

**TECHNISCHE
UNIVERSITÄT
DRESDEN**

Fakultät Verkehrswissenschaften „Friedrich List“
Institut für Wirtschaft und Verkehr

Professur für Ökonometrie und Statistik, insb. im Verkehrswesen

Masterarbeit

Aktienkurse und Unternehmenszahlen – Eine ökonometrische Analyse des Wechselspiels am Beispiel der Automobilindustrie

eingereicht von:	Philipp Koltermann
Matrikel-Nr.:	3590297
Studiengang:	Verkehrswirtschaft Master
verantwortlicher Hochschullehrer:	Prof. Dr. rer. pol. Ostap Okhrin
betreut von:	Dr. rer. nat. Reik Donner

Dresden, den 7. September 2015

Abstract

Public traded companies are obliged to account for their operating numbers from time to time. These numbers are usually published in their interim and annual reports. Besides annual accounts and their balance sheet, the income statement provides great value for potential investors and shareholders. This master thesis wants to prove that announcements of operating numbers have verifiable influence on share prices.

Event studies are mainly used to determine abnormalities in return series. An event study focuses on the prediction of normal returns with the help of a certain market model and ascertains abnormal returns in a second step. The selection of a suitable market model is the essence of every event study. On the one hand, there are market models which use certain external factors in their regression equation, having influence on returns. On the other hand, a widely range of autoregressive models computes returns on the basis of their own precursors. Furthermore an extension to that is even able to detect and map volatility clustering in return series. Eventually the variety of different market models exhibits that return prediction can only be an approach to real observations.

Besides the study of abnormalities on a certain event day, it could be worthwhile to examine intervals in return series prior and afterwards an incident. Keynote of this analysis is that investors and shareholders could detect earnings surprises premature and also trade afterwards a publication on an extraordinary basis. The statistical question raised is whether there are coincidences between significantly more distinct trends in return series and the release of business reports. Furthermore, it is arguable whether these coincidences appear only on a random basis or not.

In addition to that, time series of capital market values succumb specific statistical characteristics. Properties like a leptokurtic distribution and weak stationarity constitute prerequisites to subsequent analysis. Additionally autocorrelation of returns is taken into particularly consideration. To sum up, it seems that capital markets provide a diversity of attributes to analyse. Taken all together, these procedures try to disprove capital market efficiency.

Inhaltsverzeichnis

Abbildungsverzeichnis	III
Tabellenverzeichnis	IV
Abkürzungsverzeichnis	V
Symbolverzeichnis	VI
1 Einleitung	1
2 Theoretische Grundlagen	3
2.1 Bilanzanalyse	3
2.1.1 Rechte und Pflichten	3
2.1.2 Kennzahlen	4
2.2 Analyse des Kapitalmarktes	5
2.2.1 Aktienanalyse und Markteffizienzhypothese	5
2.2.2 Ereignisstudie	7
2.3 Annahmen	9
2.3.1 Datengrundlage	9
2.3.2 Thesenbildung	11
3 Grundlagen zur statistischen Auswertung	12
3.1 Renditeberechnung und –bereinigung	12
3.1.1 Stetige und diskrete Rendite	12
3.1.2 Marktbereinigte Renditen	13
3.1.3 Zeitpunktspezifischer t–Test	16
3.2 Definitionen	16
3.2.1 Stationarität, Leptokurtosis und Normalverteilung	17
3.2.2 Autokorrelation und Autokovarianz	18
3.2.3 White Noise, Random Walk und Lag–Operator	19
3.3 Linear stochastische Prozesse	20
3.3.1 Autoregressive Prozesse	21
3.3.2 Moving–Average–Prozesse	22
3.3.3 Autoregressive–Moving–Average–Prozesse	24
3.4 Modelle zum Volatilitätsclustering	25
3.4.1 ARCH–Modelle	25
3.4.2 GARCH–Modelle	27
3.4.3 Weiterführende Modelle	28
3.5 Berechnung erwarteter Gewinn	29
3.5.1 Hauptkomponentenanalyse	30
3.5.2 Saisonale Regression	31

3.5.3	Gewinnerwartung	33
3.6	Verfahren zu These 2 und 3	33
3.6.1	Koinzidenzanalyse	33
3.6.2	Bootstrapping	35
3.6.3	Monte-Carlo-Simulation	36
4	Literaturübersicht	37
4.1	Bisherige Studien über Gewinneinfluss	37
4.2	Studien mit Bezug auf ARCH-Modelle	38
4.3	Zusammenfassung	39
5	Ergebnisauswertung	40
5.1	Nachweis statistischer Eigenschaften	40
5.1.1	Stationarität, Leptokurtosis und Autokorrelation	40
5.1.2	Interpretation von Volatilität mittels GARCH-Prozess	44
5.1.3	Kritische Würdigung	47
5.2	Einfluss des Gewinns	47
5.2.1	Vorgehen	47
5.2.2	Ergebnisse	50
5.2.3	Kritische Würdigung	53
5.3	Ergebnisse der Koinzidenzanalyse	53
5.3.1	Vorgehen	53
5.3.2	Ergebnisse	56
5.3.3	Kritische Würdigung	58
6	Fazit	59
	Literaturverzeichnis	IX
	Anhang	XV

Abbildungsverzeichnis

1	Ausschnitt des Aktienkursverlaufs der Continental AG	8
2	Simulierter Verlauf eines Random Walk und White Noise Prozesses .	20
3	ACF eines AR(1)–Prozesses	22
4	ACF eines MA(1)–Prozesses	23
5	Stilisierter Aufbau einer Koinzidenzanalyse	34
6	Vergleich der Kerndichteschätzung	42
7	Q–Q–Plots der Rendite–Zeitreihen	43
8	Hauptkomponentenabalyse Volkswagen AG	49
9	Regressionsanalyse BMW AG und Daimler AG	50
10	Aktienkurs DAXSector Auto (P)	54
11	Koinzidenzen der Simulation	55
12	Koinzidenzanalyse der Volkswagen AG	57
13	Aktienkurs Daimler AG	XV
14	Aktienkurs Leoni AG	XV
15	Aktienkurs Volkswagen AG	XVI
16	Aktienkurs Continental AG	XVI
17	Aktienkurs BMW AG	XVII
18	Aktienkurs Bertrandt AG	XVII
19	Aktienkurs Grammer AG	XVIII
20	Aktienkurs ElrinKlinger AG	XVIII
21	Aktienkurs PWO AG	XIX
22	Kerndichteschätzungen der restlichen Unternehmen	XX
23	Q–Q–Plots der restlichen Unternehmen	XXI
24	PCA Daimler AG	XXII
25	PCA Continental AG	XXII
26	PCA BMW AG	XXII
27	PCA Leoni AG	XXII
28	PCA Bertrandt AG	XXIII
29	PCA Grammer AG	XXIII
30	PCA ElringKlinger AG	XXIII
31	PCA PWO AG	XXIII
32	Hauptkomponentenwerte der restlichen Unternehmen	XXIV
33	Koinzidenzanalyse der Daimler AG	XXVI
34	Koinzidenzanalyse der Continental AG	XXVI
35	Koinzidenzanalyse der BMW AG	XXVII
36	Koinzidenzanalyse der Leoni AG	XXVII
37	Koinzidenzanalyse der Bertrandt AG	XXVIII
38	Koinzidenzanalyse der Grammer AG	XXVIII
39	Koinzidenzanalyse der ElrinKlinger AG	XXIX
40	Koinzidenzanalyse der PWO AG	XXIX

Tabellenverzeichnis

1	Übersicht der zu betrachtenden Unternehmen	10
2	Übersicht der Stichprobenbereinigung	10
3	Übersicht der bisherigen Literatur	39
4	Ergebnisse des ADF-Tests	40
5	Statistische Eigenschaften der Rendite-Zeitreihen	41
6	Geschätzte Autokorrelationswerte erster Ordnung	44
7	Ergebnisse Ljung-Box-Statistik	44
8	Ergebnisse LM-Test	45
9	Parameter der GARCH(1,1)-Modellierung	46
10	Ergebnisse Volatilitätsprognose	46
11	Eigenvektoren der Kennzahlen der Volkswagen AG	48
12	Übersicht der abnormalen Renditen am Ereignistag	51
13	Übersicht der abnormalen Renditen rund um Ereignistag	52
14	Ergebnisse der Koinzidenzanalyse der Volkswagen AG	56
15	Ergebnisse der Koinzidenzanalyse Daimler AG	XXX
16	Ergebnisse der Koinzidenzanalyse Continental AG	XXXI
17	Ergebnisse der Koinzidenzanalyse BMW AG	XXXII
18	Ergebnisse der Koinzidenzanalyse Leoni AG	XXXIII
19	Ergebnisse der Koinzidenzanalyse Bertrandt AG	XXXIV
20	Ergebnisse der Koinzidenzanalyse Grammer AG	XXXV
21	Ergebnisse der Koinzidenzanalyse der ElrinKlinger AG	XXXVI
22	Ergebnisse der Koinzidenzanalyse der PWO AG	XXXVII

Abkürzungsverzeichnis

ACF	Autocorrelation Function
ADF	Augmented Dickey–Fuller
AR	Autoregressive
ARCH	Autoregressive Conditional Heteroscedasticity
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
ASE	American Stock Exchange)
BörsG	Börsengesetz
BörsO	Börsenordnung der Frankfurter Wertpapierbörse
BörsZulV	Börsenzulassungs–Verordnung
CAPM	Capital Asset Pricing Model
DAX	Deutscher Aktienindex
DGAP	Deutsche Gesellschaft für Ad–hoc–Publizität
EBIT	Earnings Before Interest and Taxes
EBT	Earnings Before Taxes
EGARCH	Exponential Generalized Autoregressive Conditional Heteroscedasticity
GARCH	Generalized Autoregressive Conditional Heteroscedasticity
GARCH-M	Generalized Autoregressive Conditional Heteroscedasticity in-the-Mean
HGB	Handelsgesetzbuch
HML	High–Minus–Low
IASB	International Accounting Standards Board
IFRS	International Financial Reporting Standards
ISIN	International Securities Identification Number
JB	Jarque–Bera–Statistik
LM	Lagrange–Multiplikator–Test
MA	Moving Average
NYSE	New York Stock Exchange
PCA	Principal Component Analysis
Q–Q	Quantil–Quantil
RMRF	Überrendite des Marktes
SMB	Small–Minus–Big
SSR	Sum of Squared Residuals
ST	Stammaktie
TASE	Tel–Aviv Stock Exchange
VZ	Vorzugsaktie
WML	Winner–Minus–Loser
WpHG	Wertpapierhandelsgesetz

Symbolverzeichnis

Autoregressive Prozesse

α_i	Wichtung der stochastischen Prozesse autoregressiver Modelle aus Vorperioden
β_i	Wichtung der Störprozesse von Moving–Average–Modellen aus Vorperioden
$\gamma(t, \tau)$	Autokovarianzfunktion
ε_t	White Noise Prozess
λ_τ	Autokovarianz
μ	Erwartungswert eines stochastischen Prozesses
ρ_τ	Autokorrelationsfunktion
σ^2	unbedingte Varianz
σ_ε^2	Varianz des weißen Rauschen
$\sigma_{i,t}^2$	bedingte Varianz
$\bar{\sigma}_{t,p}^{GARCH}$	prognostizierte Volatilität
$\bar{\sigma}_{t,p}^*$	Vergleichswert zur Volatilität
τ	zeitliche Verschiebung
χ^2	Chi–Quadrat–Verteilung
ω	Konstante der ARCH–Modelle
c	Konstante
d	Häufigkeit der Differenzbildung
F	Teststatistik des LM–Tests
K	Anzahl Autokorrelationskoeffizienten
$\hat{K}$	Schätzer der Kurtosis
L	Lag–Operator
N	Normalverteilung
n	Stichprobenumfang
p	Ordnungsparameter autoregressiver Prozesse
Q	Ljung–Box–Teststatistik
q	Ordnungsparameter Moving–Average–Prozesse
$\bar{R}_{t,p}$	beobachtete Volatilität
$\hat{S}$	Schätzer der Schiefe
T	Anzahl der Beobachtungen
t	Zeitpunkt
$u_{i,t}$	Fehlerterm
X_t	stochastischer Prozess
x_t	Realisation eines stochastischen Prozesses

Renditeberechnung und -bereinigung

α_i	Marktrendite unabhängiger Bestandteil der Aktienrendite i
β_i	Einfluss der Abhängigkeit der Aktienrendite i von der Rendite des Marktindex
$\varepsilon_{i,t}$	Restterm der Regression
τ	zeitliches Intervall der Ereignisperiode
$aR_{i,t}$	abnormale Rendite der Aktie i zum Zeitpunkt t
$caR_{i,\tau}$	kumulierte abnormale Rendite der Aktie i zum Zeitintervall τ in der Ereignisperiode
h_i	Einfluss der Abhängigkeit des Value-Effekts HML
N	Stichprobenumfang
$P_{i,t}$	Aktienkurs i zum Zeitpunkt t
R_f	risikolose Anlage
$R_{i,t}$	Rendite der Aktie i zum Zeitpunkt t
$R_{m,t}$	Rendite des Marktindex zum Zeitpunkt t
s_i	Einfluss der Abhängigkeit des Size-Effekts SMB
T	Anzahl der Handelstage in der Schätzperiode
T_{ZS}	zeitpunktspezifischer t-Test

Berechnung erwarteter Gewinn

α	Niveauparameter der Regression
β	Trendparameter der Regression
$\delta_{i,k}$	Saisonfigur zum Quartal k
$\epsilon_{i,t}$	Ausrichtung der Gewinnerwartung einer Aktie i zum Zeitpunkt t
λ	theoretischer Eigenwert
Σ	theoretische Kovarianz-Matrix
$\mathbf{a}$	theoretische Eigenvektoren
$D_{k,t}$	Dummy-Variable zum Quartal k
$\mathbf{g}$	empirischer Eigenvektor
J	Anzahl Jahre
k	Quartalszugehörigkeit
l	empirischer Eigenwert
q_i	Dummy-Variable zum Strukturbruch
$\mathbf{S}$	empirische Kovarianz-Matrix
t'	Zeitpunkt des Strukturbruchs
$\mathbf{X}$	Vektor einer Zufallsvariablen
$y_{i,t}$	beobachteter Hauptkomponentenwert einer Aktie i zum Zeitpunkt t
$\hat{y}_{i,t}$	geschätzter Hauptkomponentenwert einer Aktie i zum Zeitpunkt t

Verfahren zu These 2 und 3

Θ	Heaviside Funktion
λ_A, λ_B	Ereignisrate der Reihe A bzw. B
F	Verteilungsfunktion
N_A, N_B	Anzahl Ereignisse der Reihe A bzw. B
R	Stichprobenverteilung
r_p	Vorläufer–Koinzidenzrate
r_t	Auslöser–Koinzidenzrate
t_i^A, t_i^B	Ereignis der Reihe A bzw. B
X	Zufallsvariable
x	Realisations der Zufallsvariable

1 Einleitung

„Volkswagen steigert Gewinn überraschend deutlich. [...] Die Volkswagen-Aktie verteuerte sich nach der Veröffentlichung der Quartalszahlen am Donnerstagmorgen zunächst um rund 3 Prozent“ [1]. Solche und ähnliche Nachrichten prägen das tägliche Börsengeschehen. Börsennotierte Unternehmen sind verpflichtet, in gewissen zeitlichen Abständen und bei speziellen Vorkommnissen, Rechenschaft über ihre Geschäftstätigkeit in Form von Berichten abzulegen. Die Veröffentlichung solcher Unternehmensmeldungen ist durch gewisse Rechte und Pflichten gesteuert. Sie enthalten Informationen unterschiedlichster Art, welche u. a. für Investoren von besonderer Bedeutung sind.

Diese Informationen werden von sogenannten Ereignisstudien aufgegriffen. Mit Hilfe verschiedener Marktmodelle werden dabei die vom Markteinfluss bereinigten Renditen rund um den Zeitpunkt der Veröffentlichung der Unternehmensmeldung betrachtet. Unter Renditen sind hier die ersten Differenzen der Aktienkurse zu verstehen. Aktien sind Anteilscheine; die Höhe ihres Preises bildet den Wert des dazugehörigen Unternehmens ab. Die Preisbestimmung erfolgt durch An- und Gebote seitens der Investoren. Wer Aktien kauft, investiert in ein Unternehmen und besitzt dadurch Anteile an diesem [2].

Im Laufe der Zeit wurden vor allem die Marktmodelle immer spezifischer, da sie weitere Faktoren in ihre Betrachtung einbezogen haben. Als Grundstein gilt das einfaktorielle Marktmodell, welches die Rendite einer Aktie von der Rendite des Marktindex abhängig macht [2]. Das Capital Asset Pricing Model von *Sharpe* (1964) und *Lintner* (1965) erweiterte dieses um einen Risikofaktor [3, 4]. *Fama/French* (1993) stellten als Erste mit ihrem Drei-Faktoren-Modell ein mehrfaktorielles Marktmodell auf [5]. Zu guter Letzt führte die Hinzunahme eines weiteren Faktors zum Vier-Faktoren-Modell von *Carhart* (1997) [6]. Erkenntnisse von *Engle* (1982) schufen die Modelle der ARCH-Prozesse, welche in der Lage sind, wiederkehrende Volatilitätscluster abzubilden [7]. Auch diese Prozesse unterlagen in den letzten Jahren zahlreicher Erweiterungen. So führte zunächst *Bollerslev* (1986) die GARCH-Prozesse ein, welche die ARCH-Modelle verallgemeinerten [8]. Darüber hinaus entwickelte *Nelson* (1991) das EGARCH-Modell, welches Volatilitätscluster asymmetrisch abbilden kann [9].

Diese Masterarbeit knüpft an dieser Stelle an, indem mit Hilfe der Erstellung einer Datenbank aus Kennzahlen und Aktienkursen deutscher Unternehmen der Automobilwirtschaft der wechselseitige Einfluss beider Größen analysiert wird. Durch unterschiedliche statistische Methoden konnte das Einwirken von Unternehmensberichten auf Aktienkurse zumin-

dest auf eine dem Veröffentlichungszeitpunkt nachgelagerte Periode nachgewiesen werden. Außerdem werden in einem vorherigen Schritt die statistischen Eigenschaften der Kapitalmarktzeitreihen, u. a. mit Hinblick auf die Untersuchung von Volatilitätsclustern, geprüft. Hauptaugenmerk liegt dabei auf dem Versuch der Beantwortung folgender Fragen: Können typische Eigenschaften von Kapitalmarktzeitreihen nachgewiesen werden? Beeinflussen Unternehmenszahlen den Aktienkursverlauf und falls ja, in positiver oder negativer Richtung und über welchem Zeitraum hinweg? Oder nehmen Aktienkurse die Unternehmenszahlen sogar vorweg?

Nach der Einleitung werden im zweiten Kapitel die theoretischen Grundlagen dieser Arbeit gelegt. Mit Hilfe der Bilanzanalyse erfolgt eine Auswahl an betriebswirtschaftliche Kennzahlen. Darauf folgt eine Einführung in die Kapitalmarktanalyse. Hier wird neben der Betrachtung von Theorien zur Aktienanalyse und deren Informationsverarbeitung auch der Ablauf einer Ereignisstudie definiert. Erläuterungen zur Datengrundlage sowie die Aufstellung der Hypothesen schließen das zweite Kapitel ab.

Im dritten Kapitel werden Berechnungsvorschriften als Grundlage der statistischen Auswertung definiert. Sie fungieren als unterstützender Bestandteil der empirischen Auswertung dieser Arbeit. Neben den typischen Marktmodellen werden auch autoregressive Modelle sowie Modelle mit konditioneller Heteroskedastizität vorgestellt. Es folgt die Aufstellung eines Regressionsmodells, mit der die Gewinnüberraschung von Unternehmensberichten eingeschätzt wird. Abschließend erfolgt eine Einführung zur Koinzidenzanalyse, mit deren Hilfe die Wahrscheinlichkeit eingeschätzt werden kann, gegeben einem Berichtszeitpunkt vorher bzw. nachher einen signifikanten Trend in der Rendite-Zeitreihe zu finden.

Nachdem im vierten Kapitel ein kurzer Überblick bisheriger wissenschaftlicher Arbeiten zum Thema gegeben wird, erfolgt die empirische Auswertung der Daten und Interpretation der Ergebnisse im fünften Kapitel. Die Masterarbeit wird durch ein Fazit im sechsten Kapitel abgeschlossen.

2 Theoretische Grundlagen

Bevor Aktienkurse und Unternehmenszahlen analysiert werden können, ist zu untersuchen, welche Regelungen Unternehmen bei der Veröffentlichung von Quartals- und Jahresabschlussberichten einzuhalten haben. Ferner sind Eigenschaften des Aktienmarktes zu eruieren, welche wesentlich für die empirische Auswertung dieser Arbeit sind. Schließlich werden Informationen zur Datengrundlage bereitgestellt und die zu untersuchenden Hypothesen formuliert.

2.1 Bilanzanalyse

Die Bilanzanalyse ist eine der Hauptdisziplinen der Volkswirtschaftslehre, welche in verschiedenste Teilkategorien untergliedert wird. Der Fokus für diese Arbeit liegt dabei hauptsächlich auf der traditionellen Kennzahlenanalyse des Einzeljahresabschlusses.

2.1.1 Rechte und Pflichten

Zunächst muss aber die gesetzliche Grundlage geklärt werden, denen Veröffentlichungen von Unternehmensberichten unterliegen. Folgende Gesetze und Gesetzestexte sind für dieses Kapitel relevant und regeln u. a. die Publikationspflicht von deutschen Unternehmen: das Handelsgesetzbuch (HGB), das Wertpapierhandelsgesetz (WpHG), das Aktiengesetz (AktG), das Börsengesetz (BörsG), die Börsenordnung der Frankfurter Wertpapierbörse (BörsO FWB) und die Börsenzulassungs-Verordnung (BörsZulV).

Im Allgemeinen haben Kapitalgesellschaften nach §242 & §264 HGB am Ende eines Jahres einen Lagebericht, eine Bilanz sowie die Gewinn- und Verlustrechnung aufzustellen. Nach §37 WpHG sind zudem Unternehmen, die Aktien als Inlandsemittenten ausgeben, verpflichtet, Halbjahres- sowie Quartalsfinanzberichte zu veröffentlichen. Es gelten die identischen Vorschriften wie bei der Erstellung des Jahresabschlussberichts. Halbjahresfinanzberichte sind nach den ersten sechs Monaten eines Jahres, Quartalsberichte jeweils zum Stichtag des ersten und dritten Quartals anzufertigen.

Neben der Pflicht zur Veröffentlichung von Geschäftsberichten unterliegen börsennotierte Unternehmen ebenfalls der Ad-hoc-Publizitätspflicht nach §15 WpHG. Diese regelt die sofortige Veröffentlichung von Unternehmensnachrichten die Einfluss auf die Geschäftstätigkeit haben könnten, wie beispielsweise Korrekturen von Absatzprognosen oder abweichende Umsatzzahlen. Diese Kurznachrichten werden zumeist auf den unternehmenseige-

nen Webseiten selbst oder durch die *Deutsche Gesellschaft für Ad-hoc-Publizität* (DGAP) veröffentlicht. Für diese Arbeit kommen Ad-hoc-Nachrichten nur in Frage, wenn sie Vorabinformationen für einen Jahresabschluss- oder Quartalsbericht enthalten und somit dessen Informationswirkung vorwegnehmen.

Weiterhin regelt §14 WpHG das Verbot des Insiderhandels. Es verbietet den Handel von Insiderpapieren (§12 WpHG), zu welchen man Insiderinformationen (§13 WpHG) noch vor öffentlicher Bekanntgabe besitzt. Jene Gesetze sind für diese Arbeit von essentieller Bedeutung, da eine eventuelle Reaktion der Aktienmärkte erheblich vom Veröffentlichungszeitpunkt eines Unternehmensberichts abweichen würde. Zudem wäre eine Festlegung des Informationszugangs nicht möglich.

Eine einheitliche Rechnungslegung von kapitalmarktorientierten, global agierenden Unternehmen bieten die *International Financial Reporting Standards* (IFRS), welche durch das *International Accounting Standards Board* (IASB) herausgegeben werden. Laut Verordnung (EG) Nr. 1606/2002 vom 19.07.2002, angeordnet durch europäischen Rat und Parlament, müssen diese für betroffene Unternehmen seit spätestens 2007 angewendet werden [10]. Um einen besseren Vergleich der Kennzahlen zu gewährleisten, werden ausschließlich nach IFRS angefertigte Geschäftsberichte berücksichtigt.

2.1.2 Kennzahlen

Der Hauptbestandteil eines Unternehmensberichts ist der Jahresabschluss. Er dient hauptsächlich der Informationsvermittlung für Investoren, Mitarbeiter und Lieferanten. Er enthält u. a. die Bilanz, die Kapitalflussrechnung und die Gewinn- und Verlustrechnung. Letztere beinhaltet wiederum zum größten Teil jene Kennzahlen, die für diese Arbeit erforderlich sind [11].

Da für die spätere Hauptkomponentenanalyse in Kapitel 3.5.1 wichtig ist, dass die betrachteten Kennzahlen dieselbe Skala aufweisen, werden im Folgenden jene Kennzahlen in Mio. €, respektive in Tsd. Fahrzeugen für den Absatz, betrachtet [12]:

Absatz: bezeichnet die Anzahl an ausgelieferten Fahrzeugen der Automobilhersteller. Wird bei Zulieferunternehmen nicht betrachtet.

Umsatzerlöse: ist eine betriebswirtschaftlich wichtige, gut prognostizierbare Größe. Ergibt sich aus Erlös des Verkaufs von Waren und Dienstleistungen abzüglich der Umsatzsteuer. Dadurch vor allem für Anleger eine Kennzahl von erhöhter Bedeutung [13].

- Bruttoergebnis:** wird aus den Umsatzerlösen abzüglich der „Herstellungskosten der zur Erzielung der Umsatzerlöse erbrachten Leistungen“ [14] berechnet. Kann bei kleineren Kapitalgesellschaften als Rohergebnis bezeichnet werden, wobei zusätzlich Personalkosten und sonstige betriebliche Erträge berücksichtigt werden [14].
- EBIT:** *Earnings Before Interest and Taxes* – auch „Ergebnis vor Zinsen und Steuern“ oder „operatives Ergebnis“ genannt, ist eine der probatesten Kennzahlen zum Unternehmensvergleich, da der Einfluss der unterschiedlichen Kapitalzusammensetzung (variierende Steuer- und Zinsbelastungen) eliminiert wird [14].
- EBT:** *Earnings Before Taxes* – Ergebnis vor Steuern. Analog zu EBIT, mit Berücksichtigung des Zinsaufwandes [14].
- Gewinn/Verlust:** auch als „Jahresüberschuss/–fehlbetrag“, „Konzernergebnis“ oder „Ergebnis nach Steuern“ bezeichnet, liefert es den endgültigen Wert des Gewinns oder Verlustes eines Unternehmens.
- Cashflow:** zeitraumbezogene Größe der Kapitalflussrechnung, hier: „Cashflow aus betrieblicher Tätigkeit“. Stellt den Geldfluss aus der Geschäftstätigkeit (Erhöhung/Verminderung von Forderungen, Lieferverbindlichkeiten und Vorräten) dar [15].

Bis auf den Cashflow, der zu den absoluten Kennzahlen der Liquiditätsanalyse zählt, können alle anderen absoluten Kennzahlen der Erfolgsanalyse zugeordnet werden [16]. Auf relative Kennzahlen wie dem Kurs-Gewinn-Verhältnis oder der Eigenkapitalrentabilität wird bewusst unter der Prämisse der Maßstabgleichheit verzichtet.

2.2 Analyse des Kapitalmarktes

Die Informationsverarbeitung auf dem Kapitalmarkt wird durch verschiedenste Thesen interpretiert. Eine kurze Übersicht ist dem ersten Unterkapitel 2.2.1 zu entnehmen. Danach folgt eine Einführung in die Thematik der Ereignisstudien.

2.2.1 Aktienanalyse und Markteffizienzhypothese

Hauptziel eines Investors ist unumstritten die Maximierung der Rendite seiner Anlage. Doch welche Informationen stehen dem Anleger zur Verfügung, die schlussendlich seine

Investitionsentscheidung beeinflussen? Die Analyse der Aktienmärkte kann grob in zwei verschiedene Philosophien eingeteilt werden: die *technische Aktienanalyse* und die *fundamentale Aktienanalyse*. Darüber hinaus gibt die *Markteffizienzhypothese* an, welche Informationen unter welchen Umständen vom Kapitalmarkt verarbeitet werden.

Die Verfahren der *technischen Analyse* beziehen sich auf Informationen, die aus historischen Kursverläufen entnommen werden können. Dabei werden nicht nur Kurse, sondern auch Umsatz und Open Interest (nur bei Futures und Optionen), zusammengefasst als Marktbewegung betitelt, genutzt. Die technische Analyse stützt sich im Kern auf drei Hypothesen. Die erste lautet: „Die Marktbewegung diskontiert alles“, d. h. alle Einflüsse, die auf den Marktpreis einwirken (Politik, Wirtschaft etc.) werden schlussendlich durch den Marktpreis verkörpert. Folglich ist nur die Betrachtung der Marktbewegung nötig. Die zweite Hypothese besagt, dass sich Kurse in Trends bewegen. Chartanalysten versuchen dabei, Trends frühzeitig zu erkennen, um aus ihnen den weiteren Kursverlauf abschätzen zu können. „Die Geschichte wiederholt sich“ lautet die dritte und letzte Annahme. Wiederkehrende Muster in den historischen Kursverläufen werden genutzt, um aktuelle Bewegungen nachvollziehen zu können [17].

Die zentrale These der *Fundamentalanalyse* besagt, dass der wahre Unternehmenswert gleich der Summe der abgezinsten Dividendenausschüttungen entspricht. Eine Investition am Kapitalmarkt ist demnach nur sinnvoll, wenn der wahre Unternehmenswert den Marktpreis übersteigt. Da die Dividendenausschüttungen der Zukunft unbekannt sind, versucht die Fundamentalanalyse mittels der Auswertung unternehmerischer Kennzahlen den wahren Wert eines Unternehmens zu schätzen. Dabei nimmt die Fundamentalanalyse, neben aktuellen und historischen Daten, auch Prognosen mit in ihre Betrachtung auf [18]. Im Gegensatz zur technischen Analyse untersucht die Fundamentalanalyse nicht die Auswirkungen von Marktbewegungen, sondern deren Ursachen [17].

Die Arbeit von *Fama* (1970) legte den Grundstein der *Markteffizienzhypothese* [19]. Demnach ist ein Markt als effizient zu bezeichnen, wenn die Aktienpreise zu jeder Zeit alle verfügbaren Informationen abbilden. Infolgedessen wird die Kapitalmarkteffizienz auch als Informationseffizienz bezeichnet. *Fama* (1970) unterscheidet drei Arten von effizienten Märkten: die schwache, mittelstrenge und strenge Markteffizienz. Die schwache Markteffizienz geht davon aus, dass keine Prognose auf Basis historischer Kursverläufe möglich ist. Sie bildet die Grundlage für die beiden weiteren Arten der Markteffizienz [19]. Durch die Anwendung der technischen Analyse sind demnach keine Überrenditen zu erzielen, da die gesamte Informationsmenge vergangener Kurse im aktuellen Preis inbegriffen ist [20].

Die mittelstrenge Markteffizienz besagt, dass Einflüsse durch öffentlich zugänglichen Informationen, wie Gewinnbenachrichtigungen oder Aktienaufstockungen, bereits im aktuellen Preis berücksichtigt wurden. Neben der technischen Analyse erübrigt sich hier auch die Fundamentalanalyse, unter der Absicht, Überrenditen erzielen zu können [20].

Wenn zusätzlich exklusive Insiderinformationen vom Kapitalmarkt aufgenommen und sofort im jeweiligen Aktienpreis abgebildet wurden, liegt die strenge Markteffizienz vor. Vor allem der amerikanische Markt wurde verschiedener Tests zum Thema der Markteffizienz unterzogen. Demzufolge kann die strenge Markteffizienz ausgeschlossen werden [20]. Angesichts der Untersuchungen der Auswirkungen von Unternehmensmeldungen auf Aktienkurse in dieser Arbeit, sind vor allem die schwache und mittelstrenge Informationseffizienz passiver Gegenstand dieser Ausführungen.

2.2.2 Ereignisstudie

Bei der Betrachtung des Einflusses von diversen Ereignissen auf den Verlauf von Aktienkursen haben sich Ereignisstudien bewährt. Neben der Betrachtung von Jahres- und Zwischenberichten können auch andere Ereignisse, wie beispielsweise Dividendenmeldungen, Meldungen zu einem Positionswechsel im Management oder eine außerordentliche Gewinnmeldung bzw. -berichtigung, ausgewertet werden. Ziel einer solchen Studie ist demnach die Betrachtung des störungsfreien Einflusses eines einzelnen Events auf die Rendite einer Aktie. Generell können sowohl Tagesrenditen, als auch Wochen- und Jahresrenditen betrachtet werden [2]. Durch die Unterstützung vollautomatischer Handelssysteme kann heutzutage auch auf Aktienkurse im Intraday-Handelszeitraum zurückgegriffen werden.

Die zeitliche Einteilung von Ereignisstudien erfolgt in eine Ereignisperiode und in eine vorgelagerte Schätzperiode. Zur Überprüfung der Konstanz der Schätzer kann eine nachgelagerte zweite Schätzperiode betrachtet werden. Je nach Ereignisart kann sich die Schätzperiode von wenigen Tagen bis zu einigen Jahren ausdehnen. Bei einer zu breit gesetzten Schätzperiode besteht jedoch die Gefahr überlappender Ereignisse, welche zusätzlichen Einfluss auf die Aktienreaktion haben könnten und somit das Ergebnis des eigentlich zu betrachtenden Ereignisses verfälschen würden. Eine zu klein gewählte Schätzperiode würde nicht konsistent genug in den Schätzern des Marktmodells sein und sie somit systematisch über- oder unterschätzen [2]. In dieser Arbeit wurde eine vorgelagerte, relativ kleine Schätzperiode von 50 Tagen gewählt, da durch die Einteilung der Ereignisse in Jahresquartale eine größere Periode zu Überschneidungen führen würde. Aus diesem Grund wurde auch auf eine zweite, nachgelagerte Schätzperiode verzichtet.




Abbildung 1: Ausschnitt des Aktienkursverlaufs der Continental AG, eingeteilt in Ereignis- und Schätzperiode, Ereignistag $t = 0$ [2]

Die Ereignisperiode wurde auf sieben Tage festgelegt, sodass die Kursdifferenzen (hier: abnormale Renditen, Definition in Kapitel 3.1.2) des Ereignistags und der drei vorherigen und drei nachfolgenden Tage jeweils einzeln und kumuliert betrachtet werden. Abbildung 1 verbildlicht den generellen zeitlichen Ablauf. Dabei werden in der vorgelagerte Schätzperiode der Länge T die Schätzer eines Gleichgewichtsmodells mittels Kleinst-Quadrate-Regression ermittelt. Diese werden für die Berechnung der abnormalen Renditen in der Ereignisperiode benötigt [2]. Der systematische Ablauf ist tendenziell unabhängig der Ereignisart und gliedert sich wie folgt auf [21]:

1. Detektion der Ereignisse
2. Festlegung der Ereignis- und Schätzperiode
3. Berechnung der normalen Renditen
4. Berechnung der abnormalen Renditen auf Basis eines Marktmodells
5. Kategorisierung und Aggregation der Daten
6. Signifikanzbewertung der abnormalen Renditen in der Ereignisperiode
7. Interpretation der Ergebnisse

Die genauen Berechnungsvorschriften der verschiedenen Punkte werden im dritten Kapitel aufgezeigt. Vor allem bei der Aufstellung und Interpretation des Marktmodells gibt es verschiedene Herangehensweisen. Die Kategorisierung der Ereignisse erfolgt in positiv bzw. negativ geprägte Nachrichten.

Schlussendlich kann eine Ereignisstudie nicht garantieren, ein perfektes, störungsfreies Abbild eines Ereigniseinflusses auf Renditen erzeugen zu können. Die Eigenschaften der Aktienmärkte, welche im vorhergehenden Kapitel erläutert wurden, erschweren dieses Vorhaben enorm. Durch die Anpassung der verschiedenen Parameter auf die Eigenschaften der jeweiligen Ereignisart kann dies aber optimiert werden.

2.3 Annahmen

Bevor dieses Kapitel durch die Aufstellung der Hypothesen abgeschlossen wird, werden Informationen zur Datengrundlage bereitgestellt. Hauptaugenmerk liegt dabei vor allem bei der Aufschlüsselung und Bereinigung der Stichprobe.

2.3.1 Datengrundlage

Datengrundlage dieser Arbeit sind alle im DAXSector Automobile (Performance)¹ notierten Unternehmen, welche im Zeitraum von Anfang 2000 bis Mitte 2015 ausreichend Daten (Aktienkurse und Berichte) lieferten. Tabelle 1 gibt einen Überblick der ausgewählten Aktiengesellschaften. Auf Grund der Höhe des Handelsvolumens wurde bei der Volkswagen AG die Vorzugsaktie und bei der BMW AG die Stammaktie gewählt. Aus frei zugänglichen Quellen wurden von diesen Unternehmen Jahres- und Zwischenberichte genutzt, um an die im Kapitel 2.1.2 genannten Kennzahlen zu gelangen.

Der Veröffentlichungszeitpunkt wurde zum größten Teil aus den Angaben der Berichte selbst festgelegt und mit Hilfe von Datums- und Uhrzeitangaben anderer Medien verglichen. Der Zeitpunkt der Veröffentlichung wurde auf den nächsten Handelstag verschoben, wenn ein Bericht erst nach 16:30 Uhr publiziert wurde. Somit ist den Investoren genügend Handlungsspielraum eingeräumt, da die meisten inländischen Orders über die elektronische Handelsplattform Xetra angenommen werden. Der Kernhandel der Xetra-Börse läuft zwischen 09:00 und 17:30 Uhr ab [22]. Die Datenbank der Webseite www.boerse-frankfurt.de diente als Quelle für die benötigten Aktienkurse. Für die spätere Berechnung der Rendite in Kapitel 3.1 wurden die täglichen Xetra-Schlusskurse ausgewählt.

¹wird ab hier zur Vereinfachung als „Marktindex“ bezeichnet

Tabelle 1: Übersicht der zu betrachtenden Unternehmen unter Angabe des Sitzes, des Kerngeschäfts sowie dem Kürzel und der ISIN, absteigend sortiert nach Mitarbeiterzahl – Stand 31.03.2015 [56, 57, 58, 59, 60, 61, 62, 63, 64]

Name	Kürzel	Sitz	Kerngeschäft	Mitarbeiter	ISIN
Volkswagen AG	VOW3	Wolfsburg	Automobilherstellung	595.300	DE0007664039
Daimler AG	DAI	Stuttgart	Automobilherstellung	283.541	DE0007100000
Continental AG	CON	Hannover	Reifenherstellung	202.496	DE0005439004
BMW AG	BMW	München	Automobilherstellung	117.554	DE0005190003
Leoni AG	LEO	Nürnberg	Boardnetz-Systeme	70.065	DE0005408884
Bertrandt AG	BDT	Ehningen	Entwicklung	11.859	DE0005232805
Grammer AG	GMM	Amberg	Innenausstattungen	10.693	DE0005895403
ElringKlinger AG	ZIL2	Dettingen	Spezialdichtungen	7.492	DE0007856023
PWO AG	PWO	Oberkirch	Leichtbau	3.152	DE0006968001

Tabelle 2 ist zu entnehmen, unter welchen Umständen Unternehmensberichte nicht in der endgültigen Stichprobe berücksichtigt wurden. Von 549 Ereignissen im Betrachtungszeitraum verbleiben nach Bereinigung noch 478. Zum größten Teil wirkt die späte Umstellung der Grammer AG und der ElringKlinger AG auf die Bilanzierung nach IFRS Maßstäben (jeweils erst mit Ausstellung des ersten Quartalsbericht 2005) auf die Bereinigung der Stichprobe ein.

Tabelle 2: Übersicht der Stichprobenbereinigung, aufgegliedert nach Bereinigungsgrund

Bereinigungsgrund	Anzahl der Ereignisse
Stichprobe	549
Keine ausreichende Markträumung zum Ereigniszeitpunkt	2
Fehlende Berichte oder Berichte mit fehlenden Angaben	4
Bericht nicht nach IFRS bilanziert	59
Fehlende Angabe zum Veröffentlichungszeitpunkt	6
Verbleiben	478

Die empirische Auswertung der Daten und die Erstellung der Abbildungen wurde mit Hilfe der freien Programmiersprache *R* durchgeführt. *R* wurde gezielt für statistische Analysen entworfen und kann durch den Open Source Charakter leicht durch Erweiterungen auf individuelle Bedürfnisse angepasst werden [65].

2.3.2 Thesenbildung

Im Folgenden werden Hypothesen formuliert, die im Sinne der ökonometrischen Analyse des Wechselspiels zwischen Aktienkursen und Unternehmenszahlen aufgestellt wurden und Grundlage für die empirische Auswertung darstellen.

Hypothese 1:

Aktienkurse reagieren mit instantanen Schocks auf die Veröffentlichung von Unternehmensberichten.

Dabei wird unterstellt, dass diese Auswirkungen bereits am Tag der Veröffentlichung, bzw. wenige Handelstage zuvor oder danach, nachzuweisen sind. Dieses Betrachtungsintervall wurde bereits im vorhergehenden Kapitel als Ereignisperiode definiert. Weiterführende Fragestellungen wären dabei, ob sich diese Schocks: in positiver oder negativer Richtung ausrichten, auf die verschiedenen Berichtszeitpunkte unterschiedlich auswirken und an welchem Tag der Ereignisperiode sie die größten Reaktionen verursachen. Überdies hinaus ist zu untersuchen, ob die Renditen innerhalb der verschiedenen Unternehmensuntergruppierungen variieren.

Hypothese 2:

Geschäftsberichte beeinflussen Aktienkurse über einen gewissen Zeitraum hinweg.

Wenn die Veröffentlichungen von Unternehmenszahlen Auswirkungen auf die Aktienkurse haben, über welchen Zeitraum sind diese dann statistisch beweisbar? Hypothese drei weist starke Ähnlichkeiten zur zweiten Hypothese auf, sie unterscheiden sich im Kern nur vom Beobachtungszeitraum:

Hypothese 3:

Aktienkurse nehmen die Umsatzzahlen (teilweise) bereits über einen gewissen Zeitraum vorweg.

Die Aktienkurse werden dabei auf signifikante Abweichungen im Zeitraum vor der Veröffentlichung der Unternehmensberichte im Verhältnis zur restlichen Zeitreihe untersucht. Wie sicher ist zu sagen, dass diese Abweichungen nicht zufällig auftreten? Schlussendlich lassen alle drei Hypothesen genügend Spielraum zur Interpretation der Auswirkungen von Berichtsveröffentlichungen auf ihre Aktienkurse.

3 Grundlagen zur statistischen Auswertung

Nachdem durch die Analyse der Eigenschaften der Aktienmärkte, sowie der Gegebenheiten der Bilanzanalyse und der Hypothesenbildungen der Grundstein gelegt wurde, werden im folgenden Kapitel allgemeine Berechnungsvorschriften und Vorgehensweisen zur statistischen Auswertung aufgezeigt. Dabei gibt es Unterschiede in den Analysemethoden zur Untersuchung der unterschiedlichen Thesen.

3.1 Renditeberechnung und –bereinigung

Im Allgemeinen werden bei Kapitalmarktzeitreihen nicht die Aktienkurse selbst analysiert, sondern vielmehr die ersten Differenzen ihrer Preise. Diese ersten Differenzen, welche aus den täglichen Schlusskursen ermittelt werden, nennt man Renditen. Renditen haben gegenüber den Preisen von Aktien den Vorteil, dass sie den Investoren eine skalenfreie Zusammenfassung ihres Investments geben. Darüber hinaus haben Rendite–Zeitreihen attraktivere statistische Eigenschaften, welche im Kapitel 3.2 definiert werden [23].

3.1.1 Stetige und diskrete Rendite

Die diskrete Rendite einer Aktie ist die relative Änderung zwischen zwei Zeitpunkten im Kursverlauf. Formel (1) gibt die Berechnungsvorschrift an [24].

$$R_{i,t} = \frac{P_{i,t}}{P_{i,t-1}} - 1, \quad (1)$$

mit:

$R_{i,t}$: Rendite der Aktie i zum Zeitpunkt t

$P_{i,t}$: Aktienkurs i zum Zeitpunkt t

Bei der Differenzbildung der logarithmierten Kursveränderung erhält man die stetige Rendite:

$$R_{i,t} = \ln \left(\frac{P_{i,t}}{P_{i,t-1}} \right). \quad (2)$$

Der Unterschied zwischen diskreter und stetiger Renditen ist bei kleinen Kursveränderungen vernachlässigbar gering. Bei der Analyse von Rendite–Zeitreihen hat sich die stetige Rendite als Berechnungsvorschrift durchgesetzt, da ihre statistischen Eigenschaften nachvollziehbarer sind als der diskreter Renditen [24]. Bei der empirischen Auswertung dieser Arbeit findet ebenfalls die stetige Rendite Verwendung.

3.1.2 Marktbereinigte Renditen

Um etwaige Einflüsse von Veröffentlichungen oder anderweitige Informationen auf die Rendite einer Aktie i bestimmen zu können, müssen diese Renditen vom Verlauf des Marktgeschehens bereinigt werden. Grundüberlegung ist, dass ein nicht unerheblicher Teil der Renditen der einzelnen Unternehmen vom Verlauf des Gesamtmarktes gebildet werden.

Die einfachste Variante diese abnormale Rendite $aR_{i,t}$ einer Aktie i zum Zeitpunkt t zu berechnen, ist die Differenz zwischen der Rendite des Unternehmens und der des Marktindex $R_{m,t}$ [2]:

$$aR_{i,t} = R_{i,t} - R_{m,t}. \quad (3)$$

Dieses Verfahren wird auch als *Marktadjustierung* bezeichnet. Das *einfache Marktmodell* geht einen Schritt weiter, indem es die Rendite einer Aktie als einfache lineare Regression der Marktrendite angibt [2]:

$$R_{i,t} = \alpha_i + \beta_i \cdot R_{m,t} + \varepsilon_{i,t}, \quad (4)$$

wobei:

- α_i : Marktrendite unabhängiger Bestandteil der Aktienrendite i
- β_i : Einfluss der Abhängigkeit der Aktienrendite i von der Rendite des Marktindex
- $\varepsilon_{i,t}$: Restterm der Regression.

Die abnormale Rendite wird demnach als Differenz zwischen der Rendite des Unternehmens und der Prognose der Marktrendite zum Zeitpunkt t in der Ereignisperiode auf Grundlage der Parameter aus der Schätzperiode berechnet [2]:

$$aR_{i,t} = R_{i,t} - (\hat{\alpha}_i + \hat{\beta}_i \cdot R_{m,t}). \quad (5)$$

Das *Capital Asset Pricing Model* (CAPM) von *Sharpe* (1964) und *Lintner* (1965) erweitert das Marktmodell um die Einbeziehung einer risikolosen Anlage R_f . Die erwartete Rendite eines Portfolios ist demnach die Rendite der risikolosen Anlagen R_f zuzüglich einer Risikoprämie. Der einzige Faktor, der Einfluss auf die Rendite nimmt, ist die Überrendite des Marktes $RMRF (= R_m - R_f)$, demnach gehört das CAPM aus empirischer Sicht auch zu den einfaktoriellen Modellen [3, 4].

$$R_{i,t} - R_f = \alpha_i + \beta_i \cdot (R_{m,t} - R_f) + \varepsilon_{i,t} \quad (6)$$

Formel (6) zeigt die empirische Erhebung des Schätzers durch ein Regressionsmodell auf Basis der Schätzperiode. Der β -Wert impliziert das systematische Risiko. Die Höhe des Risikos ergibt sich aus der Differenz von Kovarianz zwischen Aktien- und Markttrendite sowie der Varianz der Markttrendite [25]. Die abnormale Rendite nach dem CAPM wird analog des einfachen Marktmodells berechnet:

$$aR_{i,t} = R_{i,t} - [\hat{\alpha}_i + \hat{\beta}_i \cdot (R_{m,t} - R_f) + R_f]. \quad (7)$$

Das CAPM ist das am häufigsten verwendete Modell zur Marktabbildung in Ereignisstudien. Kritisch zu hinterfragen ist dabei der Fokus auf einen einzelnen Faktor, da diese Unterstellung verglichen mit der realen Marktabwicklung nicht zu halten ist. Außerdem unterliegt die Anwendbarkeit des CAPM gewisser Prämissen, wie der realen Existenz einer risikolosen Anlage oder der Existenz eines uneingeschränkten und vollkommenen Kapitalmarktes ohne Steuern, ohne Leerverkaufsverbote und ohne Regularien des Staats [26].

Fama/French (1993) haben auf Grund der Theorie vieler vorhergehender Studien das CAPM um zwei zusätzliche Faktoren erweitert [5]. Grundlage hierfür war, dass nicht nur der Faktor der Überrendite des Marktes $RMRF$ Einfluss auf die Aktienrendite nimmt. Weitere Einflussfaktoren galten als Anomalien und wurden vom CAPM nicht berücksichtigt [5, 27].

$$R_{i,t} - R_f = \alpha_i + \beta_i \cdot RMRF_t + s_i \cdot SMB_t + h_i \cdot HML_t + \varepsilon_{i,t} \quad (8)$$

$$aR_{i,t} = R_{i,t} - [\hat{\alpha}_i + \hat{\beta}_i \cdot RMRF_t + \hat{s}_i \cdot SMB_t + \hat{h}_i \cdot HML_t + R_f] \quad (9)$$

Das in Formel (8) aufgestellte Drei-Faktoren-Modell von *Fama/French* (1993) erweitert das CAPM um die Faktoren SMB und HML [5]. SMB steht dabei für „Small-Minus-Big“, auch als Größenfaktor bezeichnet, und beruht auf den Beobachtungen von *Banz* (1981), wonach Renditen sich durch die Unternehmensgröße, gemessen an der jeweiligen Marktkapitalisierung, signifikant unterscheiden [28]. Demnach haben kleinere Firmen signifikant höhere Renditen als große Unternehmen zu erwarten. Dieser Effekt ist weithin als „Size-Effekt“ bekannt [5, 28].

Der zweite zusätzlich eingeführte Faktor wird als „High-Minus-Low“, kurz HML , bezeichnet. Dieser stellt die Differenz in den Renditen von Unternehmen mit hohem und niedrigem Buch-Marktwert-Verhältnis dar. Er bildet die Erkenntnisse von *Rosenberg/Reid/Lahnstein* (1985) ab [29]. Sie wiesen eine positive Korrelation zwischen den durchschnittlichen Renditen und dem Buch-Marktwert-Verhältnis am US-amerikanischen Markt nach. Als Grund

für diesen Value-Effekt vermuteten *Lakonishok/Shleifer/Vishny* (1994) die Überbewertung von wachsenden und die Unterbewertung von stagnierenden/schrumpfenden Unternehmen durch die Investoren [30]. *Carhatt* (1997) erweiterte das Drei-Faktoren-Modell sogar noch um eine vierte Komponente namens *WML* („Winner-Minus-Loser“), welche den Momentumeffekt abdeckt [6]. Grundgedanke ist, dass der Markt kurzfristig auf stark im Wert ansteigende Aktien überreagiert [6].

Zur Berechnung der beiden zusätzlichen Faktoren des Drei-Faktoren-Modells werden die Aktien des zu betrachteten Portfolios in eine Gruppe *S* (small) mit niedriger und einer Gruppe *B* (big) mit hoher Marktkapitalisierung eingeteilt. Zusätzlich werden sie nach der Höhe des Buch-Marktwert-Verhältnisses in drei Gruppen, *H* für high, *M* für medium und *L* für low, differenziert. Demnach werden sechs unterschiedliche Portfolios der Renditen zum Zeitpunkt *t* eingeteilt: $R_t^{S/H}$, $R_t^{S/M}$, $R_t^{S/L}$, $R_t^{B/H}$, $R_t^{B/M}$ und $R_t^{B/L}$. Der Size-Effekt wird nach folgender Gleichung berechnet [5]:

$$SMB_t = \frac{(R_t^{S/H} + R_t^{S/M} + R_t^{S/L}) - (R_t^{B/H} + R_t^{B/M} + R_t^{B/L})}{3}. \quad (10)$$

Der Value-Effekt *HML* ergibt sich analog:

$$HML_t = \frac{(R_t^{S/H} + R_t^{B/H}) - (R_t^{S/L} + R_t^{B/L})}{2}. \quad (11)$$

Die abnormale Rendite nach dem Drei-Faktoren-Modell ergibt sich aus Gleichung (9). Wenn man die abnormale Rendite über ein bestimmtes Zeitintervall, vor allem über die gesamte oder Teile der Ereignisperiode, betrachten will, wird die kumulierte abnormale Rendite der Aktie *i* über das Zeitintervall τ in der Ereignisperiode wie folgt berechnet [2]:

$$caR_{i,\tau} = \sum_{t=1}^{\tau} aR_{i,t} \quad \text{mit} \quad \tau \in \{1; \dots; T\}. \quad (12)$$

Um später über gewisse Firmenzugehörigkeiten oder andere Einteilungen aggregieren zu können, wird die abnormale Rendite im Durchschnitt der betrachteten Aktien *N* zum Zeitpunkt *t* wie folgt ermittelt [2]:

$$aR_t = \frac{1}{N} \cdot \sum_{i=1}^N aR_{i,t}. \quad (13)$$

Die kumulierte abnormale Rendite im Durchschnitt der betrachteten Aktien N zum Zeitpunkt τ ermittelt sich analog [2]:

$$caR_\tau = \frac{1}{N} \cdot \sum_{i=1}^N caR_{i,\tau}. \quad (14)$$

Abschließend ist anzumerken, dass keines dieser Modelle den Aktienmarkt exakt nachbilden kann. Zu viele Einflussfaktoren bleiben unberücksichtigt, wodurch eine perfekte Vorhersage undurchführbar ist. Außerdem könnte man eine Korrelation der verschiedenen Faktoren untereinander vermuten. Dennoch passen sich zuletzt genannte Modelle dem Marktgeschehen immer besser an. Diese Arbeit konzentriert sich bei der Berechnung der abnormalen Renditen, vor allem bei der Ereignisstudie, auf das Verfahren des einfachen Marktmodells. Bei den Analysen zur zweiten und dritten These wurde die Marktadjustierung aus Formel (3) genutzt, um abnormale Renditen zu ermitteln.

3.1.3 Zeitpunktspezifischer t-Test

Nach der Ermittlung der abnormalen Renditen müssen diese noch statistisch verifiziert werden. Mit Hilfe eines Einstichproben-t-Tests wird die Nullhypothese: $H_0 =$ „die abnormalen Renditen sind nicht signifikant von null unterschieden“ überprüft. Die Teststatistik zum zeitpunktspezifischen t-Test ist in Gleichung (15) gegeben [31]:

$$T_{zs} = \frac{aR_t}{\frac{1}{\sqrt{N}} \sqrt{\frac{1}{(N-1)} \sum_{i=1}^N (aR_{i,t} - aR_t)^2}}, \quad (15)$$

mit N als der Stichprobengröße und aR_t aus (13) als Mittelwert der abnormalen Renditen der verschiedenen Aktien i . Die Werte der Teststatistik werden mit den kritischen Werten der Student-t-Verteilung für den zweiseitigen Vertrauensbereich mit $N - 1$ Freiheitsgraden verglichen.

3.2 Definitionen

Es folgen einige wichtige Definitionen bzw. typische Eigenschaften von Kapitalmarktzeitreihen, welche als Grundlage für weitere Erläuterungen dienen. Ausgangspunkt ist ein stochastischer Prozess X_t mit einer Realisation x_t zum Zeitpunkt t , der einen beliebigen Wert zu jedem Zeitpunkt t annehmen kann [25].

3.2.1 Stationarität, Leptokurtosis und Normalverteilung

Der Nachweis der *Stationarität* von Kapitalmarktzeitreihen hat eine zentrale Bedeutung für die Analyse dieser. Wenn in dieser Arbeit von Stationarität gesprochen wird, ist im Allgemeinen auf die schwache Stationarität abgezielt. Diese liegt vor, wenn der stochastische Prozess X_t einen Erwartungswert $E[X_t] = \mu$ (mittelwertstationär) und eine Varianz $\text{Var}[X_t] = \sigma^2 < \infty$ (varianzstationär) aufweist und die Autokovarianz λ_τ nur von der zeitlichen Verschiebung τ abhängig ist, nicht aber vom Zeitpunkt selbst [25]. Die Abbildungen 15 bis 21 zeigen die Aktienkurse und zugehörige Renditen der betrachteten Unternehmen. Es ist zu erkennen, dass die Aktienkurse von spezifischen Trends geprägt sind, wohingegen die Rendite-Zeitreihen um einen konstanten Mittelwert schwingen – erster Hinweis auf die Stationarität der Rendite-Zeitreihen.

Die Stationarität einer Rendite-Zeitreihe wird mittels dem von *Dickey/Fuller* (1979) entwickelten *Dickey-Fuller-Test* überprüft [32]. Liegen autokorrelierte Werte vor, findet der *Augmented Dickey-Fuller-Test* (ADF) Anwendung, da er die Zeitverschiebung mit in seine Betrachtung einbezieht. Ausgangspunkt des ADF-Tests ist somit ein $\text{AR}(p)$ -Prozess (genauere Erläuterung dazu später). Die Regressionsgleichung zum ADF-Test ist in Gleichung (16) gegeben [24].

$$\Delta X_t = (\alpha - 1)X_{t-1} + \sum_{i=1}^p \alpha_i \Delta X_{t-i} + \varepsilon_t \quad (16)$$

Die Nullhypothese $H_0 : \alpha = 1$ unterstellt Nichtstationarität, wohingegen die Alternativhypothese $H_a : \alpha < 1$ die Stationarität der Zeitreihe postuliert. Die ADF-Teststatistik berechnet sich wie folgt:

$$ADF = \frac{1 - \hat{\alpha}}{\text{std}(\hat{\alpha})}, \quad (17)$$

wobei $\hat{\alpha}$ der Schätzer des Regressionsparameters aus (16) ist. Wenn diese Teststatistik kleiner als der kritische Vergleichswert ist, kann die Nullhypothese: „dem Prozess unterliegt eine Einheitswurzel“ verworfen werden. Einheitswurzel bedeutet, dass eine Nullstelle für die charakteristische Gleichung (18) eines $\text{AR}(1)$ -Prozesses bei $z = 1$ existiert [33, 24].

$$\alpha(z) = 1 - \alpha_1 z - \dots - \alpha_p z^p = 0. \quad (18)$$

Mit Hilfe der Kurtosis kann eine Zeitreihe einer Verteilung zugeordnet werden. Die *Leptokurtosis* ist eine der Normalverteilung abweichende Verteilung, welche häufig, auf Grund von Ausreißern, bei Finanzmarktzeihen auftritt. Bei einer normalverteilten Zeitreihe ergibt

die Kurtosis einen Wert gleich drei, bei einer leptokurtischen Verteilung einen Wert größer als drei. Darüber hinaus kann die Annahme einer leptokurtischen Verteilung mit Hilfe der *Jarque–Bera–Statistik* (JB) überprüft werden. Demnach nimmt man, unter der Nullhypothese der Normalverteilung, die Schätzer der Schiefe $\hat{S}$ und Kurtosis $\hat{K}$ als unabhängig und asymptotisch normalverteilt an [33]:

$$\sqrt{n}\hat{S} \sim N(0, 6) \quad \text{und} \quad \sqrt{n}(\hat{K} - 3) \sim N(0, 24), \quad (19)$$

mit n als Stichprobenumfang. Daraus ergibt sich folgende Gleichung zur JB-Statistik, welche mit zwei Freiheitsgraden asymptotisch χ^2 -verteilt ist [33]:

$$JB = n \left(\frac{\hat{S}^2}{6} + \frac{(\hat{K} - 3)^2}{24} \right). \quad (20)$$

3.2.2 Autokorrelation und Autokovarianz

Für die Beschreibung der Eigenschaften schwach stationärer Prozesse, wie im vorherigen Kapitel unterstellt, werden die *Autokovarianz* und *Autokorrelation* benötigt. Diese charakterisieren den linearen Zusammenhang zwischen einer Zeitreihenvariable und der um einen Zeitabstand (Lag) τ verschobenen Zeitreihe. Die Autokovarianz- und Autokorrelationsfunktion ergeben sich aus der Berechnung verschiedener Lags τ .

Die Autokovarianzfunktion $\gamma(t, \tau)$ ergibt sich unter der Prämisse, dass der Mittelwert μ_t eines stochastischen Prozesses X_t als dessen Erwartungswert $\mu_t = E[X_t]$ definiert ist zu [33]:

$$\gamma(t, \tau) = E[(X_t - \mu_t)(X_{t-\tau} - \mu_{t-\tau})] \quad \text{für} \quad \tau = 1, \dots, N - 1. \quad (21)$$

Für den Fall $\tau = 0$ gilt für die Varianzfunktion $\gamma(t, 0) = \text{Var}(X_t)$. Durch die Symmetrie der Autokovarianz gilt $\gamma(t, \tau) = \gamma(t - \tau, -\tau)$. Wenn der Prozess X_t als Kovarianz-stationär eingestuft werden kann, gilt $\gamma(t, \tau) = \gamma_\tau$. Die Autokorrelationsfunktion ρ_τ (ACF) eines schwach stationären Prozesses berechnet sich demnach wie folgt [33]:

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0}. \quad (22)$$

Die ACF nimmt Werte im Intervall $[-1, 1]$ an. Bei einem Wert von $+1$ (-1) für ein bestimmtes τ ergibt sich eine perfekte positive (negative) Korrelation zwischen X_t und $X_{t-\tau}$. Analog der Autokovarianzfunktion gilt die Symmetrie der Funktion, d. h. $\rho_\tau = \rho_{-\tau}$. Der

empirische Wert der ACF $\hat{\rho}_\tau$ berechnet sich aus folgenden Schritten [25]:

$$\hat{\gamma}_0 = \frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})^2 \quad \hat{\gamma}_\tau = \frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})(x_{t-\tau} - \bar{x}) \quad \hat{\rho}_\tau = \frac{\hat{\gamma}_\tau}{\hat{\gamma}_0}, \quad (23)$$

mit $\bar{x} = \frac{1}{N} \sum_{t=1}^N x_t$ und $\tau = 1, \dots, N-1$. Um eine statistisch gesicherte Aussage über die Eigenschaft der Autokorrelation einer Zeitreihe treffen zu können, wurde von *Ljung/Box* (1978) ein Testverfahren entwickelt [34]. Die Teststatistik zum Ljung–Box–Test ist in Gleichung (24) gegeben. K gibt dabei die Anzahl der Autokorrelationskoeffizienten, N den Stichprobenumfang und $\hat{\rho}_\tau^2$ den jeweiligen quadrierten Autokorrelationskoeffizienten zum Lag τ an.

$$Q(K) = N(N+2) \sum_{\tau=1}^K \frac{\hat{\rho}_\tau^2}{(N-\tau)} \quad (24)$$

Mit $(K-1)$ Freiheitsgraden ist die Ljung–Box–Statistik approximativ χ^2 -verteilt. Die Nullhypothese besagt, dass der vorliegende Prozess keine systematische Struktur aufweist (auch als weißes Rauschen bezeichnet, dazu mehr im nachfolgenden Kapitel).

3.2.3 White Noise, Random Walk und Lag–Operator

Ein *White Noise Prozess*, auf Deutsch *weißes Rauschen* genannt, liegt bei einem reinen Zufallsprozess mit Erwartungswert μ_t von null und konstanter Varianz vor, dabei gilt folgende Vorschrift [33]:

$$\gamma_\tau = \begin{cases} \sigma^2 & \text{für } \tau = 0 \\ 0 & \text{für } \tau \neq 0. \end{cases} \quad (25)$$

White Noise Prozesse sind schwach stationär geprägt und bilden die Grundlage für komplexere Prozesse (siehe Kapitel 3.3). Ein typischer Verlauf ist in Abbildung 2 abgebildet. Zusätzlich ist ein charakteristischer Verlauf eines *Random Walk* in Abbildung 2 gegeben. Der Random Walk schwingt im Gegensatz zum White Noise um keinen festen Mittelwert. Daraus ist die nichtstationäre Eigenschaft des Random Walks abzuleiten.

Gleichung (26) repräsentiert einen stochastischen Prozess X_t , der einem Random Walk mit einer Konstanten c und einem White Noise ε_t folgt. Ein sogenannter *Random Walk mit Drift* tritt bei einer Konstanten ungleich null auf. Random Walk–Prozesse sind von historischer Bewandnis, da sie die ersten stochastischen Modelle waren, die den Verlauf

von Aktienkursen nachzubilden versuchten [33].

$$X_t = c + X_{t-1} + \varepsilon_t \quad (26)$$

Der *Lag-Operator* L stellt die zeitliche Rückverschiebung um k -Perioden dar. Es gilt folgende Beziehung [33]:

$$L^k X_t = X_{t-k}. \quad (27)$$




Abbildung 2: Simulierter Verlauf eines Random Walk (schwarz) und White Noise Prozesses (grau) [25]

3.3 Linear stochastische Prozesse

Im Allgemeinen werden in der angewandten Zeitreihenanalyse folgende Modelle unterschieden: das *autoregressive Modell* der Ordnung p $AR(p)$, das *Moving-Average-Modell* q -ter Ordnung $MA(q)$, eine Mischung dieser beiden Modelle namens $ARMA(p, q)$ und zuletzt das $ARIMA(p, q, d)$ -Modell, welches für *autoregressive integrated moving average* steht. Es erweitert das $ARMA(p, q)$ -Modell um die Häufigkeit der Differenzbildung d . Im Folgenden werden nur jene univariaten Modelle betrachtet, welche die Eigenschaft der Stationarität aufweisen (können). Die Konzentration liegt also auf dem MA -Modell (immer stationär), dem AR - und $ARMA$ -Modell (können stationär und nichtstationär sein), da

das ARIMA(p, q, d)–Modell immer nichtstationär ist [25]. Darüber hinaus liegt der Fokus dieser Arbeit auf den Prozessen erster Ordnung.

3.3.1 Autoregressive Prozesse

Zunächst eine Zeitreihe, die einem *autoregressiven Prozess* $AR(p)$ folgt:

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \cdots + \alpha_p X_{t-p} + \varepsilon_t, \quad (28)$$

$$\alpha(L)X_t = \varepsilon_t, \quad (29)$$

wobei postuliert wird, dass aktuelle Ereignisse X_t aus einer Kombination von vergangenen Beobachtungen X_{t-p} und einer überlagernden Störvariable ε_t bestehen. Die Störvariable ε_t impliziert dabei weißes Rauschen. Gleichung (28) kann unter Hinzunahme des Lag–Operators L mit $\alpha(L) = 1 - \alpha_1 L - \cdots - \alpha_p L^p$ zu Gleichung (29) zusammengefasst werden. Grundgedanke hinter AR–Prozessen ist, dass sich Kapitalmarktzeitreihen durch eine gewisse Trägheit auszeichnen, sprich ihr Verhalten basiert auf der Vergangenheit. Im Folgenden wird der autoregressive Prozess erster Ordnung $AR(1)$ betrachtet, bei dem der aktuell beobachtete Wert auf dem direkt vorhergehenden basiert [25].

$$X_t = \alpha X_{t-1} + \varepsilon_t \quad (30)$$

Dabei hat der $AR(1)$ –Prozess eine konstante Varianz (Gleichung (31) mit $Var(\varepsilon_t)$ gleich der Varianz des weißen Rauschens σ_ε^2) und einen Erwartungswert von null. Bei einem Erwartungswert ungleich null ist μ gleich dem Erwartungswert von X_t (Gleichung (32)) [25].

$$Var(X_t) = \lambda_0 = \frac{\sigma_\varepsilon^2}{1 - \alpha^2} \quad \text{mit } \sigma_\varepsilon^2 = Var(\varepsilon_t) \quad (31)$$

$$(X_t - \mu) = \alpha(X_{t-1} - \mu) + \varepsilon_t \quad (32)$$

Folgende Gleichung beschreibt die zugehörige ACF mit τ als dem Lag. Somit nimmt die ACF mit wachsenden τ ab, vorausgesetzt α ist betragsmäßig kleiner als eins. Liegt α im Intervall $[0, 1]$ zeigt die ACF eine exponentielle Abnahme, liegt es jedoch im Intervall $[-1, 0]$ weist die ACF ein sogenanntes oszillatorisches Verhalten auf (siehe Abbildung 3). Bei einem α betragsmäßig größer als eins liegt ein nichtstationärer $AR(1)$ –Prozess vor [33]:

$$\rho_\tau = \alpha^\tau. \quad (33)$$




Abbildung 3: ACF eines AR(1)–Prozesses mit $\alpha = 0,9$ links und $\alpha = -0,8$ rechts [12]

3.3.2 Moving–Average–Prozesse

Ein *Moving–Average–Prozess* $MA(q)$ setzt sich aus dem aktuellen sowie den gewichteten q –Perioden vergangener Störterme zusammen. Da der Störprozess ε_t weißes Rauschen impliziert, sind alle $MA(q)$ –Prozesse stationär. Unter Hinzunahme des Lag–Operators L wird Formel (34) mit $\beta(L) = 1 - \beta_1 L - \dots - \beta_q L^q$ zu Formel (35) vereinfacht [33]:

$$X_t = \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q} \quad (34)$$

$$X_t = \beta(L) \varepsilon_t. \quad (35)$$

Ein Moving–Average–Prozess erster Ordnung $MA(1)$ liegt vor, wenn:

$$X_t = \varepsilon_t - \beta \varepsilon_{t-1}, \quad (36)$$

d. h. es wird angenommen, dass nur der aktuelle und der Störprozess aus der vorgelagerten Periode Einfluss auf den aktuellen Zeitreihenwert haben. Die ACF eines $MA(1)$ –Prozesses folgt Bedingung (37) [25]:

$$\rho(\tau) = \begin{cases} 1 & \text{für } \tau = 0 \\ -\beta/(1 + \beta^2) & \text{für } \tau = 1 \\ 0 & \text{sonst ,} \end{cases} \quad (37)$$

wobei sich nur für Lag eins ein Autokorrelationswert ungleich null ergibt. Nach dem ersten Lag bricht die ACF eines MA(1)–Prozesses ab und alle weiteren Werte sind gleich null. Abbildung 4 bildet diese Theorie für einen MA(1)–Prozess grafisch ab. Lag eins zeigt hier bei beiden Parametern einen deutlichen Wert ungleich null. Alle weiteren Werte nähern sich dem Wert null an. Dennoch ist eine deutlich schnellere Anpassung an den Wert null bei höheren β –Werten zu erwarten, womit es die theoretischen Überlegungen besser abbilden würde.




Abbildung 4: ACF eines MA(1)–Prozesses mit $\beta = 0,5$ links und $\beta = -0,5$ rechts [12]

Der Erwartungswert eines MA(1)–Prozesses ist gleich null, außer die Gleichung enthält eine Konstante, dann ist der Erwartungswert gleich dem Erwartungswert der Konstanten. Die Varianz für einen MA(1)–Prozess ist in Gleichung (38) gegeben [25].

$$\text{Var}(X_t) = \sigma_\varepsilon^2 + \beta^2 \sigma_\varepsilon^2 \quad (38)$$

Neben der Stationarität ist die Invertierbarkeit eine wichtige Eigenschaft von Moving–Average–Prozessen. Dazu wird Gleichung (36) nach ε_t umgestellt [25]:

$$\varepsilon_t = X_t + \beta \varepsilon_{t-1}. \quad (39)$$

Wiederholt man diesen Vorgang der Substitution, ergibt sich der Schock ε_t der aktuellen Periode aus einer Linearkombination der Zufallsvariablen vergangener Perioden [25]:

$$\varepsilon_t = X_t + \beta X_{t-1} + \beta^2 X_{t-2} + \beta^3 X_{t-3} \cdots \quad (40)$$

Es ist anzunehmen, dass für größere Werte j in β^j die β -Werte Richtung null gehen, da weiter zurückliegende Werte X_t weniger Einfluss auf den aktuellen Schock haben sollten. Außerdem zeigt Gleichung (40) die Darstellung eines MA(q)- als AR(∞)-Prozess. Die Invertierbarkeit ist dafür Grundvoraussetzung. Im Gegensatz dazu kann ein AR(p)- als MA(∞)-Prozess dargestellt werden. Dabei werden die X_t -Werte aus Gleichung (31) immer wieder mit $t-1$, $t-2$ usw. substituiert. Ergebnis ist Gleichung (41), welche die Werte X_t des aktuellen Zeitpunkts in Abhängigkeit aller vergangenen Störungen abbildet [25].

$$X_t = \sum_{i=0}^{\infty} \alpha^i \varepsilon_{t-i} \quad (41)$$

3.3.3 Autoregressive–Moving–Average–Prozesse

Wie bereits in den vorherigen Kapiteln erläutert, können, unter der Voraussetzung der Stationarität von AR-Prozessen und der Invertierbarkeit von MA-Prozessen, diese Prozesse jeweils durch den in Richtung unendlich laufenden, korrespondierenden Prozess approximiert werden. Dies spricht aber gegen die Sparsamkeit der Parametrisierung der Zeitreihenanalyse, die von *Box/Jenkins* (1970) postuliert wurde [35]. Um dies zu umgehen, wurde von *Box/Jenkins* (1970) das *Autoregressive–Moving–Average–Modell* (ARMA) eingeführt [35]. Ein ARMA(p, q)-Modell, unter Zuhilfenahme des Lag Operators L , kann wie folgt aufgestellt werden [35]:

$$\alpha(L)X_t = \beta(L)\varepsilon_t. \quad (42)$$

Weiterhin wird ein ARMA(1,1)-Modell wie in Gleichung (43) betrachtet. Der linke Teil der Gleichung repräsentiert den AR-Teil, der rechte den MA-Teil. Liegt α im Intervall $[-1, 1]$ ist der ARMA(1,1)-Prozess stationär, liegt β im Intervall $[-1, 1]$ ist er invertierbar.

$$X_t - \alpha X_{t-1} = \varepsilon_t - \beta \varepsilon_{t-1} \quad (43)$$

Die zugehörige ACF ist in Gleichung (44) gegeben. Ihr Verlauf ähnelt dem des AR(1)-Prozesses: nach dem ersten Lag gibt es eine exponentielle Abnahme, wobei das Vorzeichen entscheidet, ob es sich um eine glatte oder oszillatorische handelt [24].

$$\begin{aligned} \text{für } \tau = 1 : \quad \rho_1 &= [(1 - \alpha\beta)(\alpha - \beta)]/[1 + \beta^2 - 2\alpha\beta] \\ \text{für } \tau = k : \quad \rho_k &= \alpha\rho_{k-1} \quad \text{mit } k > 1 \end{aligned} \quad (44)$$

Im Allgemeinen können mittels der ACF die verschiedenen Prozesse, inklusive der Parametrisierung, identifiziert werden. Dabei sind reine AR- oder MA-Prozesse relativ einfach nachzuweisen, schwieriger ist es bei gemischten Prozessen (ARMA) [25].

3.4 Modelle zum Volatilitätsclustering

Die Volatilität σ gibt die Variabilität der Renditen rund um ihren Erwartungswert μ an. Die Volatilität spielt eine zentrale Rolle bei der Modellierung von Kapitalmarktzeitreihen. Da sie nicht direkt beobachtbar ist, muss sie aus den gegebenen Daten berechnet werden. Vor allem das zu beobachtende Phänomen, dass auf hohe (niedrige) Preisänderungen tendenziell hohe (niedrige) Preisänderungen folgen, kann nicht von einem klassisch-linearen AR- oder ARMA-Prozess abgebildet werden. Dieses Anomalie nennt sich Volatilitätsclustering und kann von ARCH-Modellen (Autoregressive Conditional Heteroscedasticity) nachgebildet werden. Zusätzlich decken ARCH-Modelle alle weiteren statistischen Eigenschaften von Finanzzeitreihen (Stationarität, Leptokurtosis und weißes Rauschen) wie in Kapitel 3.2 angeführt ab [33]. Das folgende Kapitel gibt eine kurze Einführung zu ARCH, GARCH und weiterführenden Modellen und zielt dabei vor allem auf eine kurzfristige Volatilitätsprognose mit Hilfe eines GARCH-Modells ab.

3.4.1 ARCH-Modelle

Das erste ARCH(q)-Modell, wie in Gleichung (45) aufgestellt, wurde von *Engle* (1982) entwickelt [7]. Dabei stellt sich die bedingte Varianz $\sigma_{i,t}^2$ der Aktie i zum Zeitpunkt t als eine lineare Funktion von quadrierten Residuen $\varepsilon_{i,t-k}^2$, zeitverzögert um q -Zeiteinheiten, dar. Diese Residuen resultieren aus der Annahme, dass sich Renditen R_t aus der Summe ihres Mittelwerts μ und den nicht zu erwartenden Schocks ε_t ergeben. Dieser Störterm ε_t ist nicht länger wie bei den linear stochastischen Prozessen aus Kapitel 3.3 unabhängig, sondern zentriert und unkorreliert [33].

$$\sigma_{i,t}^2 = \omega_i + \sum_{k=1}^q \alpha_{i,k} \varepsilon_{i,t-k}^2 \quad (45)$$

Dabei ist sicherzustellen, dass die geschätzten Parameter ω_i und $\alpha_{i,k}$ für $k = 1, \dots, q$ die Nichtnegativitätsbedingung erfüllen, um eine positive bedingte Varianz erhalten zu können. Analog eines AR(p)-Prozesse muss ein ARCH(q)-Prozess die Stationaritätsbedingung, gegeben in Gleichung (46), erfüllen [7].

$$\sum_{k=1}^q \alpha_{i,k} < 1 \quad (46)$$

Falls diese Summe aber größer gleich eins ist, existiert die unbedingte Varianz nicht und der Prozess ist nicht Kovarianz-stationär. Falls diese Bedingung aber erfüllt ist, berechnet sich die unbedingte Varianz wie folgt [33]:

$$\sigma_i^2 = \frac{\omega_i}{1 - \alpha_{i,1} - \dots - \alpha_{i,q}}. \quad (47)$$

Mit Hilfe eines ARCH(1)-Modells kann das Volatilitätsclustering von ARCH(q)-Modellen, unter Hinzunahme von Gleichung (47), belegt werden [25]:

$$\begin{aligned} \sigma_{i,t}^2 &= \omega_i + \alpha_{i,1} \varepsilon_{i,t-1}^2 \\ &= \frac{\omega_i}{1 - \alpha_{i,1}} + \alpha_{i,1} \left(\varepsilon_{i,t-1}^2 - \frac{\omega_i}{1 - \alpha_{i,1}} \right) \\ &= \sigma_i^2 + \alpha_{i,1} (\varepsilon_{i,t-1}^2 - \sigma_i^2). \end{aligned} \quad (48)$$

Die bedingte Varianz $\sigma_{i,t}^2$ ist demnach die Summe aus unbedingter Varianz σ_i^2 und der $\alpha_{i,1}$ -gewichteten Differenz aus quadriertem Residuum $\varepsilon_{i,t-1}^2$ und der unbedingten Varianz σ_i^2 . Dies impliziert, dass nach einer betragsmäßig großen unerwarteten Kursänderung eine hohe und nach einer betragsmäßig kleinen unerwarteten Kursänderung eine niedrige Volatilität folgt. Beziehung (48) belegt also das Phänomen des Volatilitätsclustering [25].

Zur Überprüfung einer Zeitreihe auf ARCH-Effekte wurde der *Lagrange-Multiplikatoren-Test* (LM-Test) von Engle (1982) entwickelt [7]. Dieser Test ist äquivalent dem normalen F-Test, wobei die Nullhypothese besagt, dass keine ARCH-Effekte vorliegen, die Parameter der Hilfsregression in (49) also nicht signifikant von null verschieden sind [7]:

$$\varepsilon_{i,t}^2 = a_{i,0} + a_{i,1} \varepsilon_{i,t-1}^2 + \dots + a_{i,q} \varepsilon_{i,t-q}^2 + u_{i,t}, \quad (49)$$

mit $u_{i,t}$ als Fehlerterm, q als Zeitverschiebung und T ($t = q + 1, \dots, T$) als die Anzahl der Beobachtungen. Die Teststatistik in Gleichung (50) ist asymptotisch äquivalent einer χ^2 -Verteilung mit q -Freiheitsgraden. Die Entscheidung, ob die Nullhypothese abgelehnt werden kann, wird getroffen, wenn $F > \chi_q^2(\alpha)$ mit $\chi_q^2(\alpha)$ als dem oberen $100(1-\alpha)$ Perzentil von χ_q^2 .

$$F = \frac{(SSR_0 - SSR_1)/q}{SSR_1/(T - 2q - 1)}, \quad (50)$$

wobei $SSR_0 = \sum_{t=q+1}^T (\varepsilon_{i,t}^2 - \bar{\omega})^2$ mit $\bar{\omega} = (1/T) \sum_{t=1}^T \varepsilon_{i,t}^2$ als dem Mittelwert von $\varepsilon_{i,t}^2$ und $SSR_1 = \sum_{t=q+1}^T \hat{u}_{i,t}^2$ mit $\hat{u}_{i,t}$ als kleinste Fehlerquadrate der Hilfsregression aus (49) [24].

3.4.2 GARCH-Modelle

Mit der Anwendung von ARCH(q)-Modellen auf finanzwirtschaftliche Zeitreihen wurde immer häufiger festgestellt, dass für eine adäquate Abbildung der Volatilität eine relativ hohe Anzahl von q -Zeitverzögerungen nötig war. Daraus folgte, dass es bei höheren Ordnungen q zu Problemen mit der Einhaltung der Nichtnegativitätsbedingungen kam [24]. Daraufhin entwickelte *Bollerslev* (1986) die *Generalized-ARCH-Modelle* (GARCH) [8].

Im Gegensatz zu ARCH(q)-Modellen werden bei GARCH(p, q)-Modellen neben den quadrierten Residuen auch die bedingten Varianzen der Vorperioden bei der Berechnung der bedingten Varianz der aktuellen Periode berücksichtigt [33]:

$$\sigma_{i,t}^2 = \omega_i + \sum_{k=1}^q \alpha_{i,k} \varepsilon_{i,t-k}^2 + \sum_{j=1}^p \beta_{i,j} \sigma_{i,t-j}^2. \quad (51)$$

Analog zum ARCH(q)-Modell gibt Gleichung (52) die Stationaritätsbedingung an, bei der die Summe der Parameter kleiner eins sein muss. Eine positive bedingte Varianz wird durch die Nichtnegativitätsbedingungen $\omega_i > 0$, $\alpha_{i,k} > 0$ für $k = 1, \dots, q$ und $\beta_{i,j} > 0$ für $j = 1, \dots, p$ garantiert [8].

$$\sum_{k=1}^q \alpha_{i,k} + \sum_{j=1}^p \beta_{i,j} < 1 \quad (52)$$

Unter dem Prinzip der sparsamen Parametrisierung von *Box/Jenkins* (1970) wird ab sofort ein GARCH(1, 1)-Modell (53) betrachtet [35, 33].

$$\sigma_{i,t}^2 = \omega_i + \alpha_{i,1} \varepsilon_{i,t-1}^2 + \beta_{i,1} \sigma_{i,t-1}^2 \quad (53)$$

Die unbedingte Varianz σ_i^2 , unter der Annahme aller Nebenbedingungen, berechnet sich wie folgt [33]:

$$\sigma_i^2 = \omega_i / (1 - \alpha_{i,1} - \beta_{i,1}). \quad (54)$$

Die Berechnung der unbedingten Varianz aus Gleichung (54) wird für die kurzfristige Prognose benötigt. Demnach ist die bedingte Varianz der nachfolgenden Periode p [33]:

$$\sigma_{i,t+p}^{2,GARCH} = E[R_{i,t+p}^2] = \sigma_i^2 + (\alpha_{i,1} + \beta_{i,1})^p (\sigma_{i,t}^2 - \sigma_i^2), \quad (55)$$

wobei bei großen p -Werten der rechte Term der Gleichung (55) Richtung null geht und die bedingte Varianz unterdessen nur aus der unbedingten Varianz laut Gleichung (55) besteht, vorausgesetzt $\alpha_{i,1} + \beta_{i,1} < 0$. Die aggregierte bedingte Varianz über das Intervall $[t+1, t+p]$ ist demzufolge [33]:

$$\tilde{\sigma}_{i,t,p}^{2,GARCH} = E[R_{i,t+1} + \dots + R_{i,t+p}]^2 = \sigma_{i,t+1}^{2,GARCH} + \dots + \sigma_{i,t+p}^{2,GARCH}. \quad (56)$$

Die Volatilität $\bar{\sigma}_{t,p}^{GARCH}$ im Ereignisfenster der verschiedenen Aktien i ergibt sich aus dem Mittelwert der einzelnen Aktien:

$$\bar{\sigma}_{t,p}^{GARCH} = \frac{1}{N} \sum_{i=1}^N \sqrt{\tilde{\sigma}_{i,t,p}^{2,GARCH}}. \quad (57)$$

Um diese geschätzte Volatilität vergleichen zu können, wird die realisierte Volatilität $\tilde{R}_{i,t,p}$ in den Ereignisfenstern berechnet (58) und in Gleichung (59) der Mittelwertbildung analog zu Gleichung (57) unterzogen [33].

$$\tilde{R}_{i,t,p}^2 = \sum_{j=1}^p R_{i,t+j}^2 \quad (58)$$

$$\bar{R}_{t,p} = \frac{1}{N} \sum_{i=1}^N \sqrt{\tilde{R}_{i,t,p}^2} \quad (59)$$

Ein Vergleich der prognostizierten $\bar{\sigma}_{t,p}^{GARCH}$ und der beobachteten Volatilität $\bar{R}_{t,p}$, kann nun zur Interpretation von Gewinnüberraschungen über ein festgelegten, kurzfristigen Horizont p genutzt werden.

3.4.3 Weiterführende Modelle

Neben der Erweiterung des ARCH(p)-Modells von *Engle* (1982) zum GARCH(p, q)-Modell von *Bollerslev* (1986) gab es in den letzten Jahrzehnten eine Vielzahl weiterer Modellvarianten der ARCH-Prozess-Familie [7, 8]. Es folgt ein kurzer Überblick zu einigen dieser Modelle.

Das *GARCH-in-the-Mean-Modell* (GARCH-M) wurde von *Engle/Lilien/Robbins* (1987) entwickelt und zählt zu den symmetrischen Modellen [36]. Auslöser der Entwicklung war die Abbildung des Wechselspiels zwischen Rendite und Risiko in der Finanzmarktwirtschaft. Da die Rendite von Volatilitätsclustern geprägt ist, wird die Annahme, sie ergebe sich aus

der Summe ihres Mittelwerts und weißem Rauschen, um die bedingte Varianz als exogene Größe erweitert [24]:

$$R_t = \mu + \lambda \cdot g(\sigma_t^2) + \varepsilon_t, \quad (60)$$

mit σ_t^2 eines in Formel (51) gegebenen GARCH-Prozesses, sowie Parameter μ und λ als Konstante. λ ist dabei als Premiumrisikoparameter zu interpretieren, der, wenn größer null, eine positive Beziehung zwischen Rendite und Volatilität anzeigt. Die Funktion $g(\sigma_t^2)$ kann als linear (σ_t^2 oder σ_t) oder logarithmisch ($\ln(\sigma_t^2)$) angewendet werden [24, 25].

Bei den bisherigen Modellen dieses Kapitels wurde durch die Quadrierung der Kursänderungen eine gewisse Symmetrie der Volatilität aufrecht erhalten. *Black* (1976) zeigte aber, dass ein negativer Schock (in gewisser Weise auch als negative Meldung zu interpretieren) zu einer höheren Volatilität und ein positiver Schock im Allgemeinen zu einer tendenziell kleineren Volatilität führe [37]. Um dieses als *Leverage-Effekt* bezeichnete Phänomen aufzufangen, wurden eine Reihe asymmetrischer Modelle aufgestellt, wie das *Exponential-GARCH-Modell* (EGARCH) von *Nelson* (1991) [9]. Dabei wird durch eine Transformation der Logarithmus der bedingten Varianz modelliert:

$$\ln(\sigma_t^2) = \omega + \sum_{k=1}^q \alpha_k \left(\left| \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \right| - E \left[\left| \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \right| \right] + c \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \right) + \sum_{j=1}^p \beta_j \ln(\sigma_{t-j}^2). \quad (61)$$

Dabei gibt Parameter c den Leverage-Effekt an. Typische Ergebnisse bei empirischen Untersuchungen geben den Parameterwert $-1 < c < 0$ an, womit negative Schocks stärker auf die Erhöhung der Volatilität einwirken als positive. Das Verhältnis $\varepsilon_{t-k}/\sigma_{t-k}$ gilt als standardisierter Fehlerterm. Unterliegt ε_{t-k} einer bedingten Normalverteilung, so sind die standardisierten Fehlerterme mit einem Erwartungswert der absoluten standardisierten Residuen von $\sqrt{\frac{2}{\pi}} \approx 0,798$ standardnormalverteilt [25].

3.5 Berechnung erwarteter Gewinn

Nach den Erläuterungen zu Berechnungsvorschriften und Definitionen der Eigenschaften von Rendite-Zeitreihen folgen nun die Analyseschritte zur Auswertung der Unternehmenszahlen. Ziel ist es, die grundsätzliche Ausrichtung einer Unternehmensmeldung (positiv oder negativ) einordnen zu können. Diese Kategorisierung der Gewinnerwartung durch die Investoren kann mittels verschiedener Verfahren nachgebildet werden.

Der einfachste Weg dies zu realisieren ist ein Vergleich des durch einen einzelnen Unternehmensbericht gegebenen Kennzahlenwertes mit dem jeweiligen Vorjahres- oder Vorquartals-

wert. Der Vorteil dieses Verfahrens ist die sofortige Vergleichsmöglichkeit, da die relative Abweichung in der Regel in jedem Bericht angegeben ist. Somit steht der schnellen Handelsmöglichkeit nichts im Wege. Nachteilig wiegt der Fakt, dass dieser Vergleich meist keine grundlegende Aussage über die zukünftige Geschäftstätigkeit des Unternehmens trifft.

Eine zweite Möglichkeit ist der Vergleich der tatsächlich berichteten Werte mit den vorherigen Einschätzungen von Analysten. Analysten prognostizieren die Gewinnkennzahlen der Unternehmen im Vorfeld, weichen diese nun von den beobachteten Werte stark ab, kann von einer Gewinnüberraschung ausgegangen werden. Der Nachteil dieser Methodik ist die schlechte Verfügbarkeit frei zugänglicher und vor allem historischer Analystenschätzungen. Darüber hinaus müssten mehrere verschiedene Analystenschätzungen herangezogen werden, um eine gewisse Homogenität der Schätzungen zu erhalten.

Eine weitere Möglichkeit, welche auch in dieser Arbeit Anwendung trägt, ist die Aufstellung eines Zeitreihenmodells, dieses in einem weiteren Schritt zu schätzen und die Ausrichtung der Residuen zwischen beobachteter und geschätzter Zeitreihe als Gewinnüberraschung zu interpretieren. Da die Automobilindustrie zyklische Eigenschaften aufweist, wäre es zusätzlich sinnvoll, der Zeitreihe eine saisonale Figur zuzufügen. Darüber hinaus ist ein Strukturbruch in der Zeitreihe, ausgelöst durch die Weltwirtschaftskrise in den Jahren 2008/2009, sehr wahrscheinlich.

3.5.1 Hauptkomponentenanalyse

Bevor im Abschnitt 3.5.2 das geschätzte Modell der Zeitreihe aufgestellt wird, erfolgt eine Auswahl der im Modell zu berücksichtigten Kennzahlen. Dabei stellt sich folgende Frage: Welche Kennzahlen bilden die unternehmerische Tätigkeit einer Aktiengesellschaft am besten ab? Da es wenig objektiv wäre diese Aufgabe einer der im Kapitel 2.1.2 angegebenen Kennzahlen einzeln zuzuordnen, wird im Folgenden eine *Hauptkomponentenanalyse* angewendet. Mit Hilfe der Hauptkomponentenanalyse (im Englischen Principal Components Analysis, kurz PCA) wird versucht, den Zusammenhang der Merkmale p (in diesem Fall die Kennzahlen der Unternehmen) auf so wenige Faktoren wie möglich zu reduzieren.

Zu Beginn der PCA steht zumeist eine Mittelwertbildung der Merkmale j zu jedem Objekt i . Der Mittelwert kann aber auch als eine Linearkombination der Merkmalswerte aufgestellt werden [38]:

$$\bar{x}_i = \sum_{j=1}^p a_j x_{ij}. \quad (62)$$

Dabei ist im späteren Verlauf wichtig, die Merkmale zu zentrieren, d. h. jeden einzelnen Wert vom Mittelwert der eigenen Merkmalsreihe zu bereinigen. Um die optimalen Gewichte der Eigenvektoren $\mathbf{a}_1, \dots, \mathbf{a}_p$ ermitteln zu können, wird von nun an eine p -dimensionale Zufallsvariable $\mathbf{X}$ mit der Varianz $\text{Var}(\mathbf{X}) = \mathbf{\Sigma}$ betrachtet. Ziel ist es, die Linearkombination $\mathbf{a}_1^T \mathbf{X}$, welche unter der Nebenbedingung $\mathbf{a}_1^T \mathbf{a}_1 = 1$ die größte Varianz aufweist, zu finden. Dafür wird folgendes Maximierungsproblem gelöst [38]:

$$\max_a \mathbf{a}^T \mathbf{\Sigma} \mathbf{a}. \quad (63)$$

Durch die Lösung des Maximierungsproblems erhält man den Eigenvektor $\mathbf{a}_1$, welcher zum größten Eigenwert λ_1 der Kovarianz-Matrix $\mathbf{\Sigma} = \text{Var}(\mathbf{X})$ gehört. Analog bildet Eigenvektor $\mathbf{a}_2$, der zum zweitgrößten Eigenwert λ_2 gehört, die Gewichte der Linearkombination unter Berücksichtigung der größten Varianz aller Vektoren, welche orthogonal zum ersten Eigenvektor stehen, ab. Bei der empirischen Untersuchung wird die theoretische Kovarianz-Matrix $\mathbf{\Sigma}$ durch die empirische Kovarianz-Matrix $\mathbf{S}$ ersetzt. Des Weiteren werden in der empirischen Untersuchung die Eigenvektoren $\mathbf{g}$ und die Eigenwerte l betrachtet [12]. Die erste Hauptkomponente $y_{i,t}$ (ab hier wird diese einfachheitshalber als beobachteter Wert bezeichnet) des Unternehmens i zum Zeitpunkt t berechnet sich wie folgt [12]:

$$y_{i,t} = \mathbf{g}_{1,i}^T \mathbf{X}_{i,t}, \quad (64)$$

mit $\mathbf{g}_{1,i}$ als erster Eigenvektor der PCA und $\mathbf{X}_{i,t}$ als Vektor der standardisierten Kennzahlen des Unternehmens i zum Zeitpunkt t .

3.5.2 Saisonale Regression

Mit Hilfe der ermittelten Werte der PCA $y_{i,t}$, wird nun folgendes Zeitreihenmodell aufgestellt, welches die lineare Abhängigkeit von der Zeit impliziert:

$$y_{i,t} = \alpha_i + \beta_i \cdot t + \varepsilon_{i,t}, \quad (65)$$

wobei die Parameter α und β unbekannt sind. Die geschätzten Werte $\hat{y}_{i,t}$ der Zeitreihe werden nun durch eine lineare Regression ermittelt:

$$\hat{y}_{i,t} = \hat{\alpha}_i + \hat{\beta}_i \cdot t, \quad (66)$$

wobei der Niveauparameter $\hat{\alpha}_i$ und der Trendparameter $\hat{\beta}_i$ mit Hilfe der empirischen Kovarianz zwischen $y_{i,t}$ und t sowie der empirischen Varianz von t geschätzt wurden [39]. Um den tatsächlichen Verlauf der beobachteten Punkte besser nachbilden zu können, wird im Folgenden die Wertereihe durch einen Strukturbruch aufgeteilt und den Abschnitten jeweils eine Saisonfigur hinzugefügt. Es wird zunächst die saisonale Differenz eines jeden Monats auf Basis des Wertes des ersten Quartals errechnet. Es ergeben sich drei zusätzliche Werte $\delta_{i,k}$, die je nach Quartalszugehörigkeit k mit Hilfe von Dummy-Variablen $D_{k,t}$ in das Regressionsmodell eingefügt werden [39].

$$\hat{y}_{i,t} = \hat{\alpha}_i + \hat{\beta}_i \cdot t + \delta_{i,k} D_{k,t} \quad \text{für} \quad k \in \{2, 3, 4\}, \quad (67)$$

womit $D_{2,t}$ im zweiten Quartal den Wert eins annimmt, in allen anderen Quartalen den Wert null. Der δ_i -Wert für das erste Quartal befindet sich indirekt schon in der konstanten Variablen $\hat{\alpha}$. Würde man die vierte Dummy Variable (für Quartal eins) mit in das Modell aufnehmen, müsste das konstante Glied $\hat{\alpha}$ auf Grund von Kollinearität entfernt werden. Es ist zu beachten, dass die Saisonfiguren jeweils bis und nach dem Strukturbruch von Jahr zu Jahr konstant bleiben. Die Saisonfiguren $\delta_{i,k}$ des Unternehmens i im Quartal k werden dabei wie folgt ermittelt [39, 40]:

$$\bar{y}_{i,k} = \frac{1}{J} \sum_{j=1}^J y_{i,k,j} \quad \text{für} \quad k \in \{1, \dots, 4\} \quad (68)$$

$$\delta_{i,k} = \bar{y}_{i,k} - \bar{y}_{i,1}, \quad (69)$$

mit $y_{i,k,j}$ als beobachteter Wert des Quartals k im Jahr j des Unternehmens i . Durch einen Strukturbruch zum Zeitpunkt $t = t'$, welcher eine Änderung in Trend und Niveau nach sich zieht, wird die geschätzte Zeitreihe in zwei unabhängige Zeitreihen unterteilt [39]:

$$\hat{y}_{i,t} = (\hat{\alpha}_i + \hat{\beta}_i \cdot t + \delta_{i,k} D_{k,t}) \cdot q_1 + (\hat{\alpha}'_i + \hat{\beta}'_i \cdot t + \delta'_{i,k} D_{k,t}) \cdot q_2 \quad \text{für} \quad k \in \{2, 3, 4\},$$

$$\text{mit} \quad q_1 = \begin{cases} 1 & \text{für } t < t' \\ 0 & \text{sonst} \end{cases}, \quad q_2 = \begin{cases} 1 & \text{für } t \geq t' \\ 0 & \text{sonst.} \end{cases} \quad (70)$$

Die neu eingeführten Parameter $\hat{\alpha}'_i$, $\hat{\beta}'_i$ und $\delta'_{i,k}$, für das Modell nach dem Strukturbruch, unterliegen denselben Berechnungsvorschriften wie die Parameter vor dem Strukturbruch.

Zur Auffindung des jeweiligen Strukturbruches werden die Theorien von *Bai* (1994) angewendet [41]. Grundüberlegung ist, dass die Koeffizienten einer einfachen, linearen Regressionsgleichung von einem stabilen Regressionsverhältnis in ein anderes wechseln. Dabei werden die Strukturbrüche durch die Minimierung der Summe der quadrierten Residuen ermittelt [41].

3.5.3 Gewinnerwartung

Um letztendlich die Gewinnüberraschung eines Unternehmensberichts kategorisieren zu können, wird die Ausrichtung der Residuen $\epsilon_{i,t}$ der Regression beurteilt. Formel (71) gibt die Beurteilungsvorschriften an. Unterteilt wird genau genommen in positive und negative Nachrichten, wenn der beobachtete größer gleich, respektive kleiner als der geschätzte Wert ist.

$$\epsilon_{i,t} = y_{i,t} - \hat{y}_{i,t} \quad \begin{cases} \text{negative Nachricht} & \text{für } \epsilon_{i,t} < 0 \\ \text{positive Nachricht} & \text{für } \epsilon_{i,t} \geq 0 \end{cases} \quad (71)$$

3.6 Verfahren zu These 2 und 3

Die bisherigen Analysemethoden werden zum größten Teil zur Validierung der ersten Hypothese, also ob Aktienkurse mit instantanen Schocks auf die Veröffentlichung von Unternehmensberichten reagieren, genutzt. Mit Hilfe der folgenden Verfahren soll eine Auswertung zu den weiteren Hypothesen erfolgen, also inwieweit signifikante Reaktionen in den Aktienkursen bereits vor bzw. nach der Veröffentlichung von Unternehmensberichten nachzuweisen sind. Diesbezüglich wird zunächst die Koinzidenzanalyse eingeführt. Per Bootstrapping-Analyse und Monte-Carlo-Simulation werden Lagemaße und Vergleichswerte ermittelt.

3.6.1 Koinzidenzanalyse

Unter Zuhilfenahme der Koinzidenzanalyse wird in diesem Unterkapitel die Beziehung zwischen Berichtsveröffentlichungszeitpunkten und Kapitalmarktreaktion auf ein Weiteres untersucht. Die zugrundeliegende Theorie wurde *Donges et. al.* (2011) und *Donges et. al.* (2015) entnommen [42, 43]. Zunächst werden zwei Ereigniszeitreihen A und B definiert. Ereigniszeitreihe A impliziert die einzelnen Veröffentlichungszeitpunkte der Unternehmensberichte $\{t_1^A, \dots, t_{N_A}^A\}$ und Ereigniszeitreihe B als eine in Trends (Trendkomponente einer einfachen linearen Regression) $\{t_1^B, \dots, t_{N_B}^B\}$ eingeteilte Rendite-Zeitreihe. N_A und N_B ge-

ben dabei die Anzahl der Ereignisse an. Beide Ereignisreihen decken ein gewisses Zeitintervall der Länge $T = t_f - t_0$ ab, sodass $t_0 \leq t_1^A \leq \dots \leq t_{N_A}^A \leq t_f$ und $t_0 \leq t_1^B \leq \dots \leq t_{N_B}^B \leq t_f$ gilt. Daraus folgen die Ereignisraten $\lambda_A = N_A/T$ und $\lambda_B = N_B/T$.

Kernverfahren der Koinzidenzanalyse ist das Zählen von Übereinstimmungen der verschiedenen Ereigniszeitreihen. Nachfolgend wird also überprüft, ob Ereignisse der Reihe B die Ereignisse der Reihe A vorwegnehmen. Abbildung 5 verbildlicht die dazugehörige Vorgehensweise. Gegeben eines Ereignisses in der Ereignisreihe A (dunkelblauer Balken) ergeben sich, unter der Berücksichtigung einer zeitlichen Verschiebung τ und einer Fensterbreite ΔT , Koinzidenzen in Reihe B (dunkelrote Balken). Mehrere Koinzidenzen in einem Betrachtungsintervall, wie in Abbildung 5 der Fall ist, werden als eine einzige Übereinstimmung gezählt.




Abbildung 5: Stilisierte Aufbau einer Koinzidenzanalyse zwischen Ereignisreihe A und B mit Lag τ und Fensterbreite ΔT [43]

Eine instantane Koinzidenz liegt vor, wenn zwei Ereignisse t_i^A, t_j^B mit $t_j^B < t_i^A$ zeitlich enger zusammen liegen als die Fensterbreite ΔT , also:

$$t_i^A - t_j^B < \Delta T. \quad (72)$$

Im Gegensatz dazu steht die verzögerte Koinzidenz, welche als instantane Koinzidenz zwischen dem zeitlich verschobenen Ereignis $t_i^A - \tau$, mit $\tau \geq 0$, und Ereignis $t_j^B < t_i^A - \tau$ anzusehen ist. Formel (73) gibt diese Beziehung wieder.

$$(t_i^A - \tau) - t_j^B < \Delta T \quad (73)$$

Diese Vorschriften gehen davon aus, dass Ereignisse der Reihe B den Ereignissen vorge-

lagert sein müssen. Die Bedingung $|t_i^A - t_j^B| < \Delta T$ lockert diese Voraussetzung, sodass auch nachgelagerte Ereignisse der Reihe B betrachtet werden können. Diese Bedingung ist wichtig um die dritte Hypothese dieser Arbeit untersuchen zu können.

Es folgt die Berechnung der Koinzidenzraten zwischen zwei Ereigniszeitreihen. Koinzidenzraten zwischen zwei Ereignisreihen können auf zwei verschiedenen Art und Weisen berechnet werden. Zuerst wird die Vorläufer-Koinzidenzrate r_p betrachtet, bei der, wie der Name schon sagt, die Ereignisse der Reihe B als Vorläufer der Reihe A angenommen werden:

$$r_p(\Delta T, \tau) = \frac{1}{N_A} \sum_{i=1}^{N_A} \Theta \left[\sum_{j=1}^{N_B} \Theta((t_i^A - \tau) - t_j^B) \Theta(\Delta T - ((t_i^A - \tau) - t_j^B)) \right], \quad (74)$$

mit $\Theta(\cdot)$ als der Heaviside-Funktion. Die Vorläufer-Koinzidenzrate r_p gibt also das Verhältnis von A -Ereignissen an, welchen mindestens ein Ereignis der Reihe B vorhergeht. Die zweite Variante Koinzidenzraten berechnen zu können, ist die Auslöser-Koinzidenzrate r_t :

$$\begin{aligned} r_t(\Delta T, \tau) &= \frac{1}{N_B} \sum_{j=1}^{N_B} \Theta \left[\sum_{i=1}^{N_A} \Theta((t_i^A - \tau) - t_j^B) \Theta(\Delta T - (t_i^A - (t_j^B + \tau))) \right] \\ &= \frac{1}{N_B} \sum_{j=1}^{N_B} \Theta \left[\sum_{i=1}^{N_A} \Theta((t_i^A - \tau) - t_j^B) \Theta(\Delta T - ((t_i^A - \tau) - t_j^B)) \right]. \end{aligned} \quad (75)$$

Sie gibt den Anteil an B -Ereignissen an, welchen mindestens ein A -Ereignis nachfolgt. Der Unterschied zwischen diesen beiden Vorgehensweisen liegt klar in der Ausrichtung der Einflussnahme der Ereignisreihen.

3.6.2 Bootstrapping

Die Koinzidenzanalyse erfordert die Einteilung der Rendite-Zeitreihe in signifikante und nicht signifikante Trends. Für diese Einteilung wird eine Simulation mit Hilfe der *Bootstrap-Methode* durchgeführt, um Lagemaße der Verteilung schätzen zu können.

Die Bootstrap-Methode wurde von *Efron* (1979) aus der Jackknife-Theorie von *Quenouille* (1956) und *Tukey* (1958) heraus entwickelt [44, 45, 46]. Ziel ist es, aus einer einzelnen Stichprobe die zugrundeliegende Verteilungsfunktion schätzen zu können. Die Simulation der Bootstrap-Methode erfolgt durch Ziehen mit Zurücklegen.

Nachfolgend wird eine unbekannte Verteilungsfunktion F einer Zufallsvariablen $X_i = (X_1, X_2, \dots, X_n)$ mit Realisationen $x_i = (x_1, x_2, \dots, x_n)$ einer Stichprobe der Größe n be-

trachtet [44]:

$$X_i = x_i, \quad X_i \sim_{ind} F \quad \text{mit} \quad i = 1, 2, \dots, n. \quad (76)$$

Interessant ist nun eine gewisse Zufallsvariable bzw. Teststatistik $R(X_i, F)$, errechnet durch die Stichprobenverteilung R auf Basis der Realisationen x_i . Um diese durch die Bootstrap-Verteilung approximieren zu können wird zunächst eine Zufallsstichprobe der Größe n , welche der empirischen Verteilungsfunktion $\hat{F}$ folgt, gezogen [44]:

$$X_i^* = x_i^*, \quad X_i^* \sim_{ind} \hat{F} \quad \text{mit} \quad i = 1, 2, \dots, n. \quad (77)$$

Durch das wiederholte ziehen von N Bootstrap-Stichproben können verschiedene Realisationen von X_i^* generiert werden: $x_i^{*1}, x_i^{*2}, \dots, x_i^{*N}$. Das Histogramm der zugehörigen Werte $R(x_i^{*1}, \hat{F}), R(x_i^{*2}, \hat{F}), \dots, R(x_i^{*N}, \hat{F})$ kann als Approximation der Bootstrap-Verteilung genutzt werden. Schlussendlich können mit diesem Verfahren Lagemaße wie beispielsweise Quantile oder Perzentile der Verteilung geschätzt werden [44].

3.6.3 Monte-Carlo-Simulation

Um die Koinzidenzraten auf Signifikanz überprüfen zu können, müssen auf Grundlage einer Simulation Vergleichswerte ermittelt werden. Zum besseren Vergleich ist es wichtig, dass Permutationen anstelle von Bootstrap-Stichproben gezogen werden, damit der Parameter N_B (Anzahl signifikanter Trends) eine gleichbleibende Länge aufweist. Realisiert wird dies mittels *Monte-Carlo-Simulation*. Die Monte-Carlo-Simulation ist im Kern die Erzeugung von Zufallsobjekten mit der Hilfe eines Computers. Genau wie bei der Bootstrap-Methode ist das Ziel, eine unbekannte Verteilung schätzen zu können. Mittels einer relativ großen Anzahl an Wiederholungen soll sichergestellt werden, dass genügend große Mengen gezogen werden, um dem Gesetz der großen Zahlen zu entsprechen [47].

4 Literaturübersicht

Das folgende Kapitel gibt einen kurzen Überblick bisheriger wissenschaftlicher Arbeiten zur Thematik. Zuerst werden Ereignisstudien mit Fokus auf die Analyse der Gewinnüberraschung vorgestellt. Danach folgt ein Auszug wissenschaftlicher Arbeiten, welche sich mit der Familie der ARCH-Prozesse beschäftigten. In Kapitel 4.3 sind diese Studien zusammengefasst aufgelistet.

4.1 Bisherige Studien über Gewinneinfluss

Eine der ersten richtungsweisenden Ereignisstudien ist die Arbeit von *Ball/Brown* (1968) gewesen [48]. Ihre Vermutung besagte, dass auf positive (negative) Unternehmensmeldungen positive (negative) abnormale Renditen zu erwarten sind. Sie untersuchten dabei die Jahresabschlüsse von 291 an der NYSE (New York Stock Exchange) gehandelten Unternehmen. Im Fokus standen hier vor allem das Einkommen und der Gewinn je Aktie. Die Einteilung in positive und negative Meldungen wurde mittels eines Regressionsmodells, ähnlich dem dieser Arbeit, realisiert. Durch den Abnormal Performance Index konnte die Entwicklung der monatlichen Renditen zwölf Monate vor und sechs Monate nach dem Ereigniszeitpunkt bewertet werden. Ihre Vermutung wurde bestätigt, indem sie nachwiesen, dass sowohl vor, als auch nach dem Veröffentlichungszeitpunkt positive (negative) abnormale Renditen auf positive (negative) geprägte Jahresabschlüsse folgten [48].

Hagerman/Zmijewski/Shah (1984) untersuchten den Zusammenhang zwischen Gewinnmeldungen und Aktienkursen an Hand von Quartalsberichten und Jahresabschlüssen 215 US-amerikanischer Unternehmen, welche an der NYSE bzw. ASE (American Stock Exchange) gelistet waren [49]. Die Stichprobe umfasst 2189 Quartalsberichte und 404 Jahresabschlüsse in der Zeit von 1974 bis 1976. Mit Hilfe von täglichen Aktienkursen berechneten sie die abnormalen Renditen mittels eines mittelwertadjustierten Modells, des einfachen Marktmodells und des speziellen Marktmodells von *Scholes/Williams* (1977) [50]. Die Einteilung der Gewinnüberraschungen erfolgte, gemessen an ihrer Höhe, in 25 unterschiedliche Portfolios. Das erste Portfolio enthält die schlechtesten und Portfolio 25 die besten Gewinnnachrichten. Sie konnten nachweisen, dass eine Relation zwischen der Höhe der Gewinnüberraschung und der abnormalen Renditen besteht. Darüber hinaus gibt es eine größere Bindung zwischen den abnormalen Renditen und der Gewinnüberraschung des vierten Quartals als mit den Gewinnüberraschungen der Jahresabschlüsse. Hierbei hat die Wahl des Modells zur Marktbereinigung keinen Einfluss auf das Ergebnis [49].

Die Studie von *Röder* (1999) befasst sich mit den Ad-hoc-Meldungen deutscher Unternehmen [2]. Die Stichprobe umfasst in der Zeit von 1996 bis 1997 insgesamt 912 Mitteilungen von 335 Emittenten. Diese Meldungen werden in verschiedene Klassen, wie Gewinnmeldung, Führungswechsel oder Strategie, eingeteilt. Zur Einteilung in positive und negative Meldungen wird die Ausrichtung der Marktreaktion genutzt. Die Berechnung der abnormalen Renditen wird mittels der Marktwertadjustierung vorgenommen. Als Marktindex wird der DAX herangezogen. *Röder* kommt mit seiner Studie zu dem Schluss, dass von den Elementen der Zwischen- und Jahresberichte die Dividendenmeldungen die niedrigsten Kursreaktionen aufweisen. Darüber hinaus wiesen Meldungen zu Auftragseingängen und über einen Großaktionärswechsel die betragsmäßig größten abnormalen Renditen auf. Eine weitere Erkenntnis ist, dass die mittelstrenge Informationseffizienz, zumindest für Nebenwerte, abgelehnt werden kann. Der Markt nimmt die Information vorweg [2].

4.2 Studien mit Bezug auf ARCH-Modelle

Eine perfekte Überleitung der klassischen Ereignisstudien zu Studien, welche ARCH-Effekte mit in ihre Betrachtung nehmen, liefert die Arbeit von *Corhay/Tourani-Rad* (1996) [51]. Sie betrachteten neben dem klassischen Marktmodell ein weiteres, um GARCH-Prozesse erweitertes Marktmodell. Dabei untersuchten sie die Informationswirkung von Unternehmensveräußerungen niederländischer Unternehmen von 1989 bis 1993 mittels tagesbasierter Aktienkurse. Kern ihrer Untersuchung war der Vergleich der abnormalen Renditen, welche mit Hilfe dieser beiden Modelle berechnet wurden. Sie kamen zur Erkenntnis, dass das erweiterte dem klassischen Modell vorzuziehen ist, da die Parameter der Maximum-Likelihood-Methode effizienter sind als die, die mittels der Ordinate-Least-Squares-Methodik ermittelt wurden. Somit kann es zur Überschätzung beim Marktmodell von abnormalen Renditen im Ereigniszeitraum kommen. Eine Fehlinterpretation der Wirkung von Unternehmensveräußerungen auf den Kapitalmarkt sind die logische Konsequenz [51]. Diese Erkenntnisse wurden von *Pynönnen* (2005) gestützt [52].

Losgelöst der Betrachtung von Informationswirkungen untersuchten *Alberg/Shalit/Yosef* (2008) die Prognosegüte mittels verschiedener ARCH-Modelle [53]. Ihre Stichprobe umfasste 3058 tägliche Schlusskurse des TA25 Index von 1992 bis 2005 und 1911 Beobachtungen des TA100 Index von 1997 bis 2005. Die beiden Indizes repräsentieren die 25 (100) Unternehmen mit der höchsten Marktkapitalisierung, welche auf der Tel-Aviv Stock Exchange gehandelt wurden. Mittels dieser Stichprobe wurde die Volatilität für ein 30-Tages-Intervall prognostiziert. Durch verschiedene Testverfahren wurde die Prognosegüte der verschiede-

nen Modelle evaluiert. Das asymmetrische EGARCH-Modell bildete dabei die Volatilität am besten ab. Schlussfolgernd sollte also das EGARCH-Modell bei der Implementierung von Risiko-Strategien israelischer Unternehmen Anwendung finden [53].

4.3 Zusammenfassung

Tabelle 3: Übersicht der bisherigen Literatur mit Fokus auf verwendetem Modell, der Gruppenbildung und der abschließenden Erkenntnis

Studie	Modell & Stichprobe	Gruppenbildung	Erkenntnis
<i>Ball/Brown</i> (1968) [48] Jahresabschlüsse	Abnormal Performance Index (API) – monatliche Kurse US-amerikanischer Unternehmen 1957–1965	Einteilung in positive und negative Meldungen mittels Regressionsmodell	positive (negative) geprägte Kennzahlen führen zu positive (negative) abnormale Renditen
<i>Hagerman/Zmijewski/Shah</i> (1984) [49] Quartalsberichte Jahresabschlüsse	u. a. Marktmodell (4) – tägliche Kurse US-amerikanischer Unternehmen 1974–1976	Einteilung in 25 Portfolios nach Größe der Gewinnüberraschung mittels saisonalem Regressionsmodell	risikoadjustierte Aktienkurse folgen der Größenordnung nach quartalsweise eingeteilten Gewinnmeldungen
<i>Röder</i> (1999) [2] Ad-hoc-Mitteilungen	Marktadjustierung (3) – Marktindex: DAX – tägliche Kurse deutscher Unternehmen 1996–1997	Einteilung in positive und negative Nachrichten nach der Ausrichtung der Marktreaktion	Dividendenmeldungen weisen die geringsten Kursreaktionen aller Meldungen auf
<i>Corhay/Tourani-Rad</i> (1996) [51] Unternehmensveräußerungen	Marktmodell (4) und GARCH (1,1) angepasstes Marktmodell – Marktindex: CBS General Index – tägliche Kurse niederländischer Unternehmen 1989–1993	Vergleich des klassischen Marktmodells mit dem um GARCH-Effekte erweiterten Marktmodells	abnormale Renditen des Marktmodells sind überschätzt – GARCH-Marktmodell liefert effizientere Parameter
<i>Alberg/Shalit/Yosef</i> (2008) [53]	u. a. GARCH(1,1) & EGARCH(1,1) – tägliche Kurse israelischer Unternehmen von 1992–2005	Vergleich der Prognosegüte eines GARCH-Modells mit asymmetrischen Modellen	asymmetrische ARCH-Modelle liefern bei der Volatilitätsprognose bessere Ergebnisse (insb. EGARCH)

5 Ergebnisauswertung

Das folgende Kapitel enthält die Ergebnisse der statistischen Auswertungen unter Zuhilfenahme der Theorie aus dem dritten Kapitel. Zuerst werden die statistischen Eigenschaften untersucht und eine Auswertung der Volatilität im Ereignisfenster erstellt. Im zweiten Abschnitt werden mit Hilfe einer Ereignisstudie zur ersten Hypothese die Höhe der abnormalen Renditen analysiert. Abschließend folgen die Ergebnisse der Koinzidenzanalyse zur Beurteilung der zweiten und dritten Hypothese.

5.1 Nachweis statistischer Eigenschaften

Zu Beginn dieses Kapitels werden die in Kapitel 3.2 unterstellten statistischen Eigenschaften für die spezifischen Rendite-Zeitreihen dieser Arbeit überprüft. Außerdem wird mittels GARCH-Modellierung die geschätzte Volatilität mit der beobachteten verglichen und interpretiert. Abschließend werden diese Ergebnisse kritisch hinterfragt.

5.1.1 Stationarität, Leptokurtosis und Autokorrelation

Mit Hilfe des ADF-Tests aus Gleichung (17) wurden die in Tabelle 4 angegebenen Werte ermittelt. Bei der Größe dieser Stichproben liegt der kritische Wert der ADF-Statistik bei einem Signifikanzniveau von 1 % bei -3,43. Auf Grund der Sparsamkeit der Parametrisierung wurde Lag zwei gewählt, wobei der Umfang der Stichprobe sicherlich eine höhere Lag-Ordnung erfordert. Tests mit höheren Lag-Ordnungen zeigten aber, dass die Werte der ADF-Statistik immer noch zu einem hoch signifikant Ergebnis führten. *Cheung/Lai* (1995) zeigten zusätzlich, dass die kritischen Werte der ADF-Statistik den veränderten Lag-Ordnungen p angepasst werden müssen [54]. Da diese Anpassungen aber marginal erscheinen, gibt es keine Auswirkung auf diese Ergebnisse. Werte der Tabelle 4 liegen allesamt weit unter dem kritischen Wert, die Nullhypothese kann demnach verworfen werden. Wie schon vermutet, handelt es sich bei den untersuchten Rendite-Zeitreihen der Unternehmen um stationär geprägte Zeitreihen.

Tabelle 4: Ergebnisse des ADF-Tests der Rendite-Zeitreihen mit zeitlicher Verschiebung $p = 2$

	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
ADF	-35.86**	-37.30**	-36.30**	-38.78**	-36.92**	-35.34**	-28.29**	-31.42**	-34.79**

** hoch signifikant bei $\alpha = 0,01$

Tabelle 5 beinhaltet Kennzahlen zu statistischen Kennzahlen der Rendite-Zeitreihen in Prozent. Der Stichprobenumfang umfasst hierbei den gesamten Betrachtungszeitraum. Folgende Kennzahlen sind gegeben: der Mittelwert, das Minimum, das Maximum, die Varianz, die Standardabweichung, die Schiefe, die Kurtosis und die Jarque-Bera-Statistik. Der Mittelwert der Rendite-Zeitreihen liegt entweder exakt bei null oder mit einer geringen Abweichung nahe null. Dies unterstützt die These der Stationarität der Zeitreihe, schwingend um einen Mittelwert von null. Auffallend sind die hohen Extrema der Rendite-Zeitreihen. Eine tägliche Rendite von über 20 % bzw. unter -20 % ist wohl als sehr starke Anomalie einzuordnen. Diese extrem hohen Werte sind vorrangig in der Zeit der Weltwirtschaftskrise zu finden. Die Standardabweichung liegt bis auf die der PWO AG deutlich über 2 %, wobei die Renditen der Grammer AG mit einer Standardabweichung von 2,71 am meisten variieren.

Tabelle 5: Statistische Eigenschaften der Rendite-Zeitreihen im Betrachtungszeitraum mit Mittelwert, Minimum, Maximum und Standardabweichung in % , Varianz sowie der geschätzten Schiefe $\hat{S}$, geschätzten Kurtosis $\hat{K}$ und der Ergebnisse der Jarque-Bera-Teststatistik (JB)

	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
Mittelwert	0.04	0.00	0.06	0.03	0.05	0.05	-0.00	0.03	0.02
Minimum	-20.85	-15.72	-22.76	-14.12	-15.17	-15.60	-24.12	-19.95	-13.51
Maximum	17.96	19.43	23.89	13.86	20.94	18.46	18.15	20.57	10.18
Varianz	5.74	5.06	6.54	4.56	6.57	5.09	7.35	6.66	3.33
St.abw.	2.40	2.25	2.56	2.14	2.56	2.26	2.71	2.58	1.82
Schiefe	-0.39	0.20	0.19	0.09	0.10	0.26	-0.46	-0.06	-0.22
Kurtosis	7.53	5.43	9.23	3.71	4.90	5.54	7.39	6.28	6.18
JB	9477***	4892***	14096***	2278***	3974***	4457***	5918***	4425***	5535***

*** höchst signifikant mit $p < 0,001$

Mit Hilfe der Schiefe der Rendite-Zeitreihen können Aussagen über die Symmetrie der Verteilung gemacht werden. Weist eine spezifische Zeitreihe eine Schiefe von null auf, so folgt die Verteilung der Zeitreihe der Gauß'schen Normalverteilung. Liegt der Wert der Schiefe jedoch unter null, so ist die Verteilung, wie bei der Volkswagen, Grammer, ElringKlinger und PWO AG zu sehen, linksschief. Die Rendite-Zeitreihen der übrigen Unternehmen weisen, durch eine Schiefe größer null, eine rechtsschiefe Verteilung auf. Eine grafische Ermittlung der Schiefe erfolgt durch sogenannte Q-Q-Plots, siehe Abbildung 7.

Ebenfalls in Kapitel 3.2.1 thematisiert, weisen Verteilungen mit einem Kurtosis-Wert größer drei eine leptokurtische Verteilung auf. Eine leptokurtische Verteilung liegt demnach bei allen untersuchten Unternehmen vor. Dies wird durch den JB-Test bekräftigt. Der Wert der Teststatistik wird mit dem Wert der χ^2 -Verteilung mit zwei Freiheitsgraden verglichen. Wenn der Wert der JB-Statistik laut Formel (20) größer ist, kann die Nullhypothese der Normalverteilung höchst signifikant abgelehnt werden. Dies ist sehr deutlich bei allen untersuchten Unternehmen zu sehen.

Besonders anschaulich lässt sich das Phänomen der Leptokurtosis anhand des Vergleichs der Kerndichteschätzung mit der Normalverteilung darstellen. Abbildung 6 zeigt diesen Vergleich beispielhaft an Hand der Rendite-Zeitreihen der Leoni AG und der Bertrandt AG, alle weiteren Verteilungen sind Abbildung 22 zu entnehmen. Dabei wird die Kerndichte mit Hilfe des Epanechnikov-Kerns ermittelt und um eine der Rendite-Zeitreihen angepasste Normalverteilung ergänzt. Die Kerndichteschätzung liegt dabei, wie bei einer leptokurtischen Verteilung typisch, sowohl im Zentrum als auch an Abschlüssen über der Normalverteilung.




Abbildung 6: Vergleich der Kerndichteschätzung (rote Kurve) mit einem Epanechnikov-Kern und einer der Rendite-Zeitreihen angepassten Normalverteilung (blaue Kurve) exemplarisch für Leoni AG und Bertrandt AG

Mit Hilfe der Quantil-Quantil-Plots (Q-Q-Plots) in Abbildung 7 und 23 lässt sich die Nicht-Normalverteilung ebenfalls darstellen. Die Punkte einer Standardnormalverteilung

würden bei einem Q–Q–Plot genau auf bzw. nahe der rot eingezeichneten Winkelhalbierenden liegen. Die Punkte der hier dargestellten Q–Q–Plots liegen aber an den Enden weit ab der Winkelhalbierenden (Ausreißer), in einer S–förmigen Anordnung. Diese S–förmige Anordnung ist durch die Schiefe bestimmt (Unterschiede an beiden Enden) und gilt als ein typisches Zeichen für Leptokurtosis.




Abbildung 7: Q–Q–Plots der Rendite–Zeitreihen exemplarisch für VW AG und Daimler AG (Winkelhalbierende in rot eingezeichnet)

Tabelle 6 zeigt die Autokorrelationswerte erster Ordnung der Rendite–Zeitreihen über den gesamten Beobachtungszeitraum, aufgeteilt in einfache, absolute und quadrierte Renditen. Hierfür wurden die Berechnungsvorschriften aus der Gleichungsreihe (23) genutzt. Die Ergebnisse zeigen für alle Unternehmen eine Autokorrelation erster Ordnung nahe null an. Im Gegensatz dazu sind die Werte der Autokorrelation für die absoluten und quadrierten Renditen positiv und signifikant größer als null. Man kann hier von einer linearen Abhängigkeit in den Renditen ausgehen, d. h. auf kleine (große) absolute Renditewerte folgen tendenziell kleine (große) absolute Renditewerte. Das Ergebnis sind Intervalle von niedrigen Preisänderungen der Aktienwerte und Zeiten, die von erhöhter Volatilität geprägt sind. Diese Vermutung spiegelt sich auch in den visualisierten Rendite–Zeitreihen aus Abbildungen 15 bis 21 wieder.

Die Ergebnisse des Ljung–Box–Tests sind in Tabelle 7 zusammengefasst. Berechnet wurde die Teststatistik (24) mit jeweils 10, 20 und 30 Autokorrelationskoeffizienten unter Hinzu-

Tabelle 6: Geschätzte Autokorrelationswerte erster Ordnung der normalen Renditen $\hat{\rho}_1(R_t)$, der absoluten Renditen $\hat{\rho}_1(|R_t|)$ und der quadrierten Renditen $\hat{\rho}_1(R_t^2)$ über den gesamten Betrachtungszeitraum

	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
$\hat{\rho}_1(R_t)$	0.0307	0.0384	0.0426	0.0282	0.0198	0.0278	0.0150	0.0530	-0.0643
$\hat{\rho}_1(R_t)$	0.3112	0.2026	0.2818	0.1886	0.2553	0.2386	0.1953	0.1931	0.1827
$\hat{\rho}_1(R_t^2)$	0.4467	0.1834	0.2076	0.1392	0.2669	0.1728	0.1127	0.1239	0.1424

nahme der quadrierten Renditen der betrachteten Aktiengesellschaften. Die Nullhypothese besagt, dass kein signifikanter Zusammenhang zwischen den Zeitreihenwerten vorliegt, die Zeitreihe also weißes Rauschen darstellt. Mit Ausnahme weniger Ergebnisse aus Tabelle 7 kann diese Nullhypothese mindestens signifikant verworfen werden, sodass von einer Korrelation der Renditen untereinander ausgegangen werden kann.

Tabelle 7: Ljung–Box–Statistik der quadrierten Renditen über den gesamten Betrachtungszeitraum

	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
Q(10)	39.85***	68.18***	21.52*	36.57***	17.21	23.06*	12.80	29.70***	21.41*
Q(20)	57.54***	90.84***	40.64**	60.54***	40.22**	35.78*	28.97	47.89***	39.41**
Q(30)	79.87***	120.04***	50.23*	90.29***	52.97**	44.25*	52.63**	60.62***	51.08**

* signifikant mit $p < 0,05$

** hoch signifikant mit $p < 0,01$

*** höchst signifikant mit $p < 0,001$

Zusammenfassend kann festgestellt werden, dass die typischen Eigenschaften von Zeitreihen der Finanzmarktwirtschaft nachgewiesen werden konnten. Die Zeitreihen der Unternehmensrenditen sind demnach schwach stationär geprägt, ihre Verteilung folgt, bedingt durch eine gewisse Schiefe und Leptokurtosis, nicht der Normalverteilung und durch ihre Autokorrelation sind die einzelnen Werte jeweils voneinander abhängig.

5.1.2 Interpretation von Volatilität mittels GARCH-Prozess

Bevor eine Prognose der Volatilität in der Ereignisperiode mit der realisierten Volatilität verglichen werden kann, muss geprüft werden, ob ARCH-Effekte in den Rendite-Zeitreihen der verschiedenen Firmen vorliegen. Dazu wurde der LM-Test mit Hilfe der Teststatistik aus (50) angewandt und die Ergebnisse in Tabelle 8 zusammengefasst. Es wurde unter der

Annahme drei verschiedener Freiheitsgrade q getestet. Unter allen Umständen kann die Nullhypothese, dass keine ARCH-Effekte vorliegen, höchst signifikant abgelehnt werden.

Tabelle 8: Test auf ARCH-Effekte mittels LM-Test unter der Annahme verschieden langer Zeitverschiebungen q , Werte der F-Statistik über den gesamten Betrachtungszeitraum

q	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
10	1117.94***	666.10***	349.36***	467.46***	611.05***	306.92***	365.20***	352.24***	91.20***
20	1154.69***	926.49***	527.52***	571.37***	758.89***	330.99***	396.88***	447.95***	104.82***
30	1166.63***	971.92***	556.63***	593.85***	797.80***	349.98***	450.61***	475.16***	115.32***

*** höchst signifikant mit $p < 0,001$

Nachdem ARCH-Effekte nachgewiesen wurden, sind die Parameter der GARCH(1,1)-Modellierung gemäß Formel (53) der verschiedenen Rendite-Zeitreihen über den gesamten Beobachtungszeitraum in Tabelle 9 aufgeführt. Alle Parameter halten die Nichtnegativitätsbedingung ein. Überdies hinaus liegen alle Summen aus $\hat{\alpha}_1$ und $\hat{\beta}_1$ knapp unter eins. Beide Beobachtungen unterstützen die Vermutung der Stationarität der Rendite-Zeitreihen. Eine hohe Persistenz vergangener Schocks auf die Zeitreihe ist durch die Summenwerte nahe eins gegeben. Die in Klammern gegebenen t-Werte zeigen, dass die Parameter signifikant von null verschieden sind. Vor allem die Signifikanz von α_1 unterstreicht ebenso das Vorliegen von ARCH-Effekten, wie in Tabelle 8 nachgewiesen. Des Weiteren ist zu erkennen, dass der Parameter $\hat{\beta}_1$ wesentlich größere Werte als $\hat{\alpha}_1$ annimmt. Aus Gleichung (53) wird entnommen, dass α_1 für die Gewichtung unmittelbar vergangener Schocks ε_t und β_1 für die Dauer des Nachwirkens der Schocks verantwortlich ist. Demzufolge zieht ein wesentlich größeres β_1 eine langsame Rückkehr der bedingten Varianz σ_t^2 auf ein normales Niveau nach sich.

Tabelle 10 zeigt die Mittelwerte der geschätzten $\bar{\sigma}_{t,p}^{GARCH}$ und beobachteten $\bar{R}_{t,p}$ Volatilitäten in den Ereignisfenstern der jeweiligen Unternehmen. Das Ereignisfenster ist dabei $p = 7$ Tage lang – der Veröffentlichungstag des Unternehmensberichts zuzüglich drei vor- und nachgelagerter Tage. Zur Schätzung der bedingten Varianz gemäß Beziehung (53) wurde eine, der Ereignisperiode vorgelagerte, Schätzperiode von 100 Tagen genutzt. Ein jedes GARCH(1,1)-Modell wurde dann wiederum für die Prognose der bedingten Varianzen mit Hilfe der Formeln (54) und (55) genutzt. Die Aggregation und Mittelwertbildung erfolgt laut (56) und (57). Die realen Volatilitäten wurden mittels Formeln (58) und (59) direkt aus den Rendite-Zeitreihen berechnet. Ergänzt wurde Tabelle 10 weiterhin um einen

Tabelle 9: Parameter der GARCH(1,1)–Modellierung der Rendite–Zeitreihen über den gesamten Betrachtungszeitraum mit $\hat{\omega}$ als Konstante, $\hat{\alpha}_1$ als Schätzer der Wichtung vergangener Schocks und $\hat{\beta}_1$ als Wichtung vergangener Varianzen

	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
$\hat{\omega}$	7.91^{-6} (4.61)	6.16^{-6} (4.99)	7.20^{-6} (3.89)	2.44^{-6} (3.70)	8.72^{-6} (4.14)	1.99^{-5} (3.99)	6.86^{-6} (2.74)	1.63^{-5} (4.74)	5.67^{-5} (4.58)
$\hat{\alpha}_1$	0.080 (8.02)	0.067 (8.87)	0.087 (7.61)	0.055 (8.99)	0.053 (7.08)	0.112 (6.22)	0.059 (5.30)	0.069 (6.27)	0.129 (6.06)
$\hat{\beta}_1$	0.906 (78.73)	0.919 (102.72)	0.902 (69.29)	0.940 (147.32)	0.932 (92.27)	0.852 (34.28)	0.933 (72.03)	0.906 (63.71)	0.707 (13.55)
$\hat{\alpha}_1 + \hat{\beta}_1$	0.986	0.986	0.989	0.995	0.984	0.964	0.992	0.974	0.836

Vergleichswert der Volatilität aus der Stichprobe $\bar{\sigma}_{t,p}^*$. Dabei wurden gemäß der Bootstrap–Methode aus der gesamten Rendite–Zeitreihe zufällig 1000 p –lange Intervalle gezogen und analog zur Berechnung der beobachtete Volatilität im Ereignisfenster weiter verfahren.

Tabelle 10: Prognostizierte $\bar{\sigma}_{t,p}^{GARCH}$ und beobachtete Volatilität $\bar{R}_{t,p}$ in der Ereignisperiode, ergänzt um einen durch eine Simualtion ermittelten Durchschnitt der Volatilität $\bar{\sigma}_{t,p}^*$ der Renditereihe als Referenz

in Prozent	VOW3	DAI	CON	BMW	LEO	BDT	GMM	ZIL2	PWO
$\bar{\sigma}_{t,p}^*$	5.36	5.15	5.74	4.93	5.87	5.24	6.32	5.88	4.32
$\bar{\sigma}_{t,p}^{GARCH}$	6.40	5.51	6.74	5.22	6.37	5.71	7.41	6.25	4.93
$\bar{R}_{t,p}$	6.73	5.90	6.44	5.76	7.10	5.83	5.91	7.65	5.04
$\bar{R}_{t,p} - \bar{\sigma}_{t,p}^*$	1.37	0.75	0.71	0.83	1.23	0.59	-0.41	1.77	0.72
$\bar{R}_{t,p} - \bar{\sigma}_{t,p}^{GARCH}$	0.33	0.39	-0.30	0.53	0.72	0.12	-1.50	1.40	0.12

Die beobachteten und geschätzten Volatilitäten im Ereignisfenster liegen relativ eng beisammen. Sonderfälle bilden hier die Volatilität der Grammer AG, welche mit 1,50 % überschätzt wird und die der ElringKlinger AG, die mit 1,40 % unterschätzt wird. Ansonsten gibt die Prognose mittels eines GARCH(1,1)–Prozesses eine Volatilität nicht erheblich abweichend der beobachteten Volatilität an. Generell liegen die geschätzten Werte nur bei der Continental AG und bei der Grammer AG über den beobachteten Werten. Im Gegensatz dazu nimmt die Differenz aus beobachteten Volatilitäten der Ereignisfenster und der zufälligen Intervalle größere Werte an. Man kann also davon ausgehen, dass ein Unterneh-

mensbericht Auswirkungen auf die Höhe der Volatilität der Aktienkurse zum Zeitpunkt der Veröffentlichung hat.

5.1.3 Kritische Würdigung

Generell anzumerken ist, dass eine Modellierung mittels GARCH-Prozessen mit einer Schätzperiode, welche 100 Werte umfasst, kritisch zu sehen ist. Tendenziell werden dazu weitaus mehr Werte benötigt. Bei der Verwendung eines größeren Umfangs der Schätzperiode verzerren überlappende Ereignisse dann aber die Prognose. Weiterhin kann bei den einzelnen Modellierungen nicht sichergestellt werden, dass die Voraussetzungen eines GARCH-Prozesses eingehalten werden können (Nichtnegativitätsbedingungen, Bedingung aus Gleichung (52)). Demnach können einzelne Werte das Ergebnis verfälschen. Schätzperioden, bei denen die GARCH-Modellierung Parameterwerte von $\alpha_1 = 0$ und $\beta_1 = 1$ ergaben, wurden wegen auftretender Berechnungsfehler nicht berücksichtigt.

Die beobachtete Volatilität lässt sich indes nur schwer von täglichen Aktienkursen als Datengrundlage abbilden. Angebrachter wäre es hier, die Volatilität im Intraday-Handel zu analysieren, da es bei täglichen Schlusskursen natürlich zu einer Volatilität von null kommen kann, wenn die Schlusskurse aufeinanderfolgender Handelstage denselben Wert aufweisen, obwohl die Intraday-Volatilität eventuell extrem hoch ausfiel.

5.2 Einfluss des Gewinns

Nachdem festgestellt wurde, dass die Volatilitäten der Aktienkurse im Ereignisfenster erhöht sein können, stellt sich nun die Frage, ob sich die Informationen aus einem Unternehmensbericht in positive oder negative Richtung auf die Renditen auswirken. Dazu wurde die in Kapitel 2.2.2 eingeführte Ereignisstudie angewendet.

5.2.1 Vorgehen

Bei der Analyse zur ersten Hypothese wurden die abnormalen Renditen im Ereignisfenster mit Hilfe des einfachen Marktmodells (5) berechnet. Die Nullhypothese besagt, dass die Aktienkurse nicht mit instantanen Schocks auf die Veröffentlichung von Unternehmensberichten reagieren. Mittels den Formeln (12), (13) und (14) wurde hinsichtlich der Unternehmen (gesamt, Hersteller, Zulieferer) und des Nachrichtentyps (gesamt, positiv und negativ) aggregiert.

Die ersten drei Eigenvektoren der PCA über die Kennzahlen werden exemplarisch für

Tabelle 11: Übersicht der ersten drei Eigenvektoren $\mathbf{g}_{VOW3,1}$, $\mathbf{g}_{VOW3,2}$ und $\mathbf{g}_{VOW3,3}$ der PCA der Kennzahlen aus Kapitel 2.1.2, exemplarisch an Hand der Volkswagen AG, komplettiert durch die jeweilige Varianzerklärung

Kennzahl	$\mathbf{g}_{VOW3,1}$	$\mathbf{g}_{VOW3,2}$	$\mathbf{g}_{VOW3,3}$
Absatz	0.419	0.067	0.311
Umsatzerlös	0.422	0.066	0.295
Bruttoergebnis	0.430	0.047	0.238
EBIT	0.413	-0.010	0.214
EBT	0.387	-0.006	-0.563
Gewinn	0.372	-0.032	-0.625
Cashflow	-0.057	0.994	-0.073
Varianzanteil	0.727	0.142	0.106

die Analyse zur Volkswagen AG in Tabelle 11 aufgeführt. Der Varianzanteil des ersten Eigenvektors $\mathbf{g}_{VOW3,1}$ liegt bereits bei ca. 72,7 %, der kumulierte Anteil der ersten drei von sieben Eigenvektoren liegt bei 97,5 %. Der Varianzanteil der restlichen Eigenvektoren ist demnach vernachlässigbar. Wenn der erste Eigenvektor eine zufriedenstellende Erklärung der Varianz der Kennwerte liefert, wird mit der Berechnung der Werte für die Zeitreihe gemäß Gleichung (64) fortgefahren. Wenn dies nicht der Fall ist, wird die Berechnung der beobachteten Werte (64) um eine oder mehrere nachfolgende Hauptkomponenten additiv erweitert.

Der erste Eigenvektor $\mathbf{g}_{VOW3,1}$ aus Tabelle 11 kann wie folgt interpretiert werden: da die Ähnlichkeit der Eigenschaften der ersten sechs Kennzahlen (vgl. Kapitel 2.1.2) durch die Gleichwertigkeit der zugehörigen Werte des ersten Eigenvektors unterstrichen wird und zudem noch ein starker Kontrast zum Cashflow auffällt, kann $\mathbf{g}_{VOW3,1}$ als „Gewinnfaktor“ betitelt werden. Der zweite Eigenvektor $\mathbf{g}_{VOW3,2}$ kann sehr ähnlich interpretiert werden, wobei der Kontrast ein noch viel höheres Ausmaß annimmt, daher auch der resultierende Unterschied in der Varianzerklärung.

Die direkte Gegenüberstellung der ersten drei Hauptkomponenten der Volkswagen AG (die zweite und dritte Hauptkomponente wird analog der ersten aus Gleichung (64) berechnet), wird in Abbildung 8 verbildlicht. Die blauen Punkte repräsentieren dabei die skalierten Werte vor, die roten gleichermaßen die nach dem Strukturbruch wie in Kapitel 3.5.2 beschrieben. Bei den Grafiken, welche die erste Hauptkomponente abbilden, ist eine stark

abgrenzende Gruppierung zu sehen. Diese ist wiederum ein starkes Kennzeichen des Strukturbruchs. Die Aufreihung der Eigenwerte l komplettiert Abbildung 8. Abbildungen 24 bis 31 zeigen analog Abbildung 8 die Auswertungen zur PCA aller weiteren Unternehmen.




Abbildung 8: Exemplarische Übersicht der PCA der Volkswagen AG (Werte skaliert) – Gegenüberstellung der ersten drei Hauptkomponenten sowie Darstellung der Eigenwerte – blaue Punkte symbolisieren Werte vor und rote Punkte Werte nach dem Strukturbruch [12]

Von nun an werden die beobachteten Werte $y_{i,t}$ eines Unternehmens i , ermittelt durch Formel (64), betrachtet. Zusätzlich wurde diese Reihe mittels einer saisonalen Regression, inklusive Strukturbruchanalyse laut Gleichung (70), geschätzt. Abbildung 9 zeigt die zeitlichen Verläufe der beobachteten $y_{i,t}$ (schwarz) und geschätzten $\hat{y}_{i,t}$ (rot) Werte am Beispiel der BMW AG und der Daimler AG. In Abbildung 32 sind alle weiteren Zeitverläufe der restlichen Unternehmen abgebildet. Ein blauer Punkt signalisiert den Zeitpunkt des Strukturbruchs. Die Regressionsfunktionen der dargestellten Unternehmen sehen wie folgt aus:

$$\begin{aligned} \hat{y}_{BMW,t} = & (-1.46 - 0.01t + 0.86D_{2,t} - 0.15D_{3,t} - 0.09D_{4,t}) \cdot q_1 \\ & + (1.12 + 0.15t + 1.19D_{2,t} - 0.38D_{3,t} + 0.08D_{4,t}) \cdot q_2, \end{aligned} \quad (78)$$

$$\begin{aligned} \hat{y}_{DAI,t} = & (1.73 - 0.04t + 1.98D_{2,t} + 0.11D_{3,t} + 0.15D_{4,t}) \cdot q_1 \\ & + (-3.42 + 0.08t + 1.04D_{2,t} + 0.67D_{3,t} + 1.02D_{4,t}) \cdot q_2, \end{aligned} \quad (79)$$

mit $t'_{BMW} = 39$ und $t'_{DAI} = 28$, alle weiteren Regressionsfunktionen sind den Gleichungen (80) bis (86) zu entnehmen. In den vorliegenden beiden Regressionsfunktionen fällt der

Betrag des zweiten Quartals $\delta_{i,2}$ bzw. $\delta'_{i,2}$ als markant größer als alle anderen auf. Die Parameter des zweiten, dritten und vierten Quartals geben die Abweichungen der saisonalen Einflüsse zur Konstanten an, welche den Einfluss des ersten Quartals abbildet. Das zweite Quartal weicht also besonders stark (in positiver Richtung) von den Werten des ersten Quartals ab. Eine Besonderheit beinhaltet der Zeitreihenverlauf der Daimler AG. Der Strukturbruch ist nicht als Einbruch, verursacht durch die Weltwirtschaftskrise, sondern der Abspaltung der Chrysler Firmenteile zuzuschreiben [57].




Abbildung 9: Darstellung des zeitlichen Verlaufs der beobachteten Werte (schwarz) am Beispiel der BMW AG und der Daimler AG inklusive saisonaler Regression (rot) mit Strukturbruch (blauer Punkt)

Abschließend wird das Residuum $\epsilon_{i,t}$ nach Gleichung (71) genutzt, um abschätzen zu können, ob der jeweilige Bericht als positiv oder negativ charakterisiert werden kann. Vermutung: da das zweite Quartal ein klassisch starkes, durch hohe Umsätze geprägtes Quartal in der Automobilwirtschaft ist, werden dort die höchsten abnormalen Renditen zu erwarten sein.

5.2.2 Ergebnisse

Der nachfolgenden Tabelle 12 sind die abnormalen Renditen am Ereignistag selbst zu entnehmen. Zusätzlich wurden diese quartalsweise nach Berichtszeitpunkt aggregiert. Ferner wurde mittels t-Test (15) auf Signifikanz geprüft und Werte mit dem jeweiligen Signifikanzniveau per Stern gekennzeichnet.

Tabelle 12: Übersicht der abnormalen Renditen am Ereignistag $aR_{i,0}$, unterteilt nach Quartal sowie Firmenzugehörigkeit und Ausrichtung der Gewinnüberraschung mit jeweiligen Stichprobenumfang N

	aR Werte in Prozent	alle			Hersteller ¹			Zulieferer ²		
		alle	pos	neg	alle	pos	neg	alle	pos	neg
Alle	aR	0.21	0.33	0.12	0.38*	0.21	0.54*	0.12	0.40	-0.14
	N	478	242	236	175	86	89	303	156	147
1. Quartal	aR	-0.01	0.04	-0.06	0.42	0.30	0.53	-0.26	-0.10	-0.42
	N	125	63	62	46	23	23	79	40	39
2. Quartal	aR	0.02	0.08	-0.04	0.04	0.05	0.02	0.01	0.09	-0.07
	N	116	57	59	43	21	22	73	36	37
3. Quartal	aR	0.77*	1.10**	0.47	0.91*	0.55	1.22	0.69	1.41**	0.03
	N	118	56	62	43	20	23	75	36	39
4. Quartal	aR	0.08	0.17	-0.02	0.15	-0.03	0.33	0.05	0.27	-0.26
	N	119	66	53	43	22	21	76	44	32

¹ BMW AG (ST), Daimler AG & Volkswagen AG (VZ)

² Bertrandt AG, Continental AG, ElringKlinger AG, Grammer AG, Leoni AG & PWO AG

* signifikant mit $p < 0,05$

** hoch signifikant mit $p < 0,01$

Die hervorgehobenen Werte in Tabelle 12 sind wie folgt zu lesen: Der Durchschnitt der abnormalen Renditen am Veröffentlichungstag aller negativ geprägten Gewinnmitteilungen des ersten Quartals der Hersteller (23 Meldungen) beträgt 0,53 %. Die größten signifikanten abnormalen Renditen sind bei der Veröffentlichung des Neun-Monatsberichts vorzufinden. Die Vermutung aus dem vorhergehenden Kapitel, dass die größten Renditen im zweiten Quartal zu erwarten sind, kann verworfen werden. Die Stärke des zweiten Quartals der Automobilwirtschaft scheinen die Anleger mit in ihre Investitionsentscheidung einzubeziehen, sodass entweder dieser Gewinnüberschuss gegenüber den anderen Berichtszeitpunkten keine Überraschung mehr darstellt und, oder gerade deshalb, bereits weit vor dem Ereignisfenster investiert wird.

Auch eine Unterscheidung zwischen positiver und negativer Gewinnmeldung kann nur an Hand des dritten Quartals handfest interpretiert werden, da nur hier die Werte weit genug voneinander abweichen. Wirkt sich eine positive im Gegensatz zu einer negativen Gewinnmeldung des dritten Quartalsbericht der Zulieferer auf eine signifikante abnormale Rendite von 1,41 % zu einer vernachlässigbaren abnormalen Rendite von 0,03 % aus, kehrt sich dieses Phänomen bei den Herstellern um. Hier sind die abnormalen Renditen mit 1,22 %

bei einer negativen Gewinnmeldung größer als bei einer positiven mit 0,55 %. Es ist zu vermuten, dass Investoren vielmehr die Chance als das Risiko in einer negativen Gewinnmeldung der großen Automobilhersteller sehen. Genau spiegelbildlich verhält es sich mit den verhältnismäßig kleinen Zulieferunternehmen.

Tabelle 13: Übersicht der abnormalen Renditen $aR_{i,t}$, und kumulierten abnormalen Renditen $caR_{i,\tau}$, rund um den Ereignistag $t = 0$ mit $t \in \{-3, \dots, 3\}$, eingeteilt nach Firmenzugehörigkeit und Art der Gewinnüberraschung mit jeweiligen Stichprobenumfang N

Werte in	alle			Hersteller			Zulieferer		
Prozent	alle	pos	neg	alle	pos	neg	alle	pos	neg
N	478	242	236	175	86	89	303	156	147
aR_{-3}	-0.06	-0.41	0.29*	-0.21	-0.70	0.26	0.03	-0.25	0.31
aR_{-2}	-0.01	-0.04	0.02	-0.04	-0.16	0.09	0.00	0.03	-0.02
aR_{-1}	0.27*	0.37*	0.16	0.14	0.35	-0.06	0.34*	0.39*	0.30
aR_0	0.21	0.33	0.12	0.38*	0.21	0.54*	0.12	0.40	-0.14
aR_1	-0.04	0.07	-0.15	0.07	0.27	-0.12	-0.10	-0.04	-0.17
aR_2	-0.25	-0.28*	-0.21	-0.46	-0.07	-0.83	-0.12	-0.40*	0.17
aR_3	0.12	0.04	0.21	-0.09	0.18	-0.36	0.25*	-0.03	0.55
$caR_{(-3,-1)}$	0.19	-0.07	0.48	-0.11	-0.52	0.28	0.37	0.17	0.59
$caR_{(1,3)}$	-0.16	-0.17	-0.15	-0.48	0.38	-1.31	0.02	-0.47	0.56

* signifikant mit $p < 0,05$

Tabelle 13 zeigt die abnormalen Renditen in der Ereignisperiode je Tag und zusätzlich die kumulierten abnormalen Renditen für drei Tage vor dem und drei Tage nach dem Ereignis. Der hervorgehobene Wert zeigt beispielsweise, dass der Durchschnitt der kumulierten abnormalen Rendite im Intervall drei Tage vor der Veröffentlichung aller positiv geprägter Meldungen der Hersteller -0,52 % beträgt. Der Stichprobenumfang dieser Gruppe umfasst 86 Meldungen. Eine Signifikanzprüfung wurde auch hier mittels t-Test gemäß Teststatistik aus Formel (15) realisiert. Signifikante abnormale Renditen sind vor allem bei der negativen Gewinnmeldung der Hersteller am Ereignistag aR_0 und bei der positiven Gewinnmeldung der Zulieferer am Tag vor der Bekanntgabe aR_{-1} auszumachen. Dies deckt sich zum Teil mit der Interpretation der abnormalen Renditen in Tabelle 12. Der Großteil der anderen abnormalen Renditewerte weisen indes keine Signifikanz auf. Es ist zu schlussfolgern, dass signifikante abnormale Renditen, gesetzt den Fall sie treten auf, entweder ein Tag vor oder am Ereignistag selber auftreten.

5.2.3 Kritische Würdigung

In den bisherigen Studien (Kapitel vier) konnten signifikante abnormale Renditen am Veröffentlichungstag von Gewinnmeldungen nachgewiesen werden. Die Gründe, warum in dieser Arbeit die abnormalen Renditen nicht signifikant genug erscheinen, können vielfältig sein. Zuerst einmal ist der Stichprobenumfang bei den unterschiedlichen Unterkategorien teilweise zu klein. Des Weiteren ist die Einteilung zwischen positiver und negativer Gewinnmeldung schwierig, da das angewendete Regressionsmodell mit Saisonkomponente, also die Ausrichtung der Residuen, nicht die realen Investitionsentscheidungen der Investoren abbildet. Überdies hinaus ist die Gewinnüberraschung nicht der einzige Faktor, der Handlungsentscheidungen auslöst. Eine Vielzahl andere Faktoren können hier Einfluss auf die Entscheidung nehmen. Auch ist der Grundgedanke, dass auf positive (negative) Gewinnüberraschungen positive (negative) Renditen folgen, eventuell etwas zu naiv formuliert. Investoren könnten auch die Chance in einer negativen Gewinnmeldung sehen. Erschwerend kommt hinzu, dass die gewählten Kennzahlen relativ einseitig im Hinblick auf den Faktor „Gewinn“ geprägt sind. Zu guter Letzt wird angemerkt, dass keines der vorgestellten Marktmodelle das reale Marktgeschehen exakt abbilden kann. Somit verbleibt bei der Prognose der Renditen des Marktindex bei einer Ereignisstudie immer ein gewisser Schätzfehler.

5.3 Ergebnisse der Koinzidenzanalyse

Im letzten Abschnitt dieses Kapitels folgen nun die Ergebnisse der Untersuchung der Koinzidenzanalyse mit Bezug zur zweiten und dritten Hypothese. Im Grunde genommen soll folgende Fragestellung beantwortet werden: Gegeben einem Berichtszeitpunkt, wie wahrscheinlich ist es, vorher oder nachher einen signifikanten Trend in den Rendite-Zeitreihen zu finden?

5.3.1 Vorgehen

Abbildung 10 zeigt den zeitlichen Verlaufs des Aktienkurses und der Renditen des DAX-Sector Auto Performance, welcher in dieser Arbeit als Marktindex fungiert. Symbolisch für alle anderen Rendite-Zeitreihen zeigt dieser ein Intervall erhöhter Volatilität im Bereich der Wirtschaftskrise 2008/2009. Da in diesem Bereich eine erhöhte Anzahl signifikanter Trends zu erwarten ist, wurden die Rendite-Zeitreihen aller Unternehmen und des Marktindex für diese Analyse um dieses Zeitintervall bereinigt. Damit wird sichergestellt, dass

dieser stark abweichende Abschnitt keinen Einfluss auf die Signifikanzprüfung der Trends der restlichen Rendite-Zeitreihe nimmt. Danach erfolgt die Marktberreinigung mit Hilfe der Marktadjustierung aus Gleichung (3). Die Marktadjustierung hat hier den entscheidenden Vorteil, dass nicht nur die abnormalen Renditen im Ereignisfenster, sondern der kompletten Zeitreihe berechnet werden können. Dies ist für die weitere Betrachtung essentiell.




Abbildung 10: Aktienkurs (oben) und zugehörige Rendite (unten) des DAXSector Auto

Nun werden mit Hilfe einer einfachen Regression Trends der Länge k der abnormalen Rendite-Zeitreihe entlang berechnet. Diese Trendreihe wurde bereits in Kapitel 3.6.1 als Ereignisreihe B der Koinzidenzanalyse definiert. Um die Trends der beobachteten Zeitreihe auf Signifikanz überprüfen zu können, wird mittels Bootstrap-Methodik eine Zufallsstichprobe der Länge k aus der abnormalen Rendite-Zeitreihe gezogen und deren Trend berechnet. Dieser Vorgang wird 1000-mal wiederholt. Das 5. & 95. Perzentil dieser Bootstrap-Verteilung wird als Signifikanzniveau zur Überprüfung der Signifikanz der Trendreihe genutzt. Die Ereignisreihe B wird somit in signifikante und nicht signifikante Trends eingeteilt.

Anschließend erfolgt die Ermittlung der Anzahl an Koinzidenz zwischen beobachteter Ereignisreihe A (Veröffentlichungszeitpunkte) und der beobachteten Ereignisreihe B , sowie die Berechnung der Vorläufer-Koinzidenzrate r_p nach Gleichung (74). Diese Berechnung wird einmal für die Intervalle vor und nach dem Veröffentlichungszeitpunkt durchgeführt,

τ wird dabei auf null gesetzt. Da die Rendite-Zeitreihe in Trends der Länge k diskretisiert wird, ist ΔT als Anzahl der nicht überlappenden Trends aufzufassen.

Um die beobachteten Koinzidenzraten auf Signifikanz überprüfen zu können, erfolgt hier eine Monte-Carlo-Simulation. Dabei werden die Koinzidenzen zwischen einer Permutation der Ereignisreihe B und der unveränderten Ereignisreihe A gezählt. Diese Methodik wird 1000-mal wiederholt und ihre relative Häufigkeitsverteilung notiert. Diese Verteilung ist am Beispiel der Volkswagen AG in Abbildung 11 abgebildet. Der Schnittpunkt der aufsummierten Häufigkeitsverteilung mit dem 95. Perzentil ergibt den Vergleichswert zur beobachteten Anzahl an Koinzidenzen. Die Verteilung der Simulation weist dabei in der ersten Hälfte höhere Werte als die angepasste Poisson-Verteilung auf. Nach dem Maximum fällt sie im Gegensatz dazu schneller wieder ab.




Abbildung 11: Koinzidenzen der Simulation für ein 7-Tages-Intervall gleichermaßen vor und nach Veröffentlichungszeitpunkt der Unternehmensberichte der Volkswagen AG mit $\Delta T = 1$ ergänzt um eine der Koinzidenzverteilung angepasste Poisson-Verteilung zum Vergleich

Um die zugehörige Koinzidenzrate zu ermitteln, wird laut Gleichung (74) die Anzahl an

Koinzidenzen durch die Anzahl der Ereignisse N_A dividiert. Auf Grund der diskreten Natur dieses Tests kann eine Koinzidenzrate, welche größer gleich der Koinzidenzrate des 95. Perzentil der Simulation ist, als signifikant eingeordnet werden.

5.3.2 Ergebnisse

Die Ergebnisse der Koinzidenzanalyse der Volkswagen AG sind in Tabelle 14 dargestellt. Die Vorläufer Koinzidenzrate r_p wurde dabei jeweils für verschiedene Kombinationen aus Intervallbreite k in Tagen und Anzahl zu betrachtender Intervalle ΔT berechnet. Die Ergebnisse der Koinzidenzanalyse der weiteren Unternehmen sind in den Tabellen 15 bis 22 angegeben.

Tabelle 14: Ergebnisse der Koinzidenzanalyse der Volkswagen AG mit $N_A = 52$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.115	0.192	0.173	0.212	0.269	0.288	0.327	0.327	0.385	731	86
6	0.096	0.115	0.135	0.154	0.192	0.231	0.192	0.212	0.308	609	55
7	0.115	0.308	0.192	0.192	0.327	0.327	0.269	0.385	0.423	522	70
8	0.077	0.135	0.135	0.135	0.192	0.250	0.192	0.231	0.346	457	45
9	0.058	0.173	0.135	0.077	0.192	0.231	0.135	0.250	0.308	406	36
10	0.038	0.173	0.135	0.115	0.192	0.231	0.173	0.250	0.308	365	32
11	0.096	0.231	0.154	0.135	0.269	0.269	-	-	-	332	37
12	0.000	0.077	0.135	0.038	0.135	0.212	-	-	-	304	26
13	0.077	0.192	0.173	0.173	0.250	0.288	-	-	-	281	33
14	0.096	0.173	0.154	0.173	0.173	0.250	-	-	-	261	28
15	0.038	0.173	0.135	0.058	0.192	0.212	-	-	-	243	21
16	0.077	0.096	0.115	-	-	-	-	-	-	228	19
17	0.096	0.096	0.154	-	-	-	-	-	-	215	22
18	0.038	0.058	0.096	-	-	-	-	-	-	203	14
19	0.038	0.096	0.115	-	-	-	-	-	-	192	16
20	0.000	0.096	0.077	-	-	-	-	-	-	182	10

Auffällig ist, dass besonders viele signifikante Koinzidenzraten im Intervall direkt vor bzw. nach dem Ereignis $\Delta T = 1$ ermittelt wurden. Infolgedessen wurden diese Ergebnisse in Abbildung 12 für die Volkswagen AG und Abbildungen 33 bis 40 für alle weiteren Unternehmen ergänzend grafisch dargestellt. Dabei zeigen die Rendite-Zeitreihen der Volkswagen AG, der ElrinKlinger AG und der Bertrandt AG besonders viele signifikante Koinzidenzraten in diesem Bereich. Könnte man noch bei der Bertrandt AG und der ElrinKlinger AG von einer zu groben Bereinigung der Rendite-Zeitreihen mittels der Marktadjustierung ausgehen (mittelständige Unternehmen sind auf Grund ihrer kleineren Marktkapitalisierung im Marktindex schwächer repräsentiert), ist diese Fehlermöglichkeit bei der Rendite-Zeitreihe der Volkswagen AG weitaus geringer. Auch das Multiple-Testing-Problem, welches postuliert, dass bei einem 5 %-Konfidenzlevel, wie hier gegeben, auch 5 % falsch positive Ergebnisse zu erwarten sind, kann durch das Auftreten von mehreren signifikanten Koinzidenzraten ausgeschlossen werden. Es kann demnach von einem signifikanten Zusammenhang zwischen signifikanten Trends und Berichtszeitpunkten der Unternehmen ausgegangen werden.




Abbildung 12: Koinzidenzanalyse der Volkswagen AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an

Bleibt das Phänomen zu klären, warum besonders viele signifikante Koinzidenzraten nach dem Veröffentlichungszeitpunkt auftreten. Aus wirtschaftspsychologischen Erwägungen ist eher eine Vorwegnahme der Unternehmens-Performance in den Aktienkursen zu erwart-

ten. Ein Grund dafür könnte der sogenannte *Post Earnings Drift* sein, welcher schon von *Ball/Brown* (1968) dokumentiert wurde [48]. Es wird davon ausgegangen, dass in der Zeit nach dem Auftreten positiver (negativer) Gewinnüberraschungen weiterhin positive (negative) abnormale Renditen beobachtbar sind. *Bernhard/Thomas* (1989) analysierten diesen Effekt auf potentielle Gründe [55]. Sie vermuteten, dass die Marktteilnehmer partiell verzögert auf die Gewinnmeldung reagieren. Weiterhin ist zu vermuten, dass wenn sich eine Marktreaktion vor einem Veröffentlichungszeitpunkt zuträgt, diese sich so kurzfristig ereignet, dass sie der Berechnung der signifikanten Trends dieser Arbeit entfällt.

5.3.3 Kritische Würdigung

Wie schon bei der Ergebnisauswertung angesprochen, kann es zu Problemen bei der Marktbereinigung der Renditen kommen. Hier sind besonders kleinere Unternehmen betroffen. Dies stellt aber, im Sinne der Auswahl des passenden Marktindex, ein generelles Problem dar. Überdies hinaus kann durch diesen Versuchsaufbau lediglich überprüft werden, ob diese signifikanten Trends nicht nur zufällig vor bzw. nach einem Ereigniszeitpunkt auftreten, jedoch nicht über welchen exakten Zeitraum die Veröffentlichungen von Gewinnmeldungen Einfluss auf die zugehörige Aktienkurse haben. Außerdem kann das Auftreten anderer Einflussfaktoren vor bzw. nach Berichtsveröffentlichungen nicht ausgeschlossen werden.

6 Fazit

Die Modellierung von Kapitalmarktzeitreihen unterlag im Laufe der Zeit verschiedenster Theorien. Diese wurden aufgenommen, um einen potentiellen Einfluss auf Aktienkurse durch Gewinnmeldungen nachweisen zu können. Im Rahmen der empirischen Auswertung, auf Basis der Rendite täglicher Schlusskurse deutscher Automobilmarktunternehmen, wurden zunächst die statistischen Eigenschaften untersucht. Es konnte die Stationarität und eine der Normalverteilung abweichende, leptokurtische Verteilung der Rendite-Zeitreihen nachgewiesen werden. Bei der Betrachtung der Autokorrelation der vorliegenden Daten konnte eine zeitliche Abhängigkeit in den absoluten und quadrierten Renditen festgestellt werden. Diese Beobachtung führte zu einer näheren Überprüfung dieser Volatilitätscluster.

Im nachfolgenden Schritt wurden die Rendite-Zeitreihen, unter Zuhilfenahme von ARCH-Prozessen, spezifisch auf diese Volatilitätscluster getestet. Die höchst signifikanten Ergebnisse dieser Untersuchung wurden als Grundlage für eine Volatilitätsprognose genutzt. Dabei nahm die Volatilität im Ereigniszeitraum rund um die Veröffentlichung von Unternehmensberichten höhere Werte als im restlichen Zeitraum an. In einer aufbauenden Untersuchung könnten asymmetrische ARCH-Modellreihen genutzt werden, um den Unterschied zwischen positiven und negativen Nachrichten besser abbilden zu können.

Aufbauend auf der Volatilitätsanalyse im Ereignisfenster, wurden abnormale Renditen im selbigen ermittelt. Durch eine Hauptkomponentenanalyse über die im Unternehmensbericht gegebenen Kennzahlen und einer saisonale Regression mit Strukturbruch dieser Hauptkomponentenwerte, konnten die Gewinnüberraschungen in positive und negative Meldungen unterteilt werden. Dabei wurden signifikante abnormale Renditen bei der Veröffentlichung von Neun-Monatsberichten festgestellt. Des Weiteren sind signifikante abnormale Renditen entweder ein Tag vor oder am Ereignistag selbst beobachtbar. Die erste Hypothese, also dass Aktienkurse mit instantanen Schocks auf die Veröffentlichung von Unternehmensberichten reagieren, kann nur partiell angenommen werden. In einer weiterführenden Analyse müsste vor allem das Marktmodell einer erweiterten Evaluation unterzogen werden.

In einer weiteren Untersuchung wurden weiterreichende Intervalle, mit dem Veröffentlichungszeitpunkt von Gewinnmeldungen als Bezugspunkt, in Betracht gezogen. Dabei wurde untersucht, wie hoch die Wahrscheinlichkeit ist, dass gegeben einem Berichtszeitpunkt ein vor bzw. nachgelagertes Intervall der zugehörigen Rendite-Zeitreihe einen signifikanten Trend aufweist. Mittels Koinzidenzanalyse konnten signifikante Trends vor allem im direkt vor- bzw. nachgelagerten Intervall aufgezeigt werden. Insbesondere im nachgelager-

ten Zeitraum konnten mehrere signifikante Koinzidenzraten festgestellt werden, sodass die Annahme, Geschäftsberichte würden Aktienkurse über einen gewissen Zeitraum hinweg beeinflussen, angenommen werden kann. Um eine stichhaltige Aussage über die Hypothese, Aktienkurse würden die Umsatzzahlen bereits über einen gewissen Zeitraum vorwegnehmen, treffen zu können, wäre es in einer weiterführenden Untersuchung ratsam, das Marktgeschehen der Intraday-Handels zugrunde zu legen.

Abschließend ist festzustellen, dass die Modellierung von Kapitalmarktzeitreihen auch weiterhin nur eine Approximation an das reale Marktgeschehen darstellen wird. Die Optimierung dieser Annäherung, wenn auch nie perfekt zu erwarten, gilt als Basis für die Untersuchung von Einflussfaktoren auf Kapitalmarktreaktionen wie sie in dieser Arbeit stattgefunden hat.

Literaturverzeichnis

- [1] *Varnholt, H.* ; Volkswagen steigert Gewinn überraschend deutlich ; Wall Street Journal, 30.10.2014 URL: <http://www.wsj.de/nachrichten/SB11912131382502414519004580245881748472018>, Abruf: 24.07.2015
- [2] *Röder, K.* ; Kurswirkungen von Meldungen deutscher Aktiengesellschaften , Reihe: Quantitative Ökonomie, Bd. 98 ; Josef Eul Verlag, Lohmar, 1999
- [3] *Sharpe, W.* ; Capital Asset Prices: A Theory of Market Equilibrium Under Conditions of Risk ; Journal of Finance (1964), Vol.19, S. 425–442
- [4] *Lintner, J.* ; The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets ; Review of Economics and Statistics (1965), Vol.47, S. 13–37
- [5] *Fama, E. F./French, K. R.* ; Common Risk Factors in the Returns on Stocks and Bonds ; Journal of Financial Economics (1993), Vol.33(1), S. 3–56
- [6] *Carhart, M. M.* ; On Persistence in Mutual Fund Performance ; Journal of Finance (1997), Vol.52(1), S. 57–82
- [7] *Engle, R. F.* ; Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation ; Econometrica (1982), Vol.50, S. 987–1007
- [8] *Bollerslev, T.* ; Generalized Autoregressive conditional heteroscedasticity ; Journal of Econometrics (1986), Vol.31, S. 307–327
- [9] *Nelson, D. B.* ; Conditional heteroskedasticity in asset returns: a new approach ; Econometrica (1991), Vol.59, S. 347–370
- [10] *KPMG Deutsche Treuhand-Gesellschaft AG (Hrsg.)* ; International Financial Reporting Standards ; Schäffer-Poeschel Verlag, Stuttgart, 2007
- [11] *Schmidlin, N.* ; Unternehmensbewertung & Kennzahlenanalyse ; Verlag Franz Vahlen, München, 2013
- [12] *Härdle, W. K./Simar, L.* ; Applied Multivariate Statistical Analysis ; Springer-Verlag, Berlin, 2015

- [13] *Spremann, K.* ; Finance ; Oldenburg Verlag, München, 2010
- [14] *Gräfer, H./Schneider, G./Gerenkamp, T.* ; Bilanzanalyse ; NWB Verlag, Paderborn/Gütersloh, 2012
- [15] *Muschol, H.* ; Bilanzpolitik und Bilanzanalyse ; M& S Verlag, Zwickau, 2014
- [16] *Seppelfricke, P.* ; Handbuch Aktien- und Unternehmensbewertung ; Schäffer–Poeschel Verlag, Stuttgart, 2012
- [17] *Murphy, J. J.* ; Technische Analyse der Finanzmärkte ; FinanzBuch Verlag, München, 2014
- [18] *Will, M. G.* ; Eine kurze Ideengeschichte der Kapitalmarkttheorie: Fundamentaldatenanalyse, Effizienzmarkthypothese und Behavioral Finance ; Diskussionspapiere des Lehrstuhls für Wirtschaftsethik an der Martin–Luther–Universität Halle–Wittenberg (2012), Vol. 2012–4
- [19] *Fama, E. F.* ; Efficient Capital Markets, A Review of Theory and Empirical Work ; Journal of Finance (1970), Vol.25, S. 383–417
- [20] *Steiner, M./Bruns, C./Stöckl, S.* ; Wertpapiermanagement ; Schäffer–Poeschel Verlag, Stuttgart, 2012
- [21] *Schmale, S.* ; Interpretation von Kapitalmarktreaktionen ; Gabler Verlag, Wiesbaden, 1994
- [22] *Morrien, R./Engst, J.* ; Börse leicht verständlich ; FinanzBuch Verlag, München, 2011
- [23] *Campbell, J. Y./Lo, A. W./MacKinlay, A. C.* ; The Econometrics of Financial Markets ; Princeton University Press, Princeton (USA), 1997
- [24] *Tsay, R. S.* ; Analysis of Financial Time Series ; Wiley–Interscience , Hoboken (USA), 2005
- [25] *Schröder, M. (Hrsg.)* ; Finanzmarkt–Ökonometrie ; Schäfer–Poeschel Verlag , Stuttgart, 2012
- [26] *Perridon, L./Steiner, M./Rathgeber A.W.* ; Finanzwirtschaft der Unternehmung ; Vahlen Verlag , München, 2012

- [27] *Fama, E. F./French, K. R.* ; Multifactor Explanations of Asset Pricing Anomalies ; Journal of Finance (1996), Vol.51(1), S. 55–84
- [28] *Banz, R. W.* ; The Relationship between Return and Market Value of Common Stocks ; Journal of Financial Economics (1981), Vol.9(1), S. 3–18
- [29] *Rosenberg, B./Reid, K./Lahnstein, R.* ; Persuasive Evidence of Market Inefficiency ; The Journal of Portfolio Management (1985), Vol.11(3), S. 9–16
- [30] *Lakonishok, J./Shleifer, A./Vishny, R. W.* ; Contrarian Investment, Exploration and Risk ; Journal of Finance (1994), Vol.49(5), S. 1541–1578
- [31] *Federspieler, C.* ; Zwischenberichtspublizität in Europa ; Peter Lang Verlag, Frankfurt am Main, 1999
- [32] *Dickey, D. A./Fuller, W. A.* ; Distribution of the Estimators for Autoregressive Time Series With a Unit Root ; Journal of the American Statistical Association (1979), Vol.74(366), S. 427–431
- [33] *Franke, J./Härdle, W. K./Hafner C. M.* ; Statistics of Financial Markets ; Springer Verlag , Berlin, 2015
- [34] *Ljung, G. M./Box, G. E. P.* ; On a measure of lack of fit in time series models ; Biometrika (1978), Vol.65(2), S. 297–303
- [35] *Box, G. E. P./Jenkins, G. M.* ; Time series analysis forecasting and control ; Holden–Day , San Francisco (USA), 1970
- [36] *Engle, R. F./Lilien, D. M./Robins, R. P.* ; Estimating Time Varying Risk Premia in the Term Structure: The Arch–M Model ; Econometrica (1987), Vol.55(2), S. 391–407
- [37] *Black, F.* ; Studies of Stock Price Volatility Changes ; Proceedings of the Business and Economics Section of the American Statistical Association (1976), S. 177–181
- [38] *Handl, A.* ; Multivariate Analysemethoden ; Springer–Verlag, Berlin Heidelberg, 2010
- [39] *Backhaus, K./Erichson, B./Plinke, W./Weiber, R.* ; Multivariate Analysemethoden ; Springer-Verlag, Berlin Heidelberg, 2011
- [40] *Hackl, P.* ; Einführung in die Ökonometrie ; Pearson–Studium, München, 2005

- [41] *Bai, J.* ; Least Squares Estimation of a Shift in Linear Processes ; Journal of Time Series Analysis (1994), Vol.15, S. 453–472
- [42] *Donges, J. F./Donner, R. V./Traut, M. H./Marwan, N./Schellnhuber, H-J., Kurths, J.* ; Nonlinear detection of paleoclimate–variability transitions possibly related to human evolution Supporting Information ; Proceedings of the National Academy of Sciences of the U.S.A. (2011), Vol.108(51), S. 20422–20427
- [43] *Donges, J. F./Schleussner, C.-F./Siegmund, J. F./Donner, R. V.* ; Coincidence analysis for quantifying statistical interrelationships between event time series ; European Physical Journal Special Topics (online first) (2015)
- [44] *Efron, B.* ; Bootstrap Methods: Another Look at the Jackknife ; The Annals of Statistics (1979), Vol.7(1), S. 1–26
- [45] *Quenouille, M. H.* ; Notes on Bias in Estimation ; Biometrika (1956), Vol.43(3–4), S. 353–360
- [46] *Tukey, J. W.* ; Bias and Confidence in Not Quite Large Samples ; The Annals of Mathematical Statistics (1958), Vol.29, S. 614
- [47] *Kroese, D. P./Brereton, T./Taimre, T./Botev, Z. I.* ; Why the Monte Carlo Method is so important today ; WIREs Comp Stat (2014), Vol.6, S. 386–392
- [48] *Ball, R./Brown, P.* ; An Empirical Evaluation of Accounting Income Numbers ; Journal of Accounting Research (1968), Vol.6, S. 159–178
- [49] *Hagerman, R. L./Zmijewski, M. E./Shah, P.* ; The Association Between the Magnitude of Quarterly Earnings Forecast Errors and Risk–Adjusted Stock Returns ; Journal of Accounting Research (1984), Vol.22, S. 526–540
- [50] *Scholes, M./Williams, J.* ; Estimating Betas from Nonsynchronous Data ; Journal of Financial Economics (1977), Vol.5, S. 309–327
- [51] *Corhay, A./Tourani-Rad, A.* ; Conditional heteroskedasticity adjusted market model and an event study ; The Quarterly Review of Economics and Finance (1996), Vol.36(4), S. 529–538
- [52] *Pynnönen, S.* ; On regression based event study ; Contributions to Accounting, Finance, and Management Science Acta Wasaensia (2005), Vol.143, S. 327–354

- [53] *Alberg, D./Shalit, H./Yosef, R.* ; Estimating stock market volatility using asymmetric GARCH models ; *Applied Financial Economics* (2008), Vol.59, S. 1201–1208
- [54] *Cheung, Y.-W./Lai, K. S.* ; Lag Order and Critical Values of the Augmented Dickey–Fuller Test ; *Journal of Business & Economic Statistics* (1995), Vol.13(3), S. 277–280
- [55] *Bernhard, V./Thomas, J.* ; Post–Earnings–Announcement Drift: Delayed Price Response or Risk Premium? ; *Journal of Accounting Research* (1989), Vol.27, S. 1–36

Quellen zur Datenerhebung und –auswertung

- [56] *Volkswagen AG* ; Publikationen ; URL: http://www.volkswagenag.com/content/vwcorp/info_center/de/publications/publications.html , Abruf: 02.05.2015
- [57] *Daimler AG* ; Geschäftsberichte seit 1979 ; URL: <http://www.daimler.com/investor-relations/berichte-und-kennzahlen/berichte/berichte-seit-1979> , Abruf: 02.05.2015
- [58] *Continental AG* ; Archiv Geschäfts– und Zwischenberichte ab 1975 ; URL: http://www.continental-corporation.com/www/portal_com_de/themen/ir/finanzberichte/archiv/arch_berichte_de.html , Abruf: 02.05.2015
- [59] *Bertrandt AG* ; Finanzberichte Archiv ; URL: <http://www.bertrandt.com/investor-relations/finanzberichte/finanzberichte-archiv.html> , Abruf: 02.05.2015
- [60] *ElringKlinger AG* ; Finanzberichte ; URL: <http://www.elringklinger.de/de/investor-relations/finanzpublikationen/finanzberichte> , Abruf: 02.05.2015
- [61] *PWO AG* ; Berichte ; URL: <http://www.progress-werk.de/investor-relations/berichte/2015/> , Abruf: 02.05.2015
- [62] *BMW AG* ; Finanzberichte ; URL: http://www.bmwgroup.com/bmwgroup_prod/d/0_0_www_bmwgroup_com/investor_relations/finanzberichte/ueberblick.shtml , Abruf: 02.05.2015
- [63] *Leoni AG* ; Publikationen ; URL: <https://www.leoni.com/de/unternehmen/publikationen/#!/ajaxsearch/de/unternehmen/publikationen/1> , Abruf: 02.05.2015

- [64] *Grammer AG* ; Geschäftsberichte ; URL: <http://www.grammer.com/investor-relations/publikationen/finanzberichte.html> , Abruf: 02.05.2015
- [65] *R Core Team* ; R: A language and environment for statistical computing ; <http://www.R-project.org/>; R Foundation for Statistical Computing, Vienna (Austria), 2013

Anhang




Abbildung 13: Aktienkurs in € (oben) und zugehörige Rendite (unten) der Daimler AG




Abbildung 14: Aktienkurs in € (oben) und zugehörige Rendite (unten) der Leoni AG




Abbildung 15: Aktienkurs (VZ) in € (oben) und zugehörige Rendite (unten) der Volkswagen AG




Abbildung 16: Aktienkurs in € (oben) und zugehörige Rendite (unten) der Continental AG




Abbildung 17: Aktienkurs (ST) in € (oben) und zugehörige Rendite (unten) der BMW AG




Abbildung 18: Aktienkurs in € (oben) und zugehörige Rendite (unten) der Bertrant AG




Abbildung 19: Aktienkurs in € (oben) und zugehörige Rendite (unten) der Grammer AG




Abbildung 20: Aktienkurs in € (oben) und zugehörige Rendite (unten) der ElringKlinger AG




Abbildung 21: Aktienkurs in € (oben) und zugehörige Rendite (unten) der PWO AG




Abbildung 22: Vergleich der Kerndichteschätzungen (rote Kurve) mit einer der Rendite-Zeitreihen angepassten Normalverteilung (blaue Kurve) der restlichen Unternehmen




Abbildung 23: Q-Q-Plots der Rendite-Zeitreihen der restlichen Unternehmen (Winkelhalbierende in rot eingezeichnet)




Abbildung 24: PCA der Daimler AG (Werte skaliert) [12]




Abbildung 25: PCA der Continental AG (Werte skaliert) [12]




Abbildung 26: PCA der BMW AG (Werte skaliert) [12]




Abbildung 27: PCA der Leoni AG (Werte skaliert) [12]




Abbildung 28: PCA der Bertrand AG (Werte skaliert) [12]




Abbildung 29: PCA der Grammer AG (Werte skaliert) [12]




Abbildung 30: PCA der ElringKlinger AG (Werte skaliert) [12]




Abbildung 31: PCA der PWO AG (Werte skaliert) [12]




Abbildung 32: Darstellung des zeitlichen Verlaufs der Hauptkomponentenwerte der restlichen Unternehmen inklusive saisonaler Regression mit Strukturbruch

$$\begin{aligned}
\hat{y}_{VOW3,t} &= (-2.20 + 0.03t + 0.55D_{2,t} + 0.02D_{3,t} + 0.16D_{4,t}) \cdot q_1 \\
&\quad + (1.56 + 0.11t + 1.05D_{2,t} + 0.58D_{3,t} - 0.29D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 39
\end{aligned} \tag{80}$$

$$\begin{aligned}
\hat{y}_{CON,t} &= (-0.52 - 0.001t + 0.07D_{2,t} - 0.47D_{3,t} - 0.94D_{4,t}) \cdot q_1 \\
&\quad + (0.97 + 0.11t + 0.15D_{2,t} - 0.66D_{3,t} - 0.39D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 42
\end{aligned} \tag{81}$$

$$\begin{aligned}
\hat{y}_{LEO,t} &= (0.56 - 0.03t - 0.47D_{2,t} + 0.06D_{3,t} - 2.11D_{4,t}) \cdot q_1 \\
&\quad + (3.70 - 0.08t - 0.78D_{2,t} - 1.62D_{3,t} - 3.17D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 44
\end{aligned} \tag{82}$$

$$\begin{aligned}
\hat{y}_{BDT,t} &= (-3.14 + 0.10t - 0.20D_{2,t} + 0.29D_{3,t} - 0.01D_{4,t}) \cdot q_1 \\
&\quad + (1.2 + 0.09t - 0.05D_{2,t} + 1.63D_{3,t} - 0.34D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 36
\end{aligned} \tag{83}$$

$$\begin{aligned}
\hat{y}_{GMM,t} &= (-0.57 + 0.17t - 1.23D_{2,t} + 1.33D_{3,t} - 0.14D_{4,t}) \cdot q_1 \\
&\quad + (-0.21 - 0.13t - 0.24D_{2,t} + 0.83D_{3,t} + 0.26D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 21
\end{aligned} \tag{84}$$

$$\begin{aligned}
\hat{y}_{ZIL2,t} &= (-1.85 + 0.02t + 0.70D_{2,t} + 0.40D_{3,t} - 0.60D_{4,t}) \cdot q_1 \\
&\quad + (0.64 + 0.13t + 0.17D_{2,t} + 0.77D_{3,t} - 0.99D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 24
\end{aligned} \tag{85}$$

$$\begin{aligned}
\hat{y}_{PWO,t} &= (0.48 + 0.01t + 0.50D_{2,t} - 0.40D_{3,t} + 0.20D_{4,t}) \cdot q_1 \\
&\quad + (-3.25 + 0.19t + 0.22D_{2,t} - 0.29D_{3,t} - 0.36D_{4,t}) \cdot q_2 \\
&\text{mit } t' = 26
\end{aligned} \tag{86}$$




Abbildung 33: Koinzidenzanalyse der Daimler AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 34: Koinzidenzanalyse der Continental AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 35: Koinzidenzanalyse der BMW AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 36: Koinzidenzanalyse der Leoni AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 37: Koinzidenzanalyse der Bertrand AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 38: Koinzidenzanalyse der Grammer AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 39: Koinzidenzanalyse der ElringKlinger AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallsbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an




Abbildung 40: Koinzidenzanalyse der PWO AG mit Koinzidenzrate r_p in Abhängigkeit der Intervallsbreite k in Tagen, ausgefüllte Kästchen zeigen eine Überschreitung der Schwellgrenze der Simulation und somit signifikante Koinzidenzraten an

Tabelle 15: Ergebnisse der Koinzidenzanalyse der Daimler AG mit $N_A = 56$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.143	0.179	0.179	0.286	0.196	0.286	0.339	0.286	0.375	731	85
6	0.125	0.107	0.179	0.250	0.161	0.286	0.321	0.214	0.393	609	72
7	0.089	0.161	0.143	0.232	0.214	0.250	0.304	0.214	0.339	522	51
8	0.107	0.179	0.179	0.214	0.286	0.304	0.268	0.339	0.393	457	56
9	0.054	0.161	0.143	0.143	0.196	0.250	0.214	0.286	0.321	406	40
10	0.107	0.179	0.161	0.179	0.232	0.286	0.268	0.268	0.375	365	43
11	0.071	0.089	0.161	0.196	0.179	0.268	-	-	-	332	37
12	0.054	0.143	0.161	0.143	0.214	0.268	-	-	-	304	35
13	0.107	0.125	0.179	0.161	0.196	0.286	-	-	-	281	34
14	0.036	0.071	0.125	0.089	0.161	0.214	-	-	-	261	23
15	0.071	0.161	0.179	0.107	0.214	0.304	-	-	-	243	31
16	0.125	0.268	0.196	-	-	-	-	-	-	228	34
17	0.018	0.107	0.143	-	-	-	-	-	-	215	23
18	0.125	0.125	0.161	-	-	-	-	-	-	203	25
19	0.125	0.089	0.125	-	-	-	-	-	-	192	18
20	0.054	0.125	0.125	-	-	-	-	-	-	182	16

Tabelle 16: Ergebnisse der Koinzidenzanalyse der Continental AG mit $N_A = 55$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.073	0.145	0.145	0.145	0.164	0.255	0.200	0.236	0.345	731	76
6	0.018	0.055	0.127	0.109	0.073	0.236	0.236	0.145	0.309	609	56
7	0.036	0.091	0.127	0.145	0.145	0.218	0.255	0.218	0.309	522	47
8	0.073	0.055	0.109	0.127	0.091	0.182	0.164	0.109	0.255	457	32
9	0.055	0.073	0.109	0.164	0.091	0.182	0.255	0.182	0.236	406	27
10	0.073	0.091	0.127	0.164	0.164	0.200	0.218	0.218	0.273	365	29
11	0.055	0.091	0.109	0.145	0.145	0.200	-	-	-	332	26
12	0.091	0.091	0.127	0.164	0.109	0.200	-	-	-	304	26
13	0.127	0.055	0.109	0.164	0.127	0.200	-	-	-	281	22
14	0.055	0.127	0.109	0.073	0.164	0.182	-	-	-	261	18
15	0.073	0.073	0.091	0.109	0.127	0.164	-	-	-	243	15
16	0.091	0.036	0.091	-	-	-	-	-	-	228	14
17	0.164	0.036	0.109	-	-	-	-	-	-	215	16
18	0.109	0.055	0.109	-	-	-	-	-	-	203	15
19	0.036	0.164	0.127	-	-	-	-	-	-	192	17
20	0.036	0.073	0.109	-	-	-	-	-	-	182	14

Tabelle 17: Ergebnisse der Koinzidenzanalyse der BMW AG mit $N_A = 53$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.057	0.094	0.132	0.057	0.189	0.226	0.132	0.208	0.302	731	62
6	0.057	0.038	0.132	0.113	0.189	0.226	0.170	0.208	0.321	609	55
7	0.057	0.113	0.113	0.113	0.170	0.189	0.132	0.226	0.264	522	38
8	0.075	0.113	0.132	0.132	0.151	0.208	0.189	0.170	0.283	457	38
9	0.057	0.075	0.113	0.113	0.132	0.170	0.113	0.132	0.245	406	27
10	0.094	0.075	0.132	0.113	0.151	0.226	0.226	0.151	0.302	365	31
11	0.057	0.170	0.189	0.170	0.208	0.321	-	-	-	332	43
12	0.075	0.113	0.113	0.113	0.170	0.208	-	-	-	304	26
13	0.057	0.132	0.113	0.094	0.170	0.208	-	-	-	281	23
14	0.094	0.094	0.151	0.132	0.189	0.245	-	-	-	261	26
15	0.057	0.075	0.113	0.170	0.113	0.189	-	-	-	243	18
16	0.132	0.132	0.132	-	-	-	-	-	-	228	22
17	0.113	0.113	0.113	-	-	-	-	-	-	215	17
18	0.132	0.170	0.170	-	-	-	-	-	-	203	24
19	0.075	0.038	0.113	-	-	-	-	-	-	192	14
20	0.038	0.113	0.132	-	-	-	-	-	-	182	16

Tabelle 18: Ergebnisse der Koinzidenzanalyse der Leoni AG mit $N_A = 55$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.073	0.182	0.127	0.091	0.255	0.218	0.200	0.291	0.309	731	62
6	0.036	0.182	0.145	0.073	0.200	0.236	0.127	0.200	0.327	609	57
7	0.055	0.164	0.127	0.055	0.236	0.218	0.182	0.255	0.291	522	43
8	0.091	0.091	0.182	0.164	0.164	0.273	0.236	0.255	0.382	457	53
9	0.036	0.127	0.145	0.164	0.164	0.255	0.255	0.236	0.327	406	40
10	0.091	0.091	0.145	0.182	0.145	0.273	0.273	0.255	0.345	365	39
11	0.109	0.109	0.145	0.182	0.182	0.255	-	-	-	332	34
12	0.091	0.145	0.145	0.200	0.182	0.236	-	-	-	304	28
13	0.055	0.073	0.127	0.164	0.145	0.200	-	-	-	281	23
14	0.073	0.091	0.109	0.164	0.091	0.182	-	-	-	261	19
15	0.055	0.055	0.091	0.164	0.091	0.164	-	-	-	243	15
16	0.127	0.091	0.145	-	-	-	-	-	-	228	23
17	0.091	0.127	0.127	-	-	-	-	-	-	215	18
18	0.036	0.091	0.091	-	-	-	-	-	-	203	13
19	0.091	0.073	0.091	-	-	-	-	-	-	192	13
20	0.109	0.091	0.109	-	-	-	-	-	-	182	14

Tabelle 19: Ergebnisse der Koinzidenzanalyse der Bertrand AG mit $N_A = 47$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.085	0.043	0.128	0.213	0.085	0.234	0.213	0.170	0.298	630	55
6	0.106	0.064	0.106	0.170	0.085	0.191	0.191	0.170	0.255	525	38
7	0.170	0.106	0.128	0.213	0.213	0.234	0.255	0.234	0.298	450	39
8	0.000	0.191	0.128	0.043	0.234	0.213	0.149	0.255	0.298	394	33
9	0.085	0.106	0.149	0.170	0.170	0.234	0.234	0.255	0.319	350	32
10	0.064	0.128	0.128	0.128	0.191	0.213	0.170	0.213	0.298	315	27
11	0.106	0.149	0.128	0.149	0.170	0.213	-	-	-	286	23
12	0.064	0.064	0.106	0.085	0.149	0.170	-	-	-	262	17
13	0.064	0.085	0.128	0.106	0.170	0.213	-	-	-	242	21
14	0.106	0.064	0.106	0.170	0.106	0.191	-	-	-	225	17
15	0.085	0.170	0.128	0.149	0.234	0.213	-	-	-	210	18
16	0.128	0.128	0.128	-	-	-	-	-	-	197	18
17	0.021	0.106	0.106	-	-	-	-	-	-	185	14
18	0.064	0.128	0.106	-	-	-	-	-	-	175	12
19	0.085	0.128	0.106	-	-	-	-	-	-	165	13
20	0.043	0.043	0.106	-	-	-	-	-	-	157	11

Tabelle 20: Ergebnisse der Koinzidenzanalyse der Grammer AG mit $N_A = 35$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.086	0.143	0.143	0.143	0.143	0.257	0.229	0.143	0.343	450	42
6	0.143	0.114	0.171	0.257	0.143	0.314	0.314	0.257	0.400	375	46
7	0.257	0.057	0.171	0.314	0.171	0.286	0.314	0.229	0.371	322	34
8	0.057	0.029	0.114	0.114	0.029	0.200	0.200	0.086	0.257	281	20
9	0.229	0.086	0.171	0.286	0.229	0.314	0.457	0.257	0.429	250	31
10	0.086	0.057	0.143	0.171	0.114	0.229	0.257	0.171	0.314	225	20
11	0.029	0.029	0.086	0.114	0.029	0.143	-	-	-	204	11
12	0.086	0.114	0.114	0.171	0.171	0.200	-	-	-	187	14
13	0.057	0.029	0.114	0.114	0.114	0.200	-	-	-	173	12
14	0.114	0.029	0.143	0.171	0.114	0.229	-	-	-	161	15
15	0.086	0.057	0.143	0.143	0.114	0.229	-	-	-	150	14
16	0.114	0.114	0.143	-	-	-	-	-	-	140	15
17	0.171	0.086	0.114	-	-	-	-	-	-	132	11
18	0.143	0.114	0.171	-	-	-	-	-	-	125	15
19	0.057	0.000	0.086	-	-	-	-	-	-	118	7
20	0.114	0.171	0.171	-	-	-	-	-	-	112	14

Tabelle 21: Ergebnisse der Koinzidenzanalyse der ElringKlinger AG mit $N_A = 37$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.135	0.270	0.162	0.297	0.405	0.270	0.324	0.405	0.378	477	51
6	0.054	0.135	0.135	0.108	0.189	0.243	0.189	0.216	0.351	398	37
7	0.081	0.216	0.135	0.189	0.270	0.243	0.243	0.297	0.324	341	30
8	0.108	0.243	0.162	0.162	0.297	0.243	0.243	0.351	0.324	298	29
9	0.108	0.216	0.135	0.135	0.243	0.216	0.216	0.270	0.297	265	21
10	0.081	0.162	0.162	0.108	0.243	0.243	0.216	0.324	0.351	238	24
11	0.108	0.081	0.108	0.162	0.135	0.216	-	-	-	217	18
12	0.000	0.108	0.135	0.108	0.108	0.216	-	-	-	199	17
13	0.000	0.135	0.108	0.054	0.216	0.189	-	-	-	183	14
14	0.027	0.162	0.108	0.081	0.216	0.189	-	-	-	170	12
15	0.054	0.108	0.135	0.189	0.270	0.243	-	-	-	159	16
16	0.081	0.135	0.135	-	-	-	-	-	-	149	14
17	0.054	0.108	0.108	-	-	-	-	-	-	140	9
18	0.135	0.162	0.108	-	-	-	-	-	-	132	11
19	0.081	0.135	0.135	-	-	-	-	-	-	125	11
20	0.081	0.189	0.135	-	-	-	-	-	-	119	10

Tabelle 22: Ergebnisse der Koinzidenzanalyse der PWO AG mit $N_A = 49$ Veröffentlichungszeitpunkten, Werte der Koinzidenzrate r_p jeweils für den Zeitraum vor der Veröffentlichung, nach der Veröffentlichung und des kritischen Wertes der Simulation mit $\alpha = 5\%$, zuzüglich der jeweiligen Länge der Trendreihe T und Anzahl signifikanter Trends N_B

k	$\Delta T = 1$			$\Delta T = 2$			$\Delta T = 3$			T	N_B
	vor	nach	sim	vor	nach	sim	vor	nach	sim		
5	0.102	0.061	0.143	0.184	0.163	0.245	0.184	0.163	0.327	629	57
6	0.082	0.082	0.143	0.143	0.122	0.224	0.204	0.204	0.306	524	46
7	0.082	0.082	0.143	0.122	0.163	0.224	0.184	0.204	0.306	449	40
8	0.122	0.102	0.143	0.204	0.204	0.224	0.327	0.224	0.306	393	35
9	0.163	0.102	0.143	0.224	0.143	0.245	0.265	0.184	0.347	349	35
10	0.041	0.082	0.122	0.163	0.102	0.204	0.204	0.204	0.265	314	24
11	0.122	0.000	0.082	0.143	0.041	0.163	-	-	-	286	17
12	0.122	0.102	0.122	0.163	0.184	0.224	-	-	-	262	23
13	0.041	0.020	0.082	0.082	0.061	0.143	-	-	-	242	13
14	0.122	0.163	0.143	0.163	0.184	0.245	-	-	-	224	22
15	0.102	0.102	0.102	0.122	0.143	0.184	-	-	-	209	16
16	0.061	0.082	0.082	-	-	-	-	-	-	196	12
17	0.041	0.102	0.082	-	-	-	-	-	-	185	10
18	0.082	0.122	0.122	-	-	-	-	-	-	174	15
19	0.020	0.041	0.082	-	-	-	-	-	-	165	10
20	0.041	0.041	0.082	-	-	-	-	-	-	157	9

Erklärung zur Urheberschaft

Ehrenwörtliche Erklärung

Hiermit erkläre ich ehrenwörtlich, dass ich die vorliegende Arbeit selbst angefertigt habe. Die aus fremden Quellen direkt oder indirekt übernommenen Gedanken sind als solche kenntlich gemacht. Die Arbeit wurde bisher noch keiner anderen Prüfbehörde vorgelegt und noch nicht veröffentlicht. Ich bin mir bewusst, dass eine unwahre Erklärung rechtliche Folgen haben wird.

Dresden, den 07.09.2015

Ort, Datum

Unterschrift