

2 Grundlagen

Wie einleitend beschrieben, soll dieses Kapitel einen Überblick über alle, für den Fortgang dieser Arbeit relevanten und grundlegenden Analysemöglichkeiten und über die verschiedenen verwendeten Handelsdaten liefern. Bevor mit der Vorstellung der Modelle zur Analyse der Volatilität auf dem Finanzmarkt begonnen werden kann (Abschnitt 2.3), ist eine kurze Darstellung der charakteristischen Eigenschaften von Finanzzeitreihen unabdingbar. Auf den Begriff Volatilität wird in diesem Kapitel immer wieder zurückgegriffen. Eine genaue Abgrenzung des Begriffes Volatilität erfolgt in Abschnitt 2.5. Vorab sei jedoch erwähnt, dass der Begriff Volatilität, sofern nicht anders angegeben, hier ausschließlich die historische Volatilität, berechnet mit einem Modell, bezeichnet.

2.1 Stilisierte Fakten von Finanzzeitreihen

Für eine modelltheoretische Betrachtung von Finanzmärkten sind Kenntnisse über dessen Struktur und Charakteristik aus ökonometrischer Sichtweise elementar. Ohne zu tief auf bekannte Eigenschaften von Finanzzeitreihen einzugehen, sollen diese im Folgenden als sog. stilisierte Fakten (engl. *stylized facts*) erläutert werden. Unter stilisierten Fakten werden die Eigenschaften verstanden, die unabhängig von speziellen Umständen und Ereignissen immer wieder zu beobachten sind (Vgl. Schmid und Trede, 2006). Die stilisierten Fakten beschreiben dabei auch die Unterschiede von Finanzzeitreihen gegenüber anderen Zeitreihen. In dem in dieser Arbeit betrachteten Zusammenhang sind die stilisierten Fakten wie folgt definiert (Vgl. dazu u.a. Franke et al., 2006):

- Die Kursreihen auf dem Finanzmarkt sind meist nicht stationär und weisen zumindest lokale Trends auf.
- Renditen von Finanzzeitreihen haben eine leptokurtische Verteilung. Das heißt, die Verteilung ist im Vergleich zur Normalverteilung grundsätzlich spitzer.
- Renditen von Finanzzeitreihen folgen i.d.R. einem *white-noise* Prozess, da die Stichprobenautokorrelationen nicht signifikant sind. Die quadrierten bzw. absoluten Stichprobenautokorrelationen sind hingegen signifikant und demnach sind die Werte zwar unkorreliert, aber nicht unabhängig voneinander.
- Volatilitäten tendieren dazu Cluster zu bilden bzw. in Clustern aufzutreten. Nach großen / kleinen Preisänderungen (positiv oder negativ) folgen tendenziell wieder

große / kleine Preisänderungen. Diese Eigenschaft wird als Volatilitätscluster (engl.: *Volatility clustering*) bezeichnet.

Neben diesen Punkten haben Finanzzeitreihen bzw. deren Renditen noch eine Reihe weiterer Eigenschaften, wie z.B.:¹

- *Heavy-tailed*: Die unbedingte Dichte der Renditen hat dickere Enden bzw. Flanken als die einer Normalverteilung (engl.: *Fat-tails* bzw. *heavy-tails*).
- *Aggregated normality*: Mit Verlängerung der Frequenz nähert sich die Verteilungsfunktion der Renditen einer Normalverteilung.
- *Long-Memory* oder langes Gedächtnis: Ereignisse auf dem Finanzmarkt, wie bspw. Schocks, haben häufig eine lange und anhaltende Wirkung. Schocks in der Volatilität zerfallen oft nur langsam.
- *Spillover Effekt* oder Übertragungseffekt: Ein Ereignis/Zustand hat Auswirkungen auf andere Ereignisse/Zustände.
- *Leverage-Effekt*: Positive und negative Informationen führen zu einer unterschiedlichen Wirkung auf die Volatilität.

Speziell der letztgenannte Punkt ist für verschiedene Modellerweiterungen, wie beispielsweise dem APARCH Modell² besonders wichtig. Daher soll der Zusammenhang zwischen dem Leverage-Effekt und der Aktienkursvolatilität noch einmal genauer dargestellt sein: Im Falle negativer Informationen (Schocks), fallen typischerweise die Aktienkurse und mithin der Unternehmenswert. Dies hat zur Folge, dass der Leverage bei fallendem Eigenkapital (Unternehmenswert) fallen muss. Ein steigender Leverage bedeutet sodann ein steigendes Unternehmensrisiko, das von den Eigenkapitalgebern in letzter Instanz zu tragen ist. Aus diesem Grunde steigt die Volatilität des Aktienkurses.

