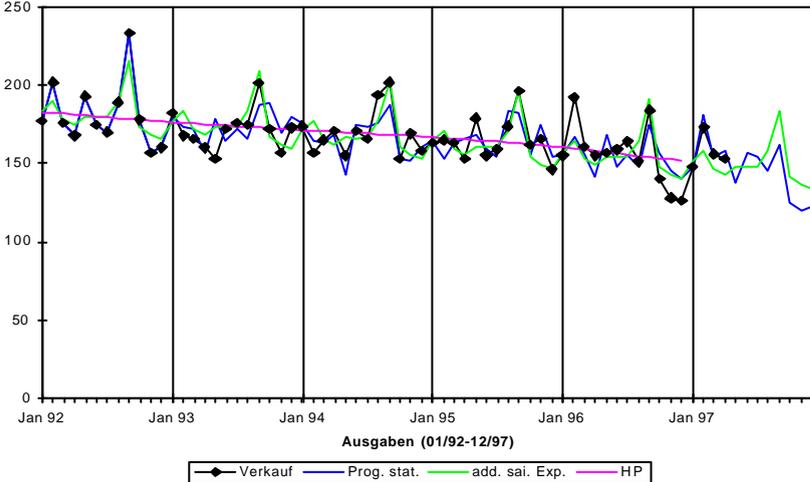
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Schmitz Bochum	$\hat{y}_t = 270,5 - 0,831 t - 0,301 u_{t-1} + 0,876 e_{t-12}$ (Linearer Trend + SARIMA(1, 0, 0)(0, 0, 1))	Realisationen: 271 ; 229 ; 237 ; 241 Wert 97:4 <u>nicht</u> im Intervall RMSE = 15,2	Exp. Glättung Holt-Winters mit add. Saison RMSE = 14,5
<u>Modellprotokoll:</u> M.D. = 243 S.D. = 23,7 S.E. = 14,5 DW = 1,94 $R_A^2 = 0,63$ F-ST = 33,4 W(F) = 0,000			
Salzmann Braunschweig	$\hat{y}_t = 532,0 - 1,511 t + 0,860 e_{t-12}$ (Linearer Trend + SARIMA(0; 0; 0) (0; 0; 1))	Realisationen: 492 ; 455 ; 442 ; 442 alle im Intervall RMSE = 25,8	Exp. Glättung Holt-Winters mit add. Saison RMSE = 25,2
<u>Modellprotokoll:</u> M.D. = 486 S.D. = 41,6 S.E. = 26,1 DW = 1,88 $R_A^2 = 0,61$ F-ST = 46,5 W(F) = 0,000			

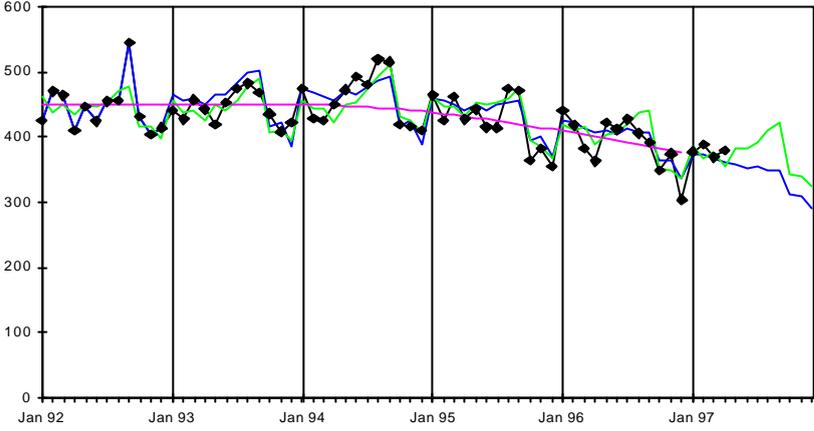
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Giesdorf Detmold	$\hat{y}_t = 180,4 + 0,886 e_{t-12}$ SARIMA(0; 0; 0) (0; 0; 1)	Realisationen: 208 ; 181 ; 181 ; 177 alle im Intervall RMSE = 13,9	Exp. Glättung Holt-Winters mit add. Saison RMSE = 12,6
<u>Modellprotokoll:</u> M.D. = 178 S.D. = 21,3 S.E. = 13,8 DW = 1,85 $R_A^2 = 0,58$ F-ST = 82,3 W(F) = 0,000	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
SWV Freiburg	$\hat{y}_t = 120,4 + 0,630 u_{t-12} - 0,885 e_{t-12}$ SARIMA(0, 0, 0)(1, 0, 1)	Realisationen: 106 ; 97 ; 112 ; 132 alle im Intervall RMSE = 9,5	Exp. Glättung Holt-Winters mit add. Saison RMSE = 10,2
<u>Modellprotokoll:</u> M.D. = 112 S.D. = 17,4 S.E. = 9,5 DW = 2,09 $R_A^2 = 0,70$ F-ST = 56,6 W(F) = 0,000	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Könemann Hagen	$\hat{y}_t = 399,7 - 1,010 t + 0,865 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0 1))	Realisationen: 409 ; 348 ; 324 ; 319 Wert 97:2 <u>nicht</u> im Intervall RMSE = 25,2	Exp. Glättung Holt-Winters mit add. Saison RMSE = 23,6
<u>Modellprotokoll:</u> M.D. = 369 S.D. = 34,2 S.E. = 24,8 DW = 1,64 $R_A^2 = 0,47$ F-ST = 27,5 W(F) = 0,000			
Doll Köln	$\hat{y}_t = 389,5 - 1,317 t + 0,861 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(0, 0, 1))	Realisationen: 317; 314 ; 313 ; 318 alle im Intervall RMSE = 23,9	Exp. Glättung Holt-Winters mit add. Saison RMSE = 23,4
<u>Modellprotokoll:</u> M.D. = 348 S.D. = 38,5 S.E. = 24,3 DW = 1,81 $R_A^2 = 0,60$ F-ST = 45,5 W(F) = 0,000			

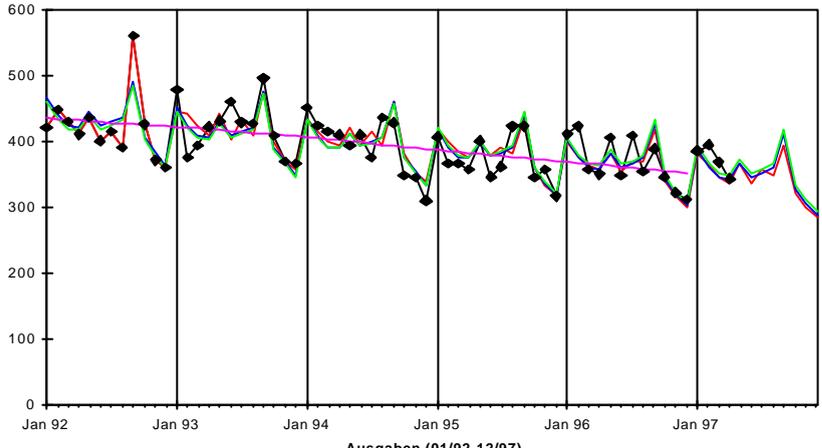
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Liebig Kolbermoor	$\hat{y}_t = 147,0 + 0,413 u_{t-1} + 0,200 u_{t-12} - 0,083 u_{t-13} + 0,867 e_{t-12}$ SARIMA(1, 0, 0)(1, 0, 1)	Realisationen: 167 ; 132 ; 159 ; 153 alle im Intervall RMSE = 15,4	Exp. Glättung Holt-Winters mit add. Saison RMSE = 14,5
<u>Modellprotokoll:</u> M.D. = 151 S.D. = 26,0 S.E. = 15,4 DW = 2,08 $R_A^2 = 0,65$ F-ST = 29,3 W(F) = 0,000			
Lütkemeyer Münster	$\hat{y}_t = 269,9 + 0,280 u_{t-1} + 0,886 e_{t-12}$ SARIMA(1, 0, 0)(0, 0, 1)	Realisationen: 307 ; 280 ; 243 ; 257 alle im Intervall RMSE = 16,5	Exp. Glättung Holt-Winters mit add. Saison RMSE = 17,2
<u>Modellprotokoll:</u> M.D. = 272 S.D. = 24,6 S.E. = 17,3 DW = 1,99 $R_A^2 = 0,50$ F-ST = 30,5 W(F) = 0,000			

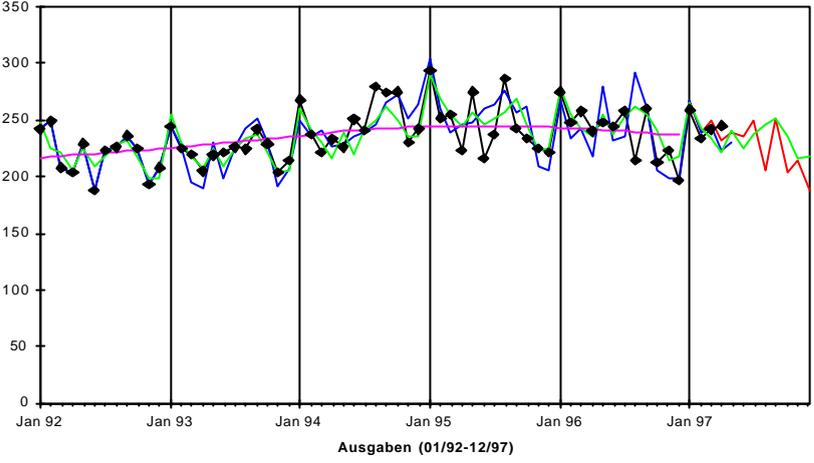
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
VPV-Lamich Rendsburg	(1) $\hat{y}_t = 272,4 + 0,438 u_{t-12} + 0,859 e_{t-12}$ SARIMA(0, 0, 0)(1, 0, 1) (2) $\hat{y}_t = 295,2 - 40,2 d_{\text{Feb}} - 35,2 d_{\text{Mrz}} - 46,6 d_{\text{Apr}} - 30,0 d_{\text{Mai}} - 16,6 d_{\text{Jun}} + 2,6 d_{\text{Jul}} + 18,2 d_{\text{Aug}} + 4,0 d_{\text{Sep}} - 16,4 d_{\text{Okt}} - 49,8 d_{\text{Nov}} - 71,8 d_{\text{Dez}}$	Realisationen: 288 ; 249 ; 224 ; 246 alle im Intervall (1) RMSE = 19,1 (2) RMSE = 18,7	Exp. Glättung Holt-Winters mit add. Saison RMSE = 18,6
<u>Modellprotokoll:</u> (zu Modell 1) M.D. = 273 S.D. = 32,6 S.E. = 19,4 DW = 1,97 $R_A^2 = 0,65$ F-ST = 44,0 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Hebeisen Offenbach	$\hat{y}_t = 255,1 - 0,622 t$ $+ 0,383 u_{t-1} + 0,886 e_{t-12}$ (Linearer Trend + SARIMA(1, 0, 0)(0, 0, 1))	Realisationen: 220 ; 232 ; 212 ; 222 alle im Intervall RMSE = 15,8	Exp. Glättung Holt- Winters mit add. Saison RMSE = 16,5
<u>Modellprotokoll:</u> M.D. = 234 S.D. = 26,3 S.E. = 16,1 DW = 2,09 $R_A^2 = 0,63$ F-ST = 33,8 W(F) = 0,000			
Strobel Sindelfingen	$\hat{y}_t = 192,3 - 0,705 t$ $+ 0,306 u_{t-12} + 0,838 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 148 ; 173 ; 156 ; 153 alle im Intervall RMSE = 10,5	Exp. Glättung Holt- Winters mit add. Saison RMSE = 9,9
<u>Modellprotokoll:</u> M.D. = 165 S.D. = 15,9 S.E. = 11,2 DW = 1,90 $R_A^2 = 0,50$ F-ST = 17,0 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Brümmer Weiterstadt	$\hat{y}_t = 1084,1 - 8,389 t$ $+ 0,788 u_{t-12} - 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 378 ; 388 ; 369 ; 380 alle im Intervall RMSE = 21,6	Exp. Glättung Holt-Winters mit add. Saison RMSE = 22,6
<u>Modellprotokoll:</u> M.D. = 430 S.D. = 43,4 S.E. = 21,9 DW = 1,79 $R_A^2 = 0,75$ F-ST = 46,8 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> Verkauf Prog. stat. add. sai. Exp. HP </p>		

Klasse 6 - Modelltyp 2 (Mit saisonaler Differenzenbildung)

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Mercur Frankfurt	(1) $D(\hat{y}_t)_{0:12} = -18,1 - 0,867 e_{t-12}$ (Saisonale Diff. Δ_{12}^1 ; SARIMA(0, 0, 0)(0, 1, 1)) (2) $\hat{y}_t = 466,5 - 1,301 t$ $- 25,3 d_{\text{Feb}} - 39,2 d_{\text{Mrz}}$ $- 40,1 d_{\text{Apr}} - 15,2 d_{\text{Mai}}$ $- 34,5 d_{\text{Jun}} - 28,0 d_{\text{Jul}}$ $- 18,7 d_{\text{Aug}} + 35,6 d_{\text{Sep}}$ $- 47,3 d_{\text{Okt}} - 68,2 d_{\text{Nov}}$ $- 86,5 d_{\text{Dez}}$	Realisationen: 386 ; 395 ; 368 ; 343 alle im Intervall (1) RMSE = 25,2 (2) RMSE = 24,2	Exp. Glättung Holt-Winters mit add. Saison RMSE = 24,2
<u>Modellprotokoll:</u> (Modell 1) M.D. = -13,4 S.D. = 36,2 S.E. = 26,1 DW = 2,22 $R_A^2 = 0,48$ F-ST = 44,2 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. (1) — Prog. stat. (2) — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Dittmann Kassel	$D(\hat{y}_t)_{1;12} = -0,975 e_{t-1} + 0,573 e_{t-2}$ (Doppelte Diff. $\Delta^1 \Delta_{12}^1$; SARIMA(0, 1, 2)(0, 1, 0))	Realisationen: 259 ; 234 ; 242 ; 245 alle im Intervall RMSE = 20,4	Exp. Glättung Holt-Winters mit add. Saison RMSE = 14,9
<u>Modellprotokoll:</u> M.D. = -0,55 S.D. = 33,6 S.E. = 21,4 DW = 2,17 $R_A^2 = 0,59$ F-ST = 67,7 W(F) = 0,000			

5.2.7 Klasse 7 - Saisonverlauf, signifikante Ausschläge der ACF und PACF auf lag 12

Die Zeitreihen, die zur Klasse 7 zusammengefasst wurden, weisen ähnliche graphische Verläufe wie die Zeitreihen der Klasse 6 auf. Unterschiede zwischen den beiden Klassen gibt es hinsichtlich der ACF, der PACF und der Box-Ljung Q-Statistik. Stark signifikant von Null abweichende Werte der ACF und der PACF treten für die Klasse 7 nur für lag 12 auf. Die Q-Statistik weist erst ab lag 12 signifikant von Null abweichende Prüfgrößenwerte auf.

Alle Zeitreihen erfüllen die Bedingung der nicht saisonalen Stationarität. Analog der Zeitreihen der Klasse 6 treten auch hier Probleme auf lag 12 der Residuen der ADF-Testgleichung auf. Die ACF- und PACF-Werte auf lag 12 sind hoch signifikant größer als Null. Bei diesen Zeitreihen werden ebenfalls der saisonale Differenzierungsgrad und die Regressionsansätze mit saisonalen Dummies überprüft. Dabei kristallisierten sich drei Modellvarianten heraus. Modelltyp 1 enthält jene Zeitreihen, die durch rein deterministische Modellansätze zu guten Anpassungen und Prognosen führen. Zeitreihen, bei denen man mit SARIMA(p, 0, q)(P, 0, Q)₁₂-Modellen zu guten Anpassungen und Prognoseergebnissen gelangt, werden zum Modelltyp 2 zusammengefasst. Dabei darf nicht vergessen werden, dass dabei die Bedingung der saisonalen Stationarität der Zeitreihen nicht erfüllt ist.

Der Modelltyp 3 enthält eine Zeitreihe, bei der die saisonale Differenzenbildung zu akzeptablen Ergebnissen in der Modellanpassung und Prognose führt.

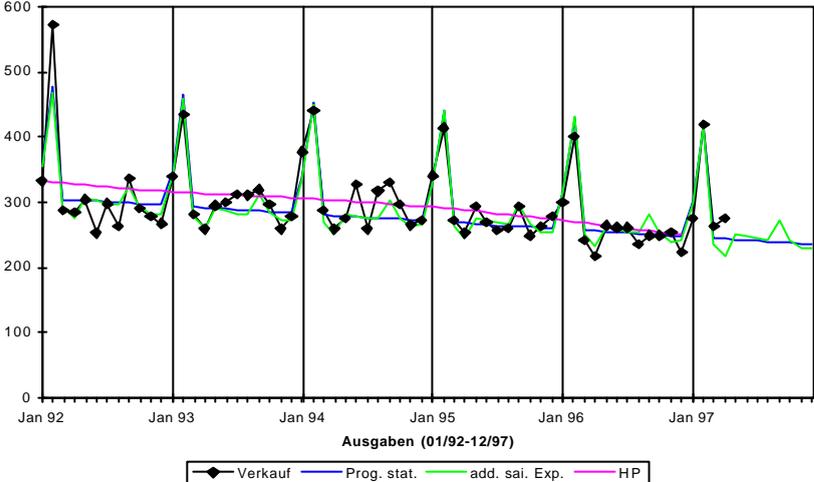
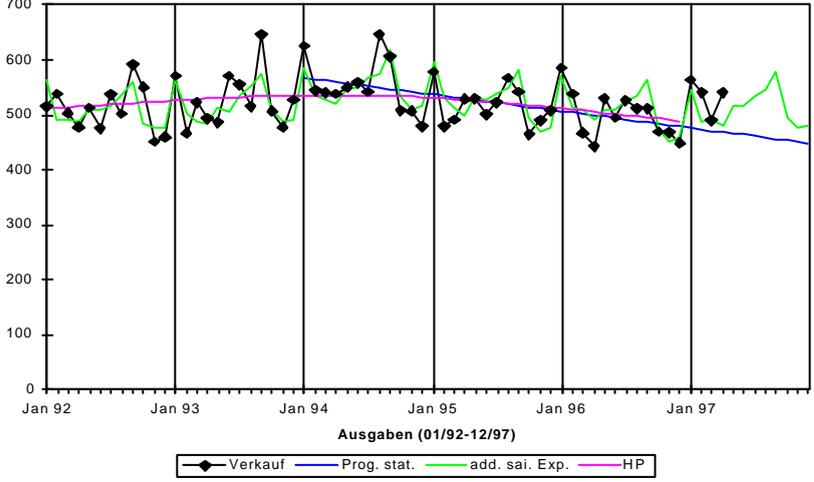
Klasse 7	Stationarität		Tests auf Normalverteilung		Tests auf Unabhängigkeit	
	H ₀ : Zeitreihe ist nicht stationär H ₁ : Zeitreihe ist stationär		H ₀ : Zeitreihe ist NV H ₁ : Zeitreihe ist nicht NV		H ₀ : Zeitreihe ist unabhängig H ₁ : Zeitreihe ist abhängig	
Grossist	ADF-Test		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov-Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)
Trunk Betzgau	ADF = -6,87 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 3,57 > t _α = 1,96 ϑ ₂ = 1,73 ≤ t _α = 1,96 S = 15,72 > χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,13 ≥ α = 0,05 ⇒ H ₀	Für alle lags k ≥ 12 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,01 < α = 0,05 ⇒ H ₁
Leistner Düsseldorf	ADF = -6,57 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 7,17 > t _α = 1,96 ϑ ₂ = 10,58 > t _α = 1,96 S = 163,4 > χ _k ² = 5,99 ⇒ H ₁	W(K-S) = 0,03 < α = 0,05 ⇒ H ₁	Für alle lags k ≥ 12 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,05 ≥ α = 0,05 ⇒ H ₀
Schmitz Duisburg	ADF = -6,11 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 2,15 > t _α = 1,96 ϑ ₂ = 0,42 ≤ t _α = 1,96 S = 4,81 ≤ χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,83 ≥ α = 0,05 ⇒ H ₀	Für alle lags k ≥ 12 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,61 ≥ α = 0,05 ⇒ H ₀
PVG Giessen	ADF = -6,27 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+		ϑ ₁ = 0,39 ≤ t _α = 1,96 ϑ ₂ = 0,44 ≤ t _α = 1,96 S = 0,35 ≤ χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 1,00 ≥ α = 0,05 ⇒ H ₀	Für alle lags k ≥ 12 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,45 ≥ α = 0,05 ⇒ H ₀
Schmitt Heidelberg	ADF = -5,95 < k _(1%) = -3,54 ⇒ H ₁ (lag 0) Resid. lag 12: AC+ u. PAC+		ϑ ₁ = 0,87 ≤ t _α = 1,96 ϑ ₂ = 0,46 ≤ t _α = 1,96 S = 0,97 ≤ χ _k ² = 5,99 ⇒ H ₀	W(K-S) = 0,91 ≥ α = 0,05 ⇒ H ₀	Für alle lags k ≥ 12 gilt: W(Q-Stat.) < α = 0,05 ⇒ H ₁	W(RT) = 0,45 ≥ α = 0,05 ⇒ H ₀

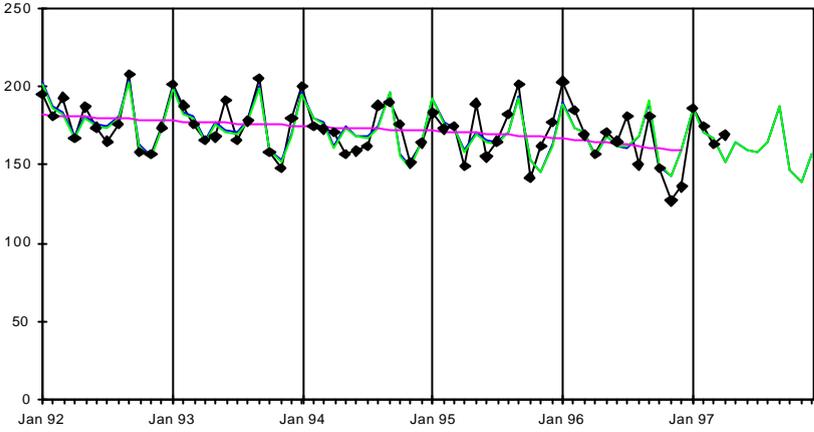
Klasse 7	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit	
		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov- Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 24)	Runs-Test (RT) (Berechnung mit arith. Mittel)
Grossist	ADF-Test				
Wertgen Minden	$ADF = -1,95 \geq k_{(1\%)} = -3,55$ $\Rightarrow H_0$ (lag 3) <u>Saisonale Differenz (D = 1):</u> $ADF = -6,38 < k_{(1\%)} = -2,61$ $\Rightarrow H_1$ (lag 4)	$ \vartheta_1 = 1,33 \leq t_\alpha = 1,96$ $ \vartheta_2 = 4,33 > t_\alpha = 1,96$ $S = 20,54 > \chi^2_k = 5,99 \Rightarrow H_0$	$W(K-S) = 0,71 \geq \alpha = 0,05$ $\Rightarrow H_0$	Für 4, 8, 9 und lags $k \geq 12$ gilt: $W(Q-Stat.) < \alpha = 0,05$ $\Rightarrow H_1$	$W(RT) = 0,12 \geq \alpha = 0,05$ $\Rightarrow H_0$
Finsterbusch Mühdorf	$ADF = -5,28 < k_{(1\%)} = -3,55$ $\Rightarrow H_1$ (lag 2) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 0,75 \leq t_\alpha = 1,96$ $ \vartheta_2 = 0,17 \leq t_\alpha = 1,96$ $S = 0,60 \leq \chi^2_k = 5,99 \Rightarrow H_0$	$W(K-S) = 0,99 \geq \alpha = 0,05$ $\Rightarrow H_0$	Für alle lags $k \geq 12$ gilt: $W(Q-Stat.) < \alpha = 0,05$ $\Rightarrow H_1$	$W(RT) = 0,43 \geq \alpha = 0,05$ $\Rightarrow H_0$
NPV Nürnberg	$ADF = -6,43 < k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 1,85 \leq t_\alpha = 1,96$ $ \vartheta_2 = 2,38 > t_\alpha = 1,96$ $S = 9,09 > \chi^2_k = 5,99 \Rightarrow H_0$	$W(K-S) = 0,27 \geq \alpha = 0,05$ $\Rightarrow H_0$	Für alle lags k gilt: $W(Q-Stat.) \geq \alpha = 0,05$ $\Rightarrow H_0$	$W(RT) = 0,20 \geq \alpha = 0,05$ $\Rightarrow H_0$
Schmitt Pforzheim	$ADF = -6,00 < k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 2,67 > t_\alpha = 1,96$ $ \vartheta_2 = 1,26 \leq t_\alpha = 1,96$ $S = 8,69 > \chi^2_k = 5,99 \Rightarrow H_0$	$W(K-S) = 0,23 \geq \alpha = 0,05$ $\Rightarrow H_0$	Für 12, 13, 22, 23, 24: $W(Q-Stat.) < \alpha = 0,05$ $\Rightarrow H_1$	$W(RT) = 0,12 \geq \alpha = 0,05$ $\Rightarrow H_0$
Schmitt Schutterwald	$ADF = -5,80 < k_{(1\%)} = -3,54$ $\Rightarrow H_1$ (lag 0) Resid. lag 12: AC+ u. PAC+	$ \vartheta_1 = 1,43 \leq t_\alpha = 1,96$ $ \vartheta_2 = 0,15 \leq t_\alpha = 1,96$ $S = 2,08 \leq \chi^2_k = 5,99 \Rightarrow H_0$	$W(K-S) = 0,55 \geq \alpha = 0,05$ $\Rightarrow H_0$	Für alle lags $k \geq 12$ gilt: $W(Q-Stat.) < \alpha = 0,05$ $\Rightarrow H_1$	$W(RT) = 0,40 \geq \alpha = 0,05$ $\Rightarrow H_0$

Klasse 7	Stationarität	Tests auf Normalverteilung		Tests auf Unabhängigkeit	
		Schiefe; Wölbung; Jarque Bera	Kolmogorov-Smirnov Test (K-S)	Ljung-Box (Q-Stat.) (Von lag k = 1 bis 15)	Runs Test (RT) (Berechnung mit arith. Mittel)
Grossist	ADF-Test				
Getzkow Ulm	ADF = -6,65 < $k_{(1\%)} = -4,12$ ⇒ H_1 (lag 0 u. det. Trend) Resid. lag 12: AC+	$ \hat{\theta}_1 = 0,49 \leq t_\alpha = 1,96$ $ \hat{\theta}_2 = 0,26 \leq t_\alpha = 1,96$ $S = 0,30 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,89 ≥ $\alpha = 0,05$ ⇒ H_0	Für 12, 16, 19, 20, 21 gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,60 ≥ $\alpha = 0,05$ ⇒ H_0
PVG Wiesbaden	ADF = -6,93 < $k_{(1\%)} = -4,12$ ⇒ H_1 . (lag 0 u. det. Trend) Resid. lag 12: AC+ u. PAC+	$ \hat{\theta}_1 = 0,84 \leq t_\alpha = 1,96$ $ \hat{\theta}_2 = 1,06 \leq t_\alpha = 1,96$ $S = 1,83 \leq \chi^2_k = 5,99 \Rightarrow H_0$	W(K-S) = 0,79 ≥ $\alpha = 0,05$ ⇒ H_0	Für alle lags k ≥ 12 gilt: W(Q-Stat.) < $\alpha = 0,05$ ⇒ H_1	W(RT) = 0,13 ≥ $\alpha = 0,05$ ⇒ H_0

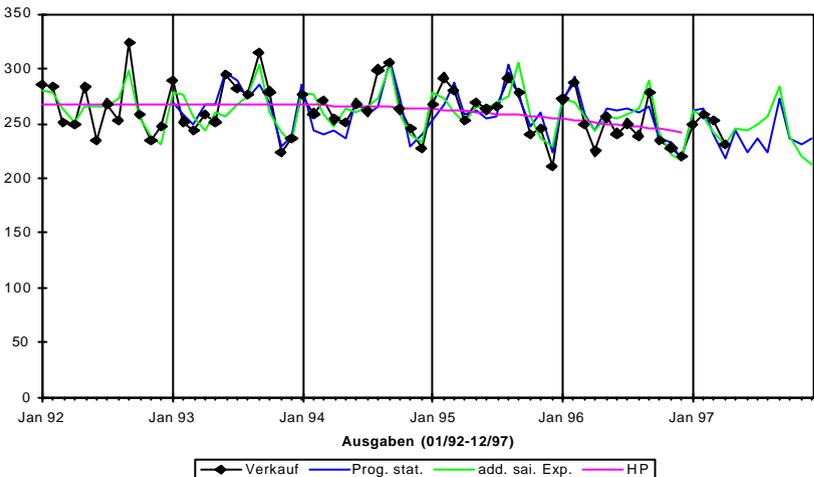
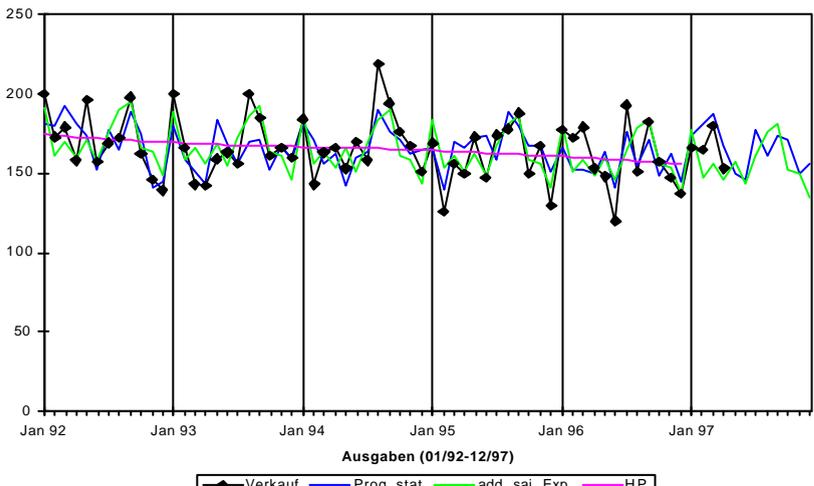
Klasse 7 - Modelltyp 1 (Deterministische Ansätze)

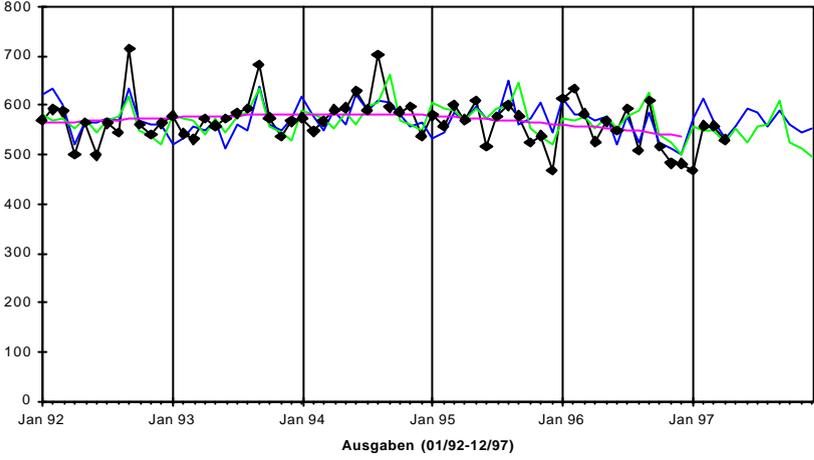
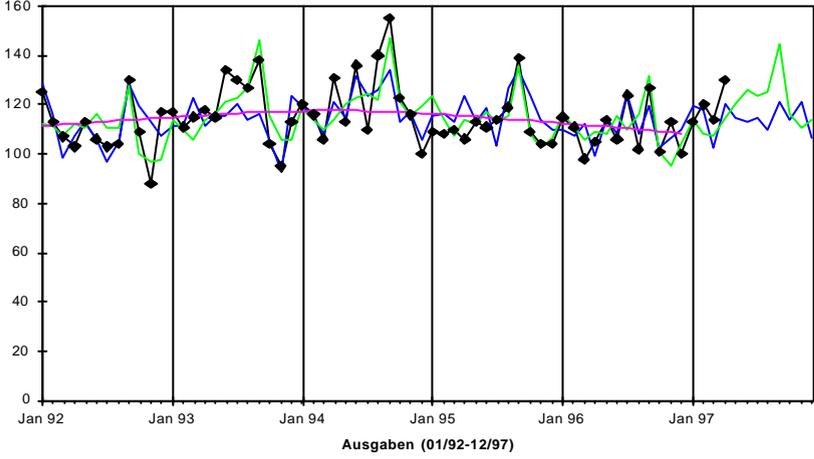
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Trunk Betzigau	$\hat{y}_t = 168,5 - 0,243 t$ - 41,2 d _{Feb} - 40,7 d _{Mrz} - 56,7 d _{Apr} - 64,8 d _{Mai} - 65,4 d _{Jun} - 59,1 d _{Jul} - 49,7 d _{Aug} - 42,9 d _{Sep} - 61,8 d _{Okt} - 69,6 d _{Nov} - 69,5 d _{Dez}	Realisationen: 134 ; 116 ; 121 ; 112 alle im Intervall RMSE = 10,6	Exp. Glättung Holt-Winters mit add. Saison RMSE = 10,6
<u>Modellprotokoll:</u> M.D. = 109 S.D. = 22,4 S.E. = 11,7 DW = 2,07 $R_A^2 = 0,73$ F-ST = 14,1 W(F) = 0,000	<p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> Verkauf Prog. stat. add. sai. Exp. HP </p>		

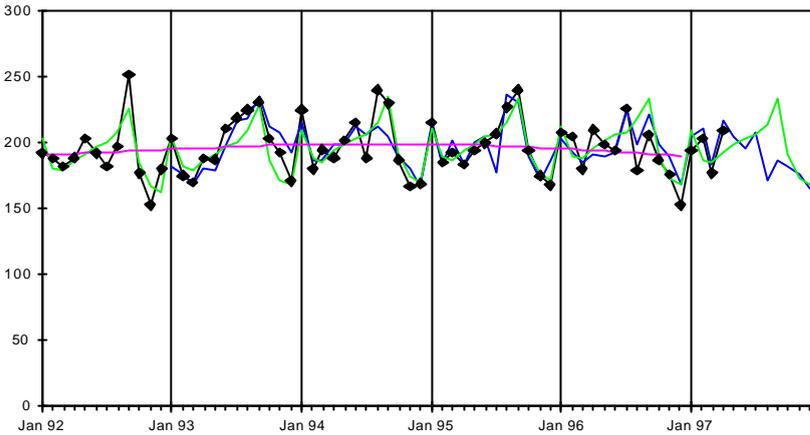
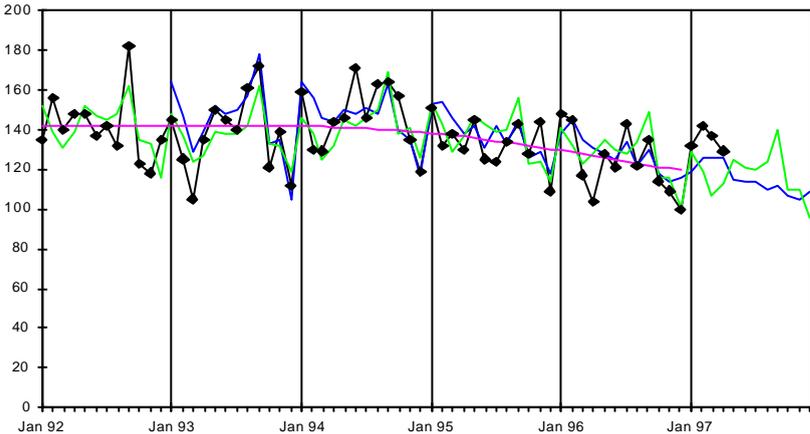
Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Leister Düsseldorf	$\hat{y}_t = 307,6 - 0,993 t$ $+ 55,0 d_{\text{Jan}} + 170,8 d_{\text{Feb}}$	Realisationen: 276 ; 419 ; 263 ; 275 alle im Intervall RMSE = 25,6	Exp. Glättung Holt-Winters mit add. Saison RMSE = 24,0
<u>Modellprotokoll:</u> M.D. = 296 S.D. = 59,4 S.E. = 26,7 DW = 2,05 $R_A^2 = 0,80$ F-ST = 78,7 W(F) = 0,000			
Schmitz Duisburg	<u>Stütz.: (01/94-12/96)</u> $\hat{y}_t = 631,2 - 2,536 t$	Realisationen: 564 ; 541 ; 490 ; 541 Wert 97:1 <u>nicht</u> im Intervall RMSE = 42,1	Exp. Glättung Holt-Winters mit add. Saison RMSE = 32,0
<u>Modellprotokoll:</u> M.D. = 523 S.D. = 47,2 S.E. = 39,5 DW = 1,64 $R_A^2 = 0,30$ F-ST = 16,0 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
PVG Giessen	$\hat{y}_t = 203,3 - 0,275 t$ - 15,7 d _{Feb} - 18,7 d _{Mrz} - 33,6 d _{Apr} - 20,9 d _{Mai} - 26,2 d _{Jun} - 27,0 d _{Jul} - 19,7 d _{Aug} + 2,8 d _{Sep} - 37,5 d _{Okt} - 44,7 d _{Nov} - 27,2 d _{Dez}	Realisationen: 186 ; 175 ; 163 ; 169 alle im Intervall RMSE = 9,6	Exp. Glättung Holt-Winters mit add. Saison RMSE = 9,7
<u>Modellprotokoll:</u> M.D. = 173 S.D. = 17,6 S.E. = 10,9 DW = 1,97 $R_A^2 = 0,62$ F-ST = 8,86 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Klasse 7 - Modelltyp 2 (Mit saisonalem ARMA-Teil)

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Schmitt Heidelberg	$\hat{y}_t = 245,9 + 0,536 u_{t-12} + 0,879 e_{t-12}$ SARIMA(0, 0, 0)(1, 0, 1)	Realisationen: 249 ; 258 ; 253 ; 231 alle im Intervall RMSE = 13,3	Exp. Glättung Holt-Winters mit add. Saison RMSE = 14,1
<u>Modellprotokoll:</u> M.D. = 261 S.D. = 23,8 S.E. = 13,6 DW = 1,50 $R_A^2 = 0,67$ F-ST = 49,2 W(F) = 0,000			
Finsterbusch Mühldorf	$\hat{y}_t = 163,7 + 0,873 e_{t-12}$ SARIMA(0, 0, 0)(0, 0, 1)	Realisationen: 166 ; 165 ; 180; 153 alle im Intervall RMSE = 14,1	Exp. Glättung Holt-Winters mit add. Saison RMSE = 13,7
<u>Modellprotokoll:</u> M.D. = 165 S.D. = 20,0 S.E. = 14,4 DW = 1,80 $R_A^2 = 0,48$ F-ST = 56,0 W(F) = 0,000			

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
NPV Nürnberg	$\hat{y}_t = 569,1 + 0,879e_{t-12}$ SARIMA(0, 0, 0)(0, 0, 1)	Realisationen 468 ; 558 ; 559 ; 530 alle im Intervall RMSE = 37,5	Exp. Glättung Holt-Winters mit add. Saison RMSE = 36,8
<u>Modellprotokoll:</u> M.D. = 570 S.D. = 46,8 S.E. = 33,7 DW = 1,78 $R_A^2 = 0,48$ F-ST = 55,7 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Schmitt Pforzheim	$\hat{y}_t = 115,0 + 0,885 e_{t-12}$ SARIMA(0, 0, 0)(0, 0, 1)	Realisationen: 113 ; 120 ; 114; 130 alle im Intervall RMSE = 9,1	Exp. Glättung Holt-Winters mit add. Saison RMSE = 8,8
<u>Modellprotokoll:</u> M.D. = 114 S.D. = 12,5 S.E. = 9,2 DW = 1,82 $R_A^2 = 0,45$ F-ST = 50,2 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Schmitt Schutterwald	$\hat{y}_t = 195,0 + 0,389 u_{t-12} + 0,875 e_{t-12}$ SARIMA(0, 0, 0)(1, 0, 1)	Realisationen: 194 ; 203 ; 177 ; 209 alle im Intervall RMSE = 12,0	Exp. Glättung Holt-Winters mit add. Saison RMSE = 12,7
<u>Modellprotokoll:</u> M.D. = 197 S.D. = 20,8 S.E. = 12,9 DW = 1,80 $R_A^2 = 0,62$ F-ST = 38,9 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		
Getzkow Ulm	$\hat{y}_t = 200,6 - 1,282 t + 0,542 u_{t-12} - 0,886 e_{t-12}$ (Linearer Trend + SARIMA(0, 0, 0)(1, 0, 1))	Realisationen: 132 ; 142 ; 137 ; 129 alle im Intervall RMSE = 11,8	Exp. Glättung Holt-Winters mit add. Saison RMSE = 12,0
<u>Modellprotokoll:</u> M.D. = 135 S.D. = 17,7 S.E. = 10,2 DW = 1,82 $R_A^2 = 0,67$ F-ST = 32,4 W(F) = 0,000	 <p style="text-align: center;">Ausgaben (01/92-12/97)</p> <p style="text-align: center;"> ◆ Verkauf — Prog. stat. — add. sai. Exp. — HP </p>		

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
PVG Wiesbaden	$\hat{y}_t = 314,7 + 0,242 u_{t-1} + 0,860 e_{t-12}$ SARIMA(1, 0, 0)(0, 0, 1)	Realisationen: 298 ; 312 ; 268 ; 307 alle im Intervall RMSE = 22,4	Exp. Glättung Holt-Winters mit add. Saison RMSE = 19,9
<u>Modellprotokoll:</u> M.D. = 319 S.D. = 32,7 S.E. = 23,2 DW = 1,97 $R_A^2 = 0,50$ F-ST = 29,6 W(F) = 0,000			

Klasse 7 - Modelltyp 3 (Mit saisonaler Differenzenbildung)

Grossist	Prognosemodell	Vergleich: Prognose und Realisationen (1997:01 - 1997:04)	Prognose mit der exponentiellen Glättung
Wertgen Minden	$D(\hat{y}_t)_{0;12} = -0,094 e_{t-1} + 0,149 e_{t-2} + 0,196 e_{t-3} - 0,886 e_{t-12} + 0,083 e_{t-13} - 0,132 e_{t-14} - 0,174 e_{t-15}$ (Saisonale Diff. Δ_{12}^1 ; SARIMA(0, 0, 3)(0, 1, 1))	Realisationen: 169 ; 145 ; 129 ; 126 alle im Intervall RMSE = 10,4	Exp. Glättung Holt-Winters mit add. Saison RMSE = 11,7
<u>Modellprotokoll:</u> M.D. = 3,17 S.D. = 16,8 S.E. = 11,3 DW = 1,80 $R_A^2 = 0,55$ F-ST = 20,0 W(F) = 0,000			

6 Abschließende Bemerkungen

Die hier vorgestellten Zeitreihenanalysen wurden in mehreren Schritten durchgeführt. Der erste Schritt bestand in der Beschreibung der Verkaufszahlen einer Special Interest Zeitschrift. Dazu wurden die absoluten Verkaufszahlen pro Grossist für die Jahre 92 bis 96 graphisch dargestellt, die Korrelogramme der ACF und PACF der Verkaufszahlen ermittelt und die Box-Ljung Q-Statistiken berechnet. Zeitreihen mit ähnlichen Korrelogrammen und graphischen Verläufen wurden zusammengefasst. Insgesamt wurden daraus sieben unterschiedliche Klassen gebildet.

Im zweiten Schritt erfolgte die genaue Identifikation der Zeitreihen mit geeigneten Testverfahren. Dadurch erhielt man gegenüber der ersten Klassierung ein deutlich differenzierteres Bild der Zeitreihen.

Als ein Ergebnis lässt sich festhalten, dass die graphische Darstellung der Verkaufszahlen und die Korrelogramme erste wichtige Hinweise über die Struktur der Daten liefern. Trendverläufe, starke saisonale Verläufe, Ausreißer, Wendepunkte, Strukturbrüche und erste Hinweise über funktionale Zusammenhänge lassen sich erkennen. Zur alleinigen Identifikation der Zeitreihen reichen sie aber nicht aus, da in der Regel die beschriebenen Effekte nicht isoliert auftreten, sondern sich vielfach überlagern und damit schwer erkennbar sind. Zum anderen fallen die Unterschiede in den graphischen Darstellungen und den Korrelogrammen zwischen vielen Zeitreihen recht gering aus.

So erklärt sich auch, dass innerhalb der Klassen zum Teil verschiedene Modelltypen, rein deterministische, rein stochastische, gemischte, mit oder ohne Saison, zur Modellierung verwendet wurden.

Die zum Teil enormen Unterschiede in den Prognosequalitäten der Modelle liefern das Hauptargument für die Richtigkeit der Vorgehensweise, die Verkaufszahlen individuell für jeden einzelnen Grossisten mit einem geeigneten Modell zu prognostizieren. Es gibt Zeitreihen, die keinerlei erkennbare Zusammenhänge in den Daten aufweisen. Für die Prognose derartige Zeitreihen wird das arithmetische Mittel verwendet, das keinen Erklärungsgehalt für die Variation der Verkaufswerte besitzt. Demgegenüber gibt es Zeitreihen, für die sich Modelle entwickeln lassen, die mehr als 90% der Variation der Verkaufswerte, gemessen mit dem bereinigten Bestimmtheitsmaß, erklären können.

Im Kapitel 5.1 wurden die von den Verlagen gelieferten Daten vorgestellt. Neben den reinen Verkaufsdaten pro Grossist und Ausgabe wurden auch eine Reihe von weiteren Variablen zur Verfügung gestellt. Dazu zählen die Variablen Bezug (bezug), Bezug aller Einzelhändler mit Nullverkauf (beznnull), Bezug aller Einzelhändler mit Ausverkauf (bezaus = verkaus), Anzahl der Einzelhändler mit Nullverkauf (ehnull), Anzahl der Einzelhändler mit Ausverkauf (ehaus) und Anzahl aller eingeschalteten Einzelhändler (eheing). Daraus konnten weitere Variablen gebildet werden:

Remission: $\text{remi} = \text{bezug} - \text{verkauf}$,
Restlicher Bezug: $\text{bezrest} = \text{bezug} - (\text{beznnull} + \text{bezaus})$,
Restlicher Verkauf: $\text{verkrest} = \text{verkauf} - \text{bezaus}$,
Restliche Anzahl eingeschalteter Einzelhändler: $\text{ehrest} = \text{eheing} - (\text{ehnull} + \text{ehaus})$.

Aus den obigen Variablen wurden eine Reihe von Verhältnissen berechnet, zum Beispiel: Der Durchschnittsverkauf pro Einzelhändler ($\text{verkauf} / \text{eheing}$), der Durchschnittsverkauf pro Einzelhändler mit Ausverkauf ($\text{bezaus} / \text{ehaus}$) oder die Remissionsquote ($\text{remi} / \text{bezug}$). Zur Prognose der Verkaufszahlen kann keine der von den Verlagen zusätzlich gelieferten Variablen und der daraus neu gebildeten Variablen verwendet werden. Sie eignen sich lediglich zur ex-post Betrachtung.

Die Verlage prognostizieren die Verkäufe pro Grossist. Daraus wird die Bezugsmenge disponiert. Die Verteilung der Bezugsmenge auf die Einzelhändler ist Aufgabe der Grossisten. Sie bestimmen die einzuschaltenden Einzelhändler und die pro Einzelhändler ausgelieferte Bezugsmenge.

Die Prognose der Verkäufe ist schon komplex genug. Eine Prognose von Ausverkäufen oder Nullverkäufen ist so gut wie unmöglich, da sich die Komplexität dieser Prozesse um ein Vielfaches erhöht. Die Frage nach der Sinnhaftigkeit einer solchen Prognose für die Verlage stellt sich ebenfalls.

Wie oben erwähnt, können die meisten Variablen nur zur ex-post Betrachtung verwendet werden. Mit ihnen kann unter Umständen die Dispositionsleistung der Grossisten bewertet werden, immer unter der Voraussetzung, dass die Verlage nicht zu hohe Bezugsmengen an die Grossisten liefern.

Zur Prognose zukünftiger Verkaufszahlen sind diese Variablen aber nicht geeignet.

Soweit bekannt, prognostizieren die Verlage nur die gesamte Verkaufsmenge mit Methoden der Zeitreihenanalyse und berechnen durch Zuschläge die pro Auflage zu erstellende und zu verteilende Bezugsmenge. In dieser Arbeit wurde bewußt eine andere deutlich differenzierte Vorgehensweise gewählt. Für jeden Grossisten wurde aus seinen vergangenen Verkäufen ein separates Modell zur kurz- bis mittelfristigen Prognose entwickelt. Die Prognoseergebnisse dienen den Vertriebsdisponenten in den Verlagen als Hilfsmittel zur Optimierung der Bezugsmengen für jeden Grossisten.

Gerade die individuelle Behandlung jedes einzelnen Grossisten liefert für Verlage und Grossisten große Vorteile.

Die Verlage sind damit in der Lage, den Grossisten über die geplanten Bezugsmengen der kommenden Ausgaben vorab zu informieren. Den Grossisten wird eine deutlich verbesserte und konstantere Planung ermöglicht. Sie sind die Vertriebspezialisten in ihrem Gebiet und verfügen über die besten Kenntnisse hinsichtlich der Struktur der Einzelverkaufsstellen. Die Entscheidungen über die möglichen einzuschaltenden Verkaufsstellen können nun mittelfristig geplant werden, ebenso die Höhe der zu beliefernden Bezugsmengen pro Einzelhändler. Durch die optimierte Verteilung der Bezugsmenge ließe sich der tatsächliche Verkauf verbessern und folglich die Remission verringern.

Das latent vorhandene Konfliktpotential zwischen den Interessen von Verlagen und Grossisten könnte durch die bessere Transparenz deutlich verringert werden. Die oft durch starken Aktionismus gekennzeichnete Vertriebsarbeit von Grossisten und Verlagen ließe sich dadurch beruhigen.

Die Verlage könnten sich ein deutlich verbessertes Erfolgs-Kontroll-System aufbauen. Bei einem guten Reporting und einer permanenten Aktualisierung der Modelle ließen sich Abweichungen zwischen prognostizierten und tatsächlich realisierten Verkäufen schnell erkennen.

Zusätzlich ergibt sich für die Verlage die Möglichkeit von Quervergleichen zwischen den Grossisten. Grossisten mit ähnlichen Gebiets- und Verkaufsstrukturen ließen sich miteinander vergleichen. Negative Verkaufsentwicklungen könnten frühzeitig erkannt und korrigiert werden.

Bei der Implementierung der Verkaufsprognosen sollten im hohen Maße die Möglichkeiten zur Automatisierung der Abläufe genutzt werden. Dazu ist ein leistungsfähiges Zeitreihen-Analysetool wie EViews erforderlich, um schnell und komfortabel für jeden Grossisten ein adäquates Modell entwickeln zu können. Besonders wichtig ist aber die Validierung und das Reporting der Modelle.

Das Einlesen der neuen Verkaufsdaten, die Überprüfung zwischen Prognose und den tatsächlichen Verkaufswerten und die Darstellung der Ergebnisse sollten automatisch nach Eingang der neuen Zahlen ablaufen. Neuschätzungen sind erforderlich, wenn die Prognose vorab definierte Gütekriterien nicht mehr erfüllt.

Schrittweise besteht die Möglichkeit, die Modelle zu verfeinern. Eine besondere Verbesserung verspricht die Erfassung von Heft- und Titeleffekten. Dies könnte durch Implementierung eines Systems von Dummy-Variablen geschehen, mit dem zum Beispiel die unterschiedlichen Effekte von Titelbildern erfasst werden. Da dazu Expertenwissen unerlässlich ist, kann dieser Schritt nur in direkter Zusammenarbeit mit den Verlagen erfolgen.

Anhang

Anhang 1

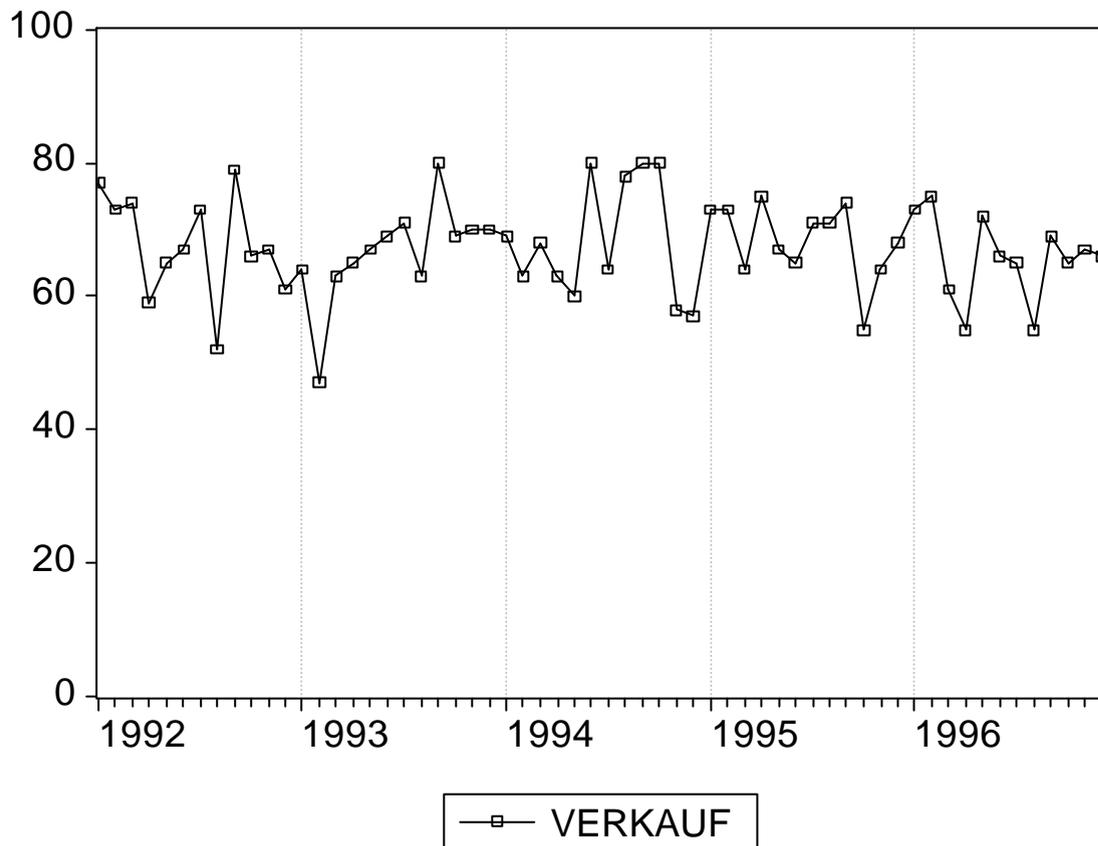
Für jede Klasse von 1 bis 7 werden exemplarisch für einen Grossisten die Verkaufszahlen graphisch aufbereitet sowie die Korrelogramme der ACF und PACF dargestellt.

Anhang 2

Tabelle mit den kritischen Grenzen des Durbin-Watson-Tests.

Anhang 1

Klasse 1: Tonollo Göttingen



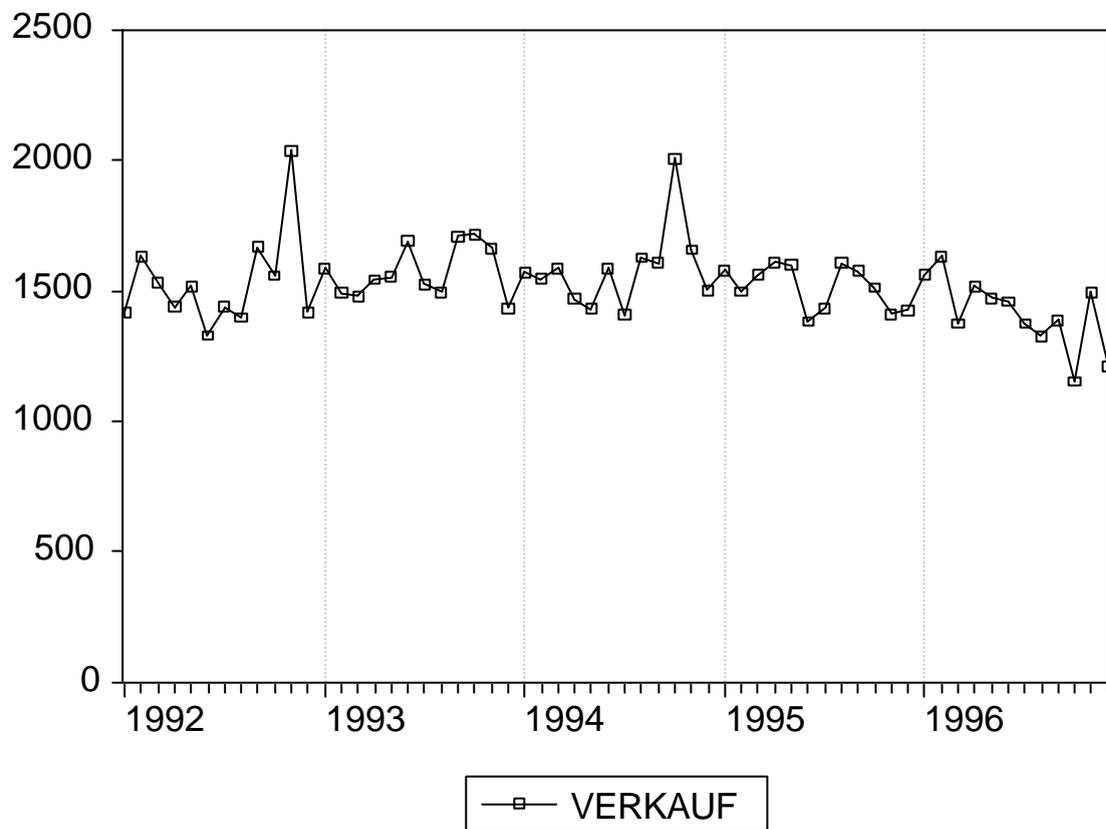
Klasse 1: Tonollo Göttingen

Date: 10/25/99 Time: 17:50

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. .	. .	1	-0.002	-0.002	0.0003	0.986
. .	. .	2	0.004	0.004	0.0015	0.999
. * .	. * .	3	-0.109	-0.109	0.7766	0.855
. * .	. * .	4	0.106	0.107	1.5296	0.821
. * .	. * .	5	-0.141	-0.145	2.8791	0.719
. * .	. * .	6	0.096	0.092	3.5090	0.743
. * .	. * .	7	-0.136	-0.126	4.8102	0.683
. .	. .	8	0.014	-0.015	4.8247	0.776
. .	. .	9	-0.023	0.022	4.8620	0.846
. * .	. * .	10	0.151	0.092	6.5669	0.766
. .	. .	11	-0.011	0.035	6.5760	0.832
. .	. .	12	0.043	0.004	6.7212	0.875
. * .	. * .	13	-0.121	-0.084	7.8877	0.851
. * .	. * .	14	-0.130	-0.173	9.2623	0.814
. .	. * .	15	0.039	0.088	9.3887	0.856
. .	. .	16	0.011	-0.046	9.3998	0.896
. .	. .	17	0.003	0.048	9.4009	0.927
. * .	. * .	18	-0.156	-0.170	11.569	0.869
. * .	. * .	19	-0.124	-0.162	12.957	0.841
. .	. .	20	-0.017	-0.010	12.983	0.878
. * .	. .	21	0.120	0.041	14.359	0.854
. * .	. * .	22	-0.125	-0.114	15.879	0.822
. * .	. * .	23	0.068	0.085	16.342	0.840
. .	. .	24	-0.054	-0.033	16.640	0.864
. .	. * .	25	-0.048	-0.136	16.882	0.886

Klasse 2: B & B Hamburg

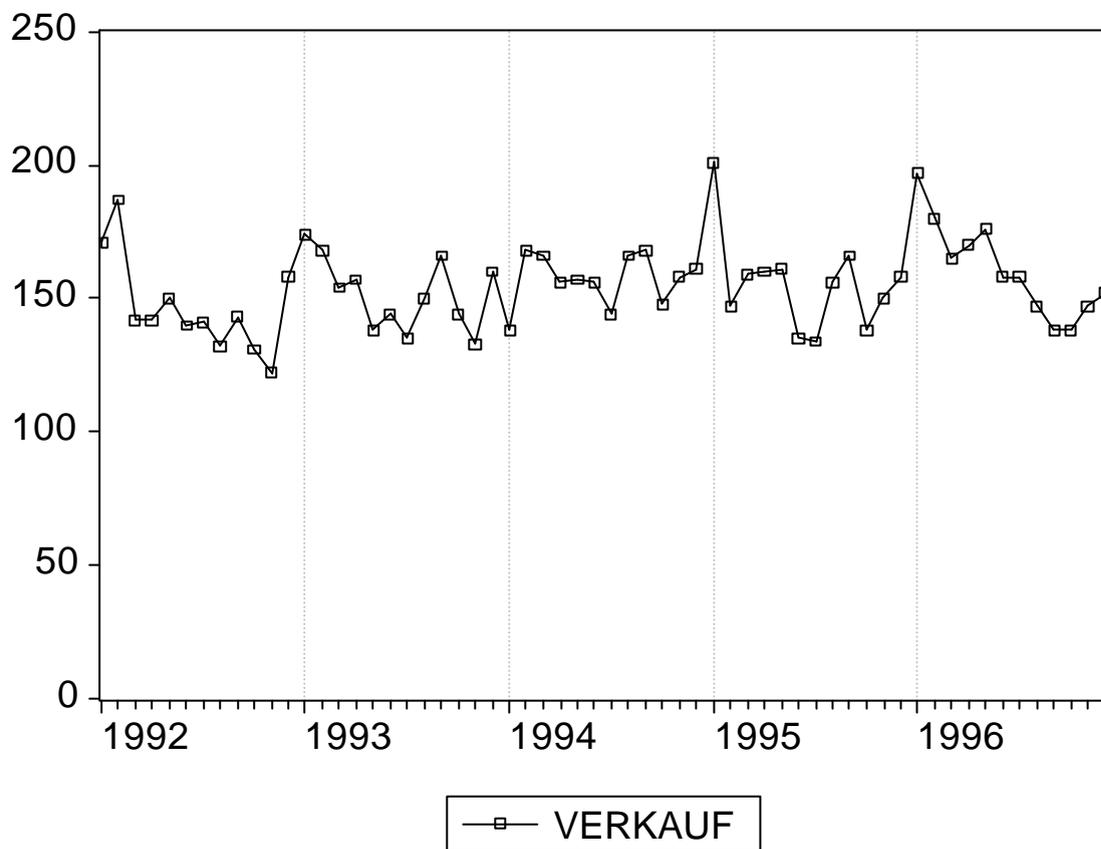
Klasse 2: B & B Hamburg

Date: 10/25/99 Time: 18:47

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. *.	. *.	1	0.186	0.186	2.1757	0.140
. **	. **	2	0.287	0.261	7.4436	0.024
. .	. *.	3	-0.011	-0.109	7.4508	0.059
. *.	. .	4	0.102	0.050	8.1373	0.087
. .	. *.	5	0.065	0.084	8.4193	0.135
. .	. *.	6	0.005	-0.069	8.4210	0.209
. *.	. *.	7	0.120	0.117	9.4341	0.223
. *.	. *.	8	-0.059	-0.086	9.6811	0.288
. *.	. .	9	0.104	0.061	10.466	0.314
. .	. .	10	-0.011	0.025	10.476	0.400
. *.	. *.	11	0.158	0.101	12.376	0.336
. *.	. *.	12	0.174	0.167	14.734	0.256
. .	. *.	13	0.018	-0.126	14.761	0.323
. .	. *.	14	-0.006	-0.091	14.764	0.394
. .	. .	15	-0.037	0.047	14.880	0.460
. *.	. *.	16	0.102	0.076	15.766	0.469
. *.	. *.	17	-0.078	-0.116	16.293	0.503
. .	. .	18	-0.012	-0.057	16.305	0.571
. .	. .	19	-0.036	0.040	16.424	0.629
. *.	. *.	20	-0.147	-0.172	18.428	0.559
. *.	. *.	21	-0.103	-0.081	19.440	0.557
. *.	. .	22	-0.090	0.048	20.232	0.569
. *.	. *.	23	0.151	0.165	22.532	0.488
. *.	. *.	24	-0.100	-0.174	23.564	0.487
. .	. *.	25	-0.055	-0.113	23.885	0.526

Klasse 3: Wehling Paderborn

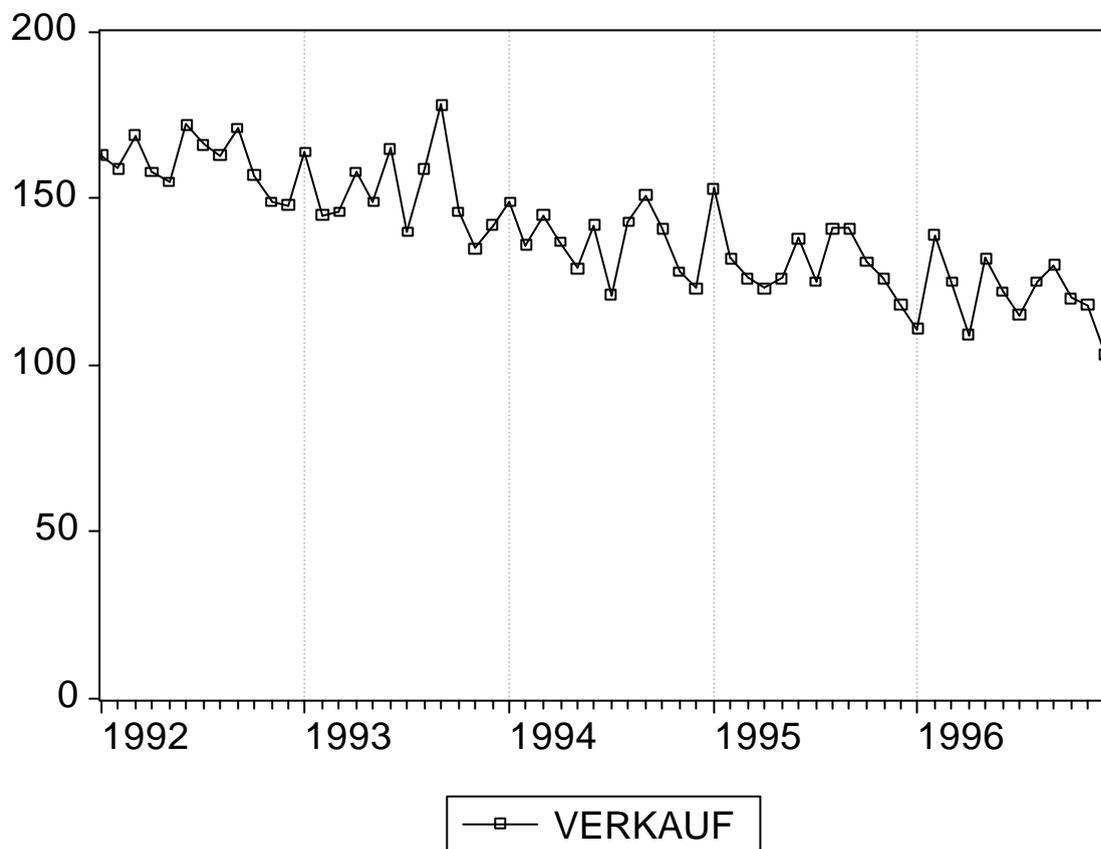
Klasse 3: Wehling Paderborn

Date: 10/25/99 Time: 20:40

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
. ***	. ***	1	0.351 0.351	7.7469	0.005
. *	. .	2	0.088 -0.039	8.2463	0.016
. .	. .	3	0.058 0.046	8.4690	0.037
. *	. *	4	0.101 0.079	9.1523	0.057
. * .	. * .	5	-0.080 -0.164	9.5800	0.088
** .	. * .	6	-0.222 -0.169	12.976	0.043
** .	. * .	7	-0.194 -0.072	15.607	0.029
. .	. *	8	-0.026 0.078	15.655	0.048
** .	** .	9	-0.210 -0.234	18.878	0.026
. * .	. .	10	-0.164 0.016	20.875	0.022
. *	. **	11	0.098 0.203	21.601	0.028
. **	. *	12	0.266 0.152	27.076	0.008
. *	. .	13	0.189 0.063	29.909	0.005
. *	. .	14	0.079 -0.026	30.409	0.007
. .	. * .	15	0.057 -0.083	30.674	0.010
. *	. * .	16	0.080 -0.058	31.211	0.013
. .	. .	17	-0.014 0.015	31.228	0.019
. * .	. .	18	-0.107 -0.035	32.243	0.021
. .	. *	19	0.012 0.125	32.256	0.029
. .	. .	20	-0.035 -0.019	32.368	0.040
. * .	. .	21	-0.099 0.017	33.298	0.043
. * .	. .	22	-0.094 0.016	34.165	0.047
. *	. *	23	0.080 0.094	34.802	0.054
. *	. * .	24	0.071 -0.097	35.316	0.064
. .	. * .	25	0.016 -0.062	35.342	0.082

Klasse 4: Schmidt & Hampe Hannover

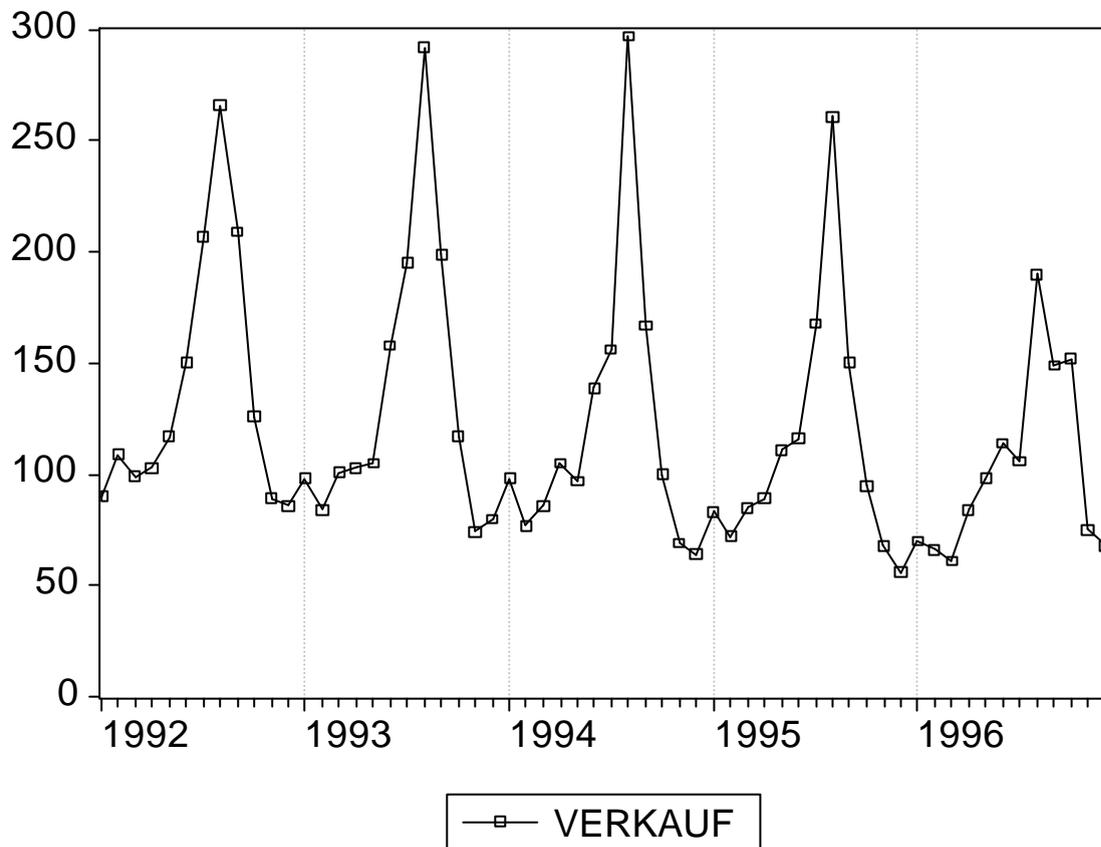
Klasse 4: Schmidt & Hampe Hannover

Date: 10/25/99 Time: 20:47

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. *****	. *****	1	0.644	0.644	26.155	0.000
. *****	. **	2	0.553	0.236	45.762	0.000
. *****	. ***	3	0.613	0.342	70.284	0.000
. *****	. *	4	0.564	0.111	91.403	0.000
. *****	. *	5	0.561	0.162	112.68	0.000
. ***	. *	6	0.451	-0.134	126.70	0.000
. ***	. *	7	0.457	0.068	141.35	0.000
. ***	. .	8	0.440	-0.041	155.20	0.000
. ***	. .	9	0.378	-0.012	165.63	0.000
. **	. **	10	0.277	-0.208	171.33	0.000
. ***	. *	11	0.338	0.175	180.00	0.000
. ***	. **	12	0.423	0.197	193.86	0.000
. **	. *	13	0.266	-0.116	199.48	0.000
. **	. *	14	0.203	-0.131	202.81	0.000
. *	. *	15	0.164	-0.166	205.04	0.000
. *	. .	16	0.186	0.014	207.98	0.000
. **	. *	17	0.209	0.098	211.76	0.000
. *	. *	18	0.084	-0.068	212.39	0.000
. *	. .	19	0.096	0.002	213.23	0.000
. *	. *	20	0.082	-0.076	213.85	0.000
. .	. .	21	0.011	-0.049	213.86	0.000
. *	. **	22	-0.109	-0.234	215.03	0.000
. *	. .	23	-0.069	0.020	215.52	0.000
. .	. *	24	0.031	0.145	215.62	0.000
. *	. .	25	-0.087	-0.008	216.43	0.000

Klasse 5: SWV Friedrichshafen

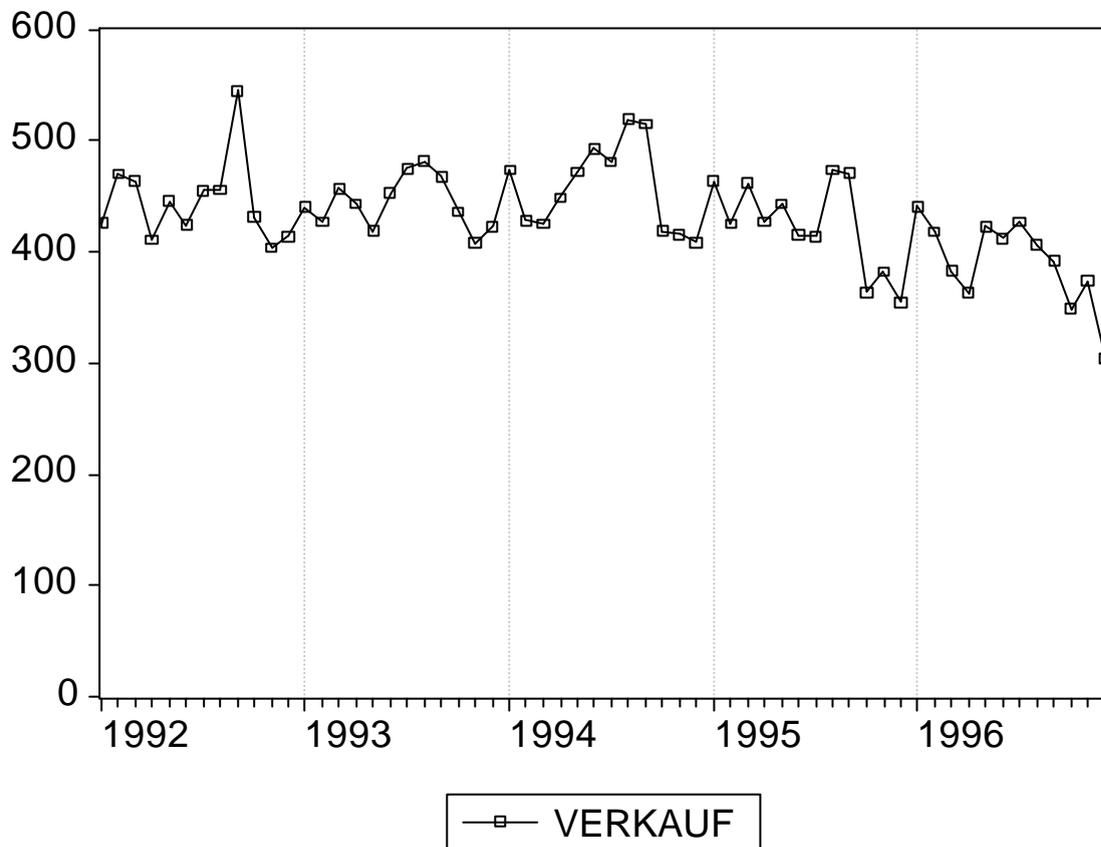
Klasse 5: SWV Friedrichshafen

Date: 10/25/99 Time: 20:53

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. *****	. *****	1	0.627	0.627	24.766	0.000
. **	** .	2	0.203	-0.312	27.411	0.000
. * .	** .	3	-0.157	-0.234	29.025	0.000
** .	. .	4	-0.312	-0.044	35.491	0.000
*** .	. * .	5	-0.359	-0.154	44.202	0.000
*** .	** .	6	-0.412	-0.299	55.921	0.000
*** .	. * .	7	-0.352	-0.064	64.635	0.000
** .	** .	8	-0.278	-0.213	70.175	0.000
. * .	. * .	9	-0.122	-0.103	71.269	0.000
. * .	. * .	10	0.144	0.169	72.820	0.000
. ****	. ***	11	0.494	0.368	91.319	0.000
. *****	. ****	12	0.779	0.479	138.30	0.000
. ****	*** .	13	0.511	-0.409	158.97	0.000
. * .	. * .	14	0.165	0.090	161.18	0.000
. * .	. .	15	-0.165	0.057	163.44	0.000
** .	. * .	16	-0.302	-0.069	171.16	0.000
** .	. * .	17	-0.309	0.123	179.40	0.000
*** .	. * .	18	-0.330	0.066	189.05	0.000
** .	. * .	19	-0.279	-0.066	196.12	0.000
** .	. .	20	-0.209	0.045	200.20	0.000
. * .	. * .	21	-0.098	-0.063	201.11	0.000
. * .	. * .	22	0.086	-0.059	201.84	0.000
. **	. * .	23	0.326	-0.144	212.50	0.000
. ****	. * .	24	0.524	-0.063	240.90	0.000
. ***	. .	25	0.348	-0.023	253.80	0.000

Klasse 6: Brümmer Weiterstadt

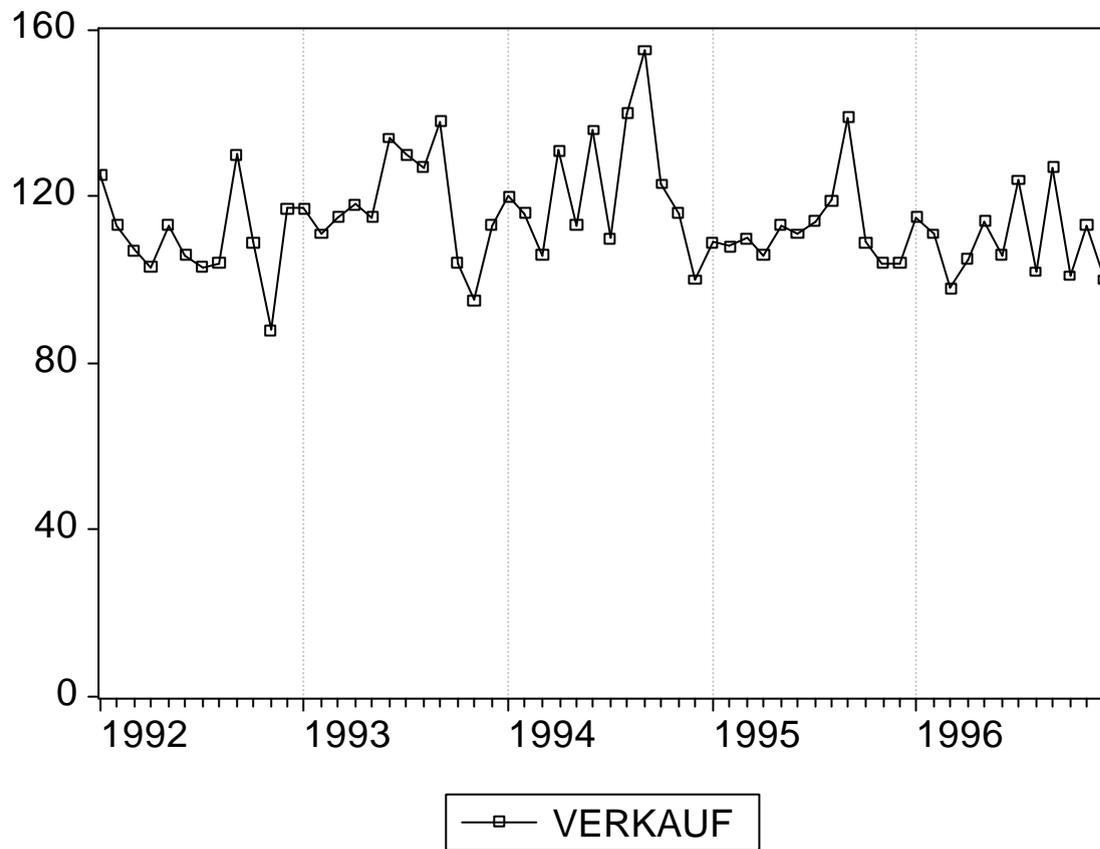
Klasse 6: Brümmer Weiterstadt

Date: 10/25/99 Time: 21:05

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
. ****	. ****	1	0.462	0.462	13.467	0.000
. **	. .	2	0.258	0.056	17.727	0.000
. *	. *	3	0.084	-0.070	18.183	0.000
. **	. **	4	0.204	0.227	20.937	0.000
. *	. .	5	0.171	0.016	22.914	0.000
. **	. *	6	0.252	0.149	27.275	0.000
. *	. .	7	0.148	-0.021	28.805	0.000
. *	. .	8	0.144	0.032	30.285	0.000
. *	. .	9	0.074	-0.006	30.682	0.000
. *	. *	10	0.173	0.108	32.903	0.000
. **	. *	11	0.234	0.139	37.064	0.000
. ***	. **	12	0.403	0.254	49.661	0.000
. *	** .	13	0.141	-0.219	51.228	0.000
. .	. *	14	-0.007	-0.140	51.232	0.000
* .	. *	15	-0.179	-0.188	53.870	0.000
. .	. .	16	-0.056	-0.042	54.133	0.000
. .	. .	17	-0.019	-0.003	54.162	0.000
* .	** .	18	-0.076	-0.243	54.668	0.000
* .	. .	19	-0.124	0.005	56.060	0.000
* .	. .	20	-0.067	0.045	56.476	0.000
* .	. *	21	-0.144	-0.141	58.441	0.000
. .	. *	22	-0.032	0.105	58.539	0.000
. .	. *	23	0.044	0.074	58.735	0.000
. *	. *	24	0.133	0.081	60.575	0.000
. .	. .	25	-0.049	-0.002	60.826	0.000

Klasse 7: Schmidt Pforzheim

Klasse 7: Schmidt Pforzheim

Date: 10/25/99 Time: 21:10

Sample: 1992:01 1996:12

Included observations: 60

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
. **	. **	1	0.215 0.215	2.9078	0.088
. *	. *	2	0.115 0.073	3.7609	0.153
. .	. .	3	0.008 -0.032	3.7652	0.288
. *	. *	4	0.094 0.095	4.3490	0.361
. .	. * .	5	-0.053 -0.093	4.5388	0.475
. * .	. * .	6	-0.165 -0.164	6.4085	0.379
. * .	. .	7	-0.094 -0.013	7.0331	0.425
. .	. .	8	-0.041 -0.001	7.1531	0.520
. .	. .	9	-0.038 -0.017	7.2577	0.610
. * .	. * .	10	-0.139 -0.108	8.7052	0.560
. *	. *	11	0.068 0.125	9.0547	0.617
. ***	. ***	12	0.405 0.412	21.777	0.040
. *	. * .	13	0.113 -0.094	22.793	0.044
. .	. * .	14	0.014 -0.097	22.808	0.063
. .	. .	15	0.028 0.042	22.874	0.087
. .	. * .	16	0.035 -0.098	22.977	0.114
. .	. .	17	-0.055 -0.043	23.241	0.142
. * .	. .	18	-0.178 -0.057	26.038	0.099
. * .	. .	19	-0.135 -0.054	27.687	0.090
. .	. *	20	0.016 0.118	27.711	0.116
. * .	. * .	21	-0.162 -0.185	30.204	0.088
** .	. * .	22	-0.275 -0.162	37.583	0.020
. * .	. .	23	-0.074 0.036	38.137	0.025
. *	. * .	24	0.098 -0.104	39.120	0.027
. .	. .	25	0.032 0.026	39.229	0.035

Anhang 2

Durbin-Watson-Test: Kritische Grenzen (5% Signifikanzniveau)

(Quelle: Judge / Hill / Griffiths / Lütkepohl / Lee 1988, S. 991-994)

N	K=2				K=3				K=4			
	d* _{UL}	d* _{UR}	D* _{OL}	d* _{OR}	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}
36	1,411	1,525	2,475	2,589	1,354	1,587	2,413	2,646	1,295	1,654	2,346	2,705
45	1,475	1,566	2,434	2,525	1,430	1,615	2,385	2,570	1,383	1,666	2,334	2,617
50	1,503	1,585	2,415	2,497	1,462	1,628	2,372	2,538	1,421	1,674	2,326	2,579
60	1,549	1,616	2,384	2,451	1,514	1,652	2,348	2,486	1,480	1,689	2,311	2,520

N	K=5				K=6				K=7			
	d* _{UL}	d* _{UR}	D* _{OL}	d* _{OR}	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}
36	1,236	1,724	2,276	2,764	1,175	1,799	2,201	2,825	1,114	1,877	2,123	2,886
45	1,336	1,720	2,280	2,664	1,287	1,776	2,224	2,713	1,238	1,835	2,165	2,762
50	1,378	1,721	2,279	2,622	1,335	1,771	2,229	2,665	1,291	1,822	2,178	2,709
60	1,444	1,727	2,273	2,556	1,408	1,767	2,233	2,592	1,372	1,808	2,192	2,628

N	K=12				K=13				K=14			
	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}	d* _{UL}	d* _{UR}	d* _{OL}	d* _{OR}
36	0,808	2,306	1,694	3,192	0,748	2,398	1,602	3,252	0,689	2,492	1,508	3,311
45	0,988	2,156	1,844	3,012	0,938	2,225	1,775	3,062	0,887	2,296	1,704	3,113
50	1,064	2,103	1,897	2,936	1,019	2,163	1,837	2,981	0,973	2,225	1,775	3,027
60	1,184	2,031	1,969	2,816	1,145	2,079	1,921	2,855	1,106	2,127	1,873	2,894

N: Anzahl der Beobachtungswerte K: Anzahl der Regressoren, einschließlich des konstanten Terms

Literatur

Abraham, B., J.Ledolter (1983), *Statistical Methods for Forecasting*, New York.

Bamberg, G., F.Baur (1998), *Statistik*, 10. Aufl., München/Wien.

Bartels, R. (1982), The Rank Version of Von Neumann's Ratio Test for Randomness, *Journal of the American Statistical Association*, 77, 40-46.

Beaulieu, J.J., J.A.Miron (1993), Seasonal Unit Roots in Aggregate U.S. Data, *Journal of Econometrics*, 55, 305-328, North-Holland.

Box, G.E.P., G.M.Jenkins (1970), *Time Series Analysis: Forecasting and Control*, San Francisco.

Brummund, P. (1985), *Struktur und Organisation des Pressevertriebs, Teil 1: Der deutsche Zeitungs- und Zeitschriftengroßhandel*, München/New York/London/Paris.

Charemza, W.W., D.F.Deadman (1993), *New Directions in Econometric Practice*, Aldershot/Brookfield.

Chatfield, C., D.L.Prothero (1973), A Reply to some Comments by Box and Jenkins, *Journal of Royal Statistical Society, A*, 136, 345-352.

Chatfield, C. (1985), *The Analysis of Time Series: An Introduction*, Third Edition, London/New York.

Chow, G.C. (1960), Tests of Equality between Sets of Coefficients in two linear Regressions, *Econometrica*, 28, 591-605.

Cleveland, W.P., G.C.Tiao (1976), Decomposition of Seasonal Time Series: A Model for the Census X-11 Program, *Journal of the American Statistical Association*, 71, 581-587.

Cromwell, J.B., W.C.Labys, M.Terraza (1994), *Univariate Tests for Time Series Models*, Thousand Oaks/London/New Delhi.

Deutsche Bundesbank (1970), Saisonbereinigung mit dem Census-Verfahren, *Monatsberichte der Deutschen Bundesbank März 1970*, Frankfurt, 38-43.

Deutsche Bundesbank (1987), Die Saisonbereinigung als Hilfsmittel der Wirtschaftsbeobachtung, *Monatsberichte der Deutschen Bundesbank Oktober 1987*, Frankfurt, 30-40.

- Dickey, D.A., W.A.Fuller (1979), Distribution of the Estimators for Autoregressive Time Series with a Unit Root, *Journal of the American Statistical Association*, 74, 427-431.
- Dickey, D.A., D.P.Hasza, W.A.Fuller (1984), Testing for Unit Roots in Seasonal Time Series, *Journal of the American Statistical Association*, 79, 355-367.
- Fieger, A., H.Toutenburg (1995), *SPSS Trends für Windows*, New York/London/Toronto/Sydney/Tokio/Singapur/München.
- Franses, P.H. (1990), Testing for Seasonal Unit Roots in Monthly Data, *Econometric Institute Report*, 9032/A, Erasmus University Rotterdam.
- Franses, P.H. (1991), Seasonality, Non-Stationarity and the Forecasting of Monthly Time Series, *International Journal of Forecasting*, 199-208, North-Holland.
- Franses, P.H., A.B.Koehler (1994), Model Selection Strategies for Time Series with Increasing Seasonal Variation, *Econometric Institute Report*, Erasmus University Rotterdam.
- Franses, P.H. (1996), *Periodicity and Stochastic Trends In Economic Time Series*, Oxford/ New York.
- Fürstner, W. (1985), Verband Deutscher Zeitschriftenverleger, in: Fischer,H.D., *Publikumszeitschriften in der Bundesrepublik Deutschland*, 134-151, Konstanz.
- Granger, C.W.J., P.Newbold (1986), *Forecasting Economic Time Series*, Orlando/London.
- Greitenevert, M., I.Kelemen-Rehm (1992), Verkaufsspezifische Strukturen von Special Interest Zeitschriften - Eine statistische Analyse der GROSSO-Gebiete, Diplomarbeit an der Universität-Gesamthochschule Paderborn.
- Hall, E.R., D.M.Lilien, G.Sueyoshi, R.Engle, J.Johnston, S.Ellsworth (1995), *EViews User Guide*, Version 2.0, Irvine.
- Hamilton, J.D. (1994), *Time Series Analysis*, Princeton/Chichester.
- Hannan, E.J. (1980), The Estimation of the Order of an ARMA Process, *American Statistician*, 8, 1071-1081.

- Harvey, A.C., I.D.McAvinchey (1978), The Small Sample Efficiency of Two-Step Estimators in Regression Models with Autoregressive Disturbances, 78-10, Discussion Paper, University of British Columbia.
- Harvey, A.C., G.Untiedt (1994), *Ökonometrische Analyse von Zeitreihen*, 2. Aufl., München/Wien/Oldenburg.
- Hillinger, C., M.Reiter, U.Woitek (1992), Model-Independent Detrending for Determining the Cyclical Properties of Macroeconomic Time Series, *Münchener Wirtschaftswissenschaftliche Beiträge*, München.
- Hübler, O. (1989), *Ökonometrie*, Stuttgart/New York.
- Hylleberg, S. (1986), *Seasonality in Regression*, Orlando/London.
- Hylleberg, S., R.F.Engle, C.W.J.Granger, B.S.Yoo (1990), Seasonal Integration and Cointegration, *Journal of Econometrics*, 44, 215-238, North-Holland.
- Hylleberg, S. (1992), *Modelling Seasonality*, Oxford.
- Ipsen, H.P. (1980), *Presse-Grosso im Verfassungsrahmen*, Berliner Abhandlungen zum Presserecht, Berlin.
- Johnston, J. (1987), *Econometric Methods*, Third Edition, Singapore.
- Judge, G.G., R.C.Hill, W.E.Griffiths, H.Lütkepohl, T.C.Lee (1988), *Introduction to the Theory and Practice of Econometrics*, New York.
- Kaiser, J.H. (1979), *Das Recht des Presse-Grosso*, 1. Aufl., Baden-Baden.
- Kanji, G.K. (1993), *100 Statistical Tests*, London/Newbury Park/New Delhi.
- Kendall, M.G. (1976), *Time-Series*, 2nd Edition, London.
- Kendall, M.G., A.Stuart (1979), *The Advanced Theory of Statistics*, Volume 2, Fourth Edition, London.
- Kenny, P.B., J.Durbin (1982), Local Trend Estimation and Seasonal Adjustment of Economic and Social Time Series (with Discussion), *Journal of the Royal Statistical Society A*, 145, 1-41.

- Kraft, M., T.Landes (1996) *Statistische Methoden*, 3. Aufl., Heidelberg.
- Kraft, M. (1997), *Neuere ökonometrische Methoden zur empirischen Überprüfung eines synergetischen Konjunkturmodells*, Marburg.
- Lewandowski, R. (1974), *Prognose- und Informationssysteme und ihre Anwendung*, Band 1, Berlin.
- Ljung, G.M., G.E.P.Box (1978), On a Measure of lack of Fit in Time Series Models, *Biometrika*, 65, 297-303.
- Lüüs, H.-P. (1993), Vergleich der Analyseergebnisse des Berliner Verfahrens (BV4) und des Bundesbankverfahrens, die monatlich für die aktuelle Konjunkturbeobachtung bereitgestellt werden, Statistisches Bundesamt, Wiesbaden.
- MacKinnon, J.G. (1990), Critical Values for Co-Integration Tests, Working Paper, University of California, San Diego.
- Makridakis, S., H.Reschke, S.C.Wheelwright (1980), *Prognosetechniken für Manager*, Wiesbaden.
- Mertens, P. (1994), *Prognoserechnung*, 5. Aufl., Heidelberg.
- Mills, T.C. (1990), *Time Series Techniques for Economists*, Cambridge/Melbourne.
- Neftci, S.N. (1984), Are Economic Time Series Asymmetric over the Business Cycle?, *Journal of Political Economy*, 92, 307-328.
- Nelson, C.R. (1973), *Applied Time Series Analysis for Managerial Forecasting*, San Francisco.
- Osborn, D.R., A.P.L.Chui, J.P.Smith, C.R.Birchenhall (1988), Seasonality and the Order of Integration for Consumption, *Oxford Bulletin of Economics and Statistics*, 50, 4, 361-377.
- Osborn, D.R. (1990), A Survey of Seasonality in UK Macroeconomic Variables, *International Journal of Forecasting*, 6, 327-336, North-Holland.
- Pearson, E.S., H.O.Hartley (1970), *Biometrika Tables for Statisticians*, Volume 1, Third Edition, Cambridge/London.

- Pflaumer, P. (1981), Prognoseverfahren für die Unternehmensplanung: Box-Jenkins-Ansatz, Prognose/Unternehmensleitung zfbf, 33, 156-164.
- Pierce, D.A. (1980), A Survey of Recent Developments in Seasonal Adjustment, American Statistician, 34, 125-134.
- Poskitt, D.S., A.R.Tremayne (1987), Determining a Portfolio of Linear Time Series Models, Biometrika, 74, 125-137.
- Presse-Grosso (1999), Homepage, Presse-Grosso in Zahlen.
- Ramsey, J.B. (1969), Tests for Specification Errors in Classical Linear Least Squares Regression Analysis, Journal of the Royal Statistical Society, B, 31, 350-371.
- Ramsey, J.B., Alexander (1984), The Econometric Approach to Business-Cycle Analysis Reconsidered, Journal of Macroeconomics, 6, 347-356.
- Rudolph, A. (1998), Prognoseverfahren in der Praxis, Heidelberg.
- Saurwein, K.H., T.Hönekopp (1992), SPSS/PC+ 4.0, Eine anwendungsorientierte Einführung zur professionellen Datenanalyse, 2. Aufl., Bonn/München.
- Schäffer, K.A. (1991), Methoden zur Zerlegung von Zeitreihen, Allgemeines Statistisches Archiv, 75, 24-36.
- Schäffer, K.A. (1997), Einführung in die Analyse saisonaler Zeitreihen, aus Analyse saisonaler Zeitreihen, Hrsg. K.Edel, K.A.Schäffer, W.Stier, Heidelberg.
- Schlittgen, R., B.H.J.Streitberg (1989), Zeitreihenanalyse, 3. Aufl., München/Wien/ Oldenbourg.
- Schmitz, B. (1989), Einführung in die Zeitreihenanalyse: Modelle, Softwarebeschreibung, Anwendungen, 1. Aufl., Bern/Stuttgart/Toronto.
- Shiskin, J., A.H.Young, J.C.Musgrave (1965), The X-11 Variant of the Census Method II Seasonal Adjustment Program. Technical Paper 15, Bureau of the Census, U.S. Department of Commerce, Washington D.C..
- Shiskin, J., T.J.Plewes (1978), Seasonal Adjustment of the U.S. Unemployment Rate, The Statistician, 27.

Steinmetz, U. (1997), MBR: Der Weg in die Zukunft, aus: VDZ, Die Publikumszeitschriften, Die Zeitschriften '97, Themen, Thesen, Standpunkte, 35-36.

Stier, W. (1980), Verfahren zur Analyse saisonaler Schwankungen in ökonomischen Zeitreihen, Berlin/Heidelberg/New York.

Tetley, H. (1946), Actuarial Statistics, Volume 1, Cambridge.

Verband Deutscher Zeitschriftenverleger e.V. (VDZ) (1981), Marktorientierte Bezugsregulierung MBR Broschüre zum Seminar 1981.

Verband Deutscher Zeitschriftenverleger e.V. (VDZ) (1996), Mini-Ehastra 1996, Bericht über die Geschäftsartenstruktur des Presse-Einzelhandels Deutschland 1996.

Verband Deutscher Zeitschriftenverleger e.V. (VDZ) (1996), Zeitschriftenpresse in Zahlen.

Verband Deutscher Zeitschriftenverleger e.V. (VDZ), Presse-Grosso, Bundesverband Deutscher Zeitungsverleger e.V. (BDZV) (1993), Koordiniertes Vertriebsmarketing, Gemeinsamer Leistungsrahmen für Grosso und Verlage.

Wei, W.W.S. (1990), Time Series Analysis: Univariate and Multivariate Methods, Redwood City, 67-69.

Weise, P., W.Brandes, T.Eger, M.Kraft (1991), Neue Mikroökonomie, 2. Aufl., Heidelberg.

Wold, S. (1974), Spline functions in data analysis, Technometrics, 16, 1-11.