Die meisten der o.g. Eigenschaften können weder durch AR³ bzw. ARMA (*Auto Regressive Moving Average*) Prozesse, noch durch andere (nicht-)lineare Verallgemeinerungen in der Spezifikation des bedingten Erwartungswertes modelliert werden (Vgl. Box et al., 1994).

¹ Vgl. auch hier u.a. Franke et al., 2006.

² Wird im Detail in Abschnitt 2.3.6 eingeführt

³ Autoregressiver Prozess: Ein autoregressiver Prozess ist ein stochastischer Prozess, dessen Realisation zum Zeitpunkt t linear nur von seinen p gewichteten Vergangenheitswerten und einem weißen Rauschen abhängt.

Daher ist immer an Erweiterungen der klassischen Volatilitätsmodelle zu denken, die diese Eigenschaften in einer geeigneten Art und Weise abbilden können. Im Verlauf dieser Arbeit sollen einige wichtige Erweiterungen dieser Modelle eingeführt werden.

Weitere speziell beobachtbare Eigenschaften, um die sich wesentliche Analysen in dieser Arbeit drehen, sind die sog. täglichen Muster. Diese Muster sind zum Einen in der Volatilität und zum Anderen auch in täglichen Handelswartezeiten zu beobachten. Tägliche Muster stellen eine besondere Herausforderung bei der Modellierung der Handelsdaten dar, da aufgrund dieser Muster die Stationaritätsbedingungen der ursprünglich entwickelten parametrischen Modelle verletzt werden. Der semiparametrische Modellansatz kann dieses Problem lösen und ist in Kapitel 3 näher beschrieben. Im Folgenden wird zunächst auf die täglichen Muster in den verschiedenen Betrachtungsebenen eingegangen, um die spezielle Problematik dieser Muster zu verdeutlichen.

2.1.1 Das tägliche Muster in Handelswartezeiten

Die Handelswartezeit (oder kurz: Wartezeit) bezeichnet die zeitliche Dauer zwischen zwei aufeinanderfolgenden Transaktionen (engl.: *Durations*). Die Abbildung 2.1 zeigt exemplarisch die Wartezeiten zwischen zwei Transaktionen der Allianz Aktie über eine zufällig ausgewählte Woche aus dem Jahr 2011 (mit einer Handelszeit von 9:00 Uhr bis 17:30 Uhr). Auf der Abszisse sind dabei die aufeinanderfolgenden Wartezeiten nummeriert und auf der Ordinate sind die Handelswartezeiten (in Sekunden) dargestellt.




Abbildung 2.1: Beispiel für den Verlauf von Handelswartezeiten

Visuell direkt erkennbar ist, dass durch die variierende Länge der Wartezeiten die zur Berechnung der Wartezeit verwendeten ultra-hochfrequenten Handelsdaten nicht äquidistant sind. Zudem lässt sich auch der unterschiedliche Grad der Handelsaktivität durch die Wartezeiten ablesen. Aus der Abbildung ist zu erkennen, dass einige Wartezeiten auf einem sehr niedrigen Level liegen (< 1 Sekunde), wobei andere Wartezeiten bei über einer Minute liegen. Folglich gibt es an jedem Tag Phasen mit einer sehr hohen und Phasen mit einer

sehr niedrigen Handelsaktivität. Der Abbildung 2.1 ist weiterhin zu entnehmen, dass in der Tagesmitte bzw. in der Mittagszeit⁴ das Niveau der Wartezeiten generell etwas höher ist als zu Beginn und gegen Ende des Handelstages.

Bereits 1993 fanden Bollerslev und Domowitz heraus, dass zu Beginn des Handelstages und kurz vor Börsenschluss mehr Käufe und Verkäufe erfolgen als in der restlichen Zeit des Tages und die täglichen Wartezeiten einem inversen U-förmigen Muster folgen (Vgl. auch Engle und Russell, 1998). In Anbetracht der Nicht-Äquidistanz der beobachteten Handelsdaten und des Clusterings der Wartezeiten befassten sich Engle und Russell (1998) in ihrem Papier: „*Autoregressive Conditional Duration: A New Model for Irregularly Spaced Transaction Data*“ mit dem Problem der Modellierung von Handelswartezeiten, indem sie diese als Punktprozesse betrachteten. Auf dieser Grundlage wurde von Engle und Russell das ACD Modell entwickelt, das im Detail in Abschnitt 2.4 sowie in Kapitel 5 dargestellt wird. Schon jetzt sei jedoch erwähnt, dass es mit Hilfe dieses Modells möglich ist, Daten mit nicht äquidistanten Beobachtungen zu modellieren, ohne eine Aggregation bzw. ohne eine vorherige Bearbeitung der Daten durchzuführen. Mit Hilfe dieses Modells werden die unregelmäßigen Zeitabstände der Handelsdaten adäquat berücksichtigt, wodurch die gesamte Bandbreite an Informationen, die diese Datenart bereithält, genutzt werden kann. Jedoch besteht auch in dieser Betrachtungsebene wieder das Problem des täglichen Musters mit der dadurch verletzten Bedingung der Stationarität. Auch dieses Problem kann durch den Einsatz eines semiparametrischen ACD Modells (Kapitel 5) gelöst werden.

2.1.2 Das tägliche Muster der Volatilität

Neben dem typischen Muster in den Handelswartezeiten einer Finanzzeitreihe ergibt sich ein ebenfalls charakteristisches Muster bei der Betrachtung der (täglichen) Volatilität. Auf ein typisches U-förmiges Muster (engl.: *U-shaped pattern*) wurde bereits 1992 von McNish und Wood in ihrer Arbeit: „*An Analysis of Intraday Patterns in Bid/Ask Spreads for NYSE Stocks*“ hingewiesen. Die folgenden Abbildungen zeigen exemplarisch den Verlauf der Volatilität für die Allianz Aktie am 25. September 2014 und am 26. September 2014 (zufällig ausgewählte Tage) mit einem 95%igen Konfidenzintervall (gestrichelten Linien).

⁴Die Mittagszeit ist in dieser Arbeit von 11:30 Uhr bis 13:00 Uhr definiert.




Abbildung 2.2: Beispiel für den U-förmigen Verlauf der Volatilität (Allianz, 25.09.14)




Abbildung 2.3: Beispiel für den U-förmigen Verlauf der Volatilität (Allianz, 26.09.14)

Im Gegensatz zu den Handelswartezeiten, die einen inversen U-förmigen Verlauf folgen, folgt die Volatilität über einen Tag einem U-förmigen Verlauf. Dieser ist typischerweise dadurch gekennzeichnet, dass eine (relativ gesehen) kleine Volatilität in der Mittagszeit⁵ von einer deutlich höheren Volatilität zu Beginn und gegen Ende des Handelstages umschlossen wird. Wie bereits erwähnt, ist der Grad der Handelsaktivität einer Finanzzeitreihe im Laufe eines Handelstages i.d.R. nicht konsistent. Kurz nach der Öffnung und vor dem Schließen des jeweiligen Marktes kann generell eine wesentlich höhere Handelsaktivität und demzufolge kürzere Handelswartezeiten verzeichnet werden als während der Mittagszeit. Dabei lässt sich festhalten: Ist die Handelsaktivität hoch, so sind die Wartezeiten zwischen zwei Transaktionen kurz und die Volatilität i.d.R. auch hoch (und umgekehrt). Das tägliche Muster der Wartezeiten ist also invers zu dem täglichen Muster der Volatilität.

Analog zu der Problematik der verletzten Stationaritätsbedingungen der parametrischen ACD Modelle (durch das tägliche Muster der Wartezeiten) ist auch das tägliche Muster der Volatilität speziell zu berücksichtigen und verletzt -wenn nicht beachtet- die Stationaritätsbedingungen der Klasse der Volatilitätsmodelle (Vgl. Bortoluzzo et al., 2010). Auch für diesen Fall soll im späteren Verlauf ein semiparametrischer Modellansatz zur Lösung vorgeschlagen werden.

Zusammenfassend kann festgehalten werden, dass Finanzzeitreihen und speziell Renditerei-

⁵ siehe dazu die Definition unter 2.1.1.

hen sich durch eine Vielzahl von speziellen Eigenschaften als besondere finanzökonometrische Beobachtungsobjekte von anderen Zeitreihen hervorheben. Für die Wahl eines geeigneten Modells sind daher zum Einen die speziellen Charakteristiken der Datentypen zu berücksichtigen, aber auch die Datensätze an sich. Im Folgenden sollen daher verschiedene Datenarten und Datenstrukturen voneinander abgegrenzt und definiert werden. Diese Darstellung erfolgt im Hinblick auf die verschiedenen Anwendungsteile dieser Arbeit, d.h. es werden die verwendeten Datenarten vorgestellt und auch die der jeweiligen Datenart angehörenden Unternehmen und Indizes.

2.2 Hochfrequente- und ultra-hochfrequente Handelsdaten

In den empirischen Teilen dieser Arbeit sollen nicht nur äquidistante Handelsdaten, d.h. Daten mit gleichen Zeitabständen zwischen den einzelnen Beobachtungen betrachtet werden sondern auch sog. ultra-hochfrequente Handelsdaten oder Tickdaten. Vordergründig gilt es, diese beiden Typen voneinander abzugrenzen. Zunächst sind jedoch grundsätzlich niederfrequente Daten und hochfrequente Daten voneinander zu unterscheiden. Erstgenannte bezeichnen Daten, bei denen die Kursverläufe einer Finanzzeitreihe bspw. mit den Tagesschlusskursen aufgezeichnet werden. Hochfrequente Handelsdaten dagegen zeichnen die Daten mit einer sehr viel höheren Frequenz auf. Hochfrequenten Handelsdaten, auch Intraday Daten genannt, enthalten also mehrere Beobachtungen bzw. Aufzeichnungen des Kurses pro Tag. Diese können z.B. alle 5 Minuten, 10 Minuten oder stündlich aufgezeichnet worden sein. Grundsätzlich führen hochfrequente Daten zwar im Allgemeinen zu präziseren Schätzungen, allerdings sollten speziell auf wenig liquiden Märkten bzw. bei wenig gehandelten Unternehmen eher längere Intervalle gewählt werden, um „Lücken“ in dem Datensatz möglichst zu vermeiden (Vgl. Poon und Granger, 2005).

Klassische Volatilitätsmodelle wie das ARCH/GARCH Modell benötigen äquidistante Daten. Das heißt, diese können zwar auf hochfrequente Daten angewendet werden, jedoch nicht ohne weiteres auf ultra-hochfrequente Daten mit nicht äquidistanten Zeitabständen zwischen den einzelnen Beobachtungen. Um diese Modelle auf ultra-hochfrequente Daten anwenden zu können, kann eine Aggregation der einzelnen Beobachtungen durchgeführt werden, so dass aus den ultra-hochfrequenten Daten hochfrequente Daten errechnet werden. Hierzu müssen die aufgezeichneten Beobachtungen zu einem festen Intervall zusammengefasst werden. Dies können die o.g. Intervalllängen von 1, 5 oder 10 Minuten sein oder sogar aggregiert bis zu einer Intervalllänge von einem Tag. Die Wahl einer geeigneten Intervalllänge ist allerdings recht schwierig, was ein grundsätzlicher Punkt bei der Verwendung

von Handelsdaten ist. Sollen generell Daten mit einer sehr kleinen Intervalllänge, d.h. mit einer hohen Frequenz, benutzt werden? Oder sind Daten mit einer höheren Intervalllänge gleichwertig oder sogar besser geeignet? Was sind die Vorteile der jeweiligen Intervalllängen? Für diese Fragestellungen kommt es immer auf den jeweiligen Untersuchungsgegenstand an. Soll z.B. ein Value-at-Risk⁶ berechnet werden oder ist die Handelsaktivität der Untersuchungsgegenstand? Generell kann eine ökonometrische Analyse sicherlich tiefer gehen, wenn Daten mit einer hohen Frequenz benutzt werden. Bei einem zu groß gewählten Intervall (niedrige Frequenz) kann viel von der Mikrostruktur der Daten verloren gehen, die jedoch auch nicht immer benötigt werden. Weitere wichtige und für diese Arbeit relevante Eigenschaften der ultra-hochfrequenten Daten sollen daher noch einmal veranschaulicht werden.

Vorbemerkung: Alle statistischen und ökonometrischen Analysen dieser Arbeit wurden mit *R*, einer Open-Source Software, durchgeführt. *R* wird als „eine interpretierte Programmiersprache zur statistischen Datenanalyse“ beschrieben (Vgl. Cribari-Neto und Zarkos, 1999). *R* entstand 1997 als Open-Source Alternative zur damals verbreiteten kommerziellen Statistik-Software *S-PLUS*. Die Programmiersprache *R* ist derjenigen von *S-PLUS* nachgebildet. Darüber hinaus ist die Software effizient in der Anwendung und ein leistungsfähiges Werkzeug für die Analysen unterschiedlichster Art. Da *R* eine Open-Source Software ist, kann jeder Benutzer an der Entwicklung, in Form der Erstellung von Programmpaketen, teilnehmen. Dieser Aspekt macht es möglich, dass fast alle ökonometrischen Fragestellungen in *R* implementiert werden können. Es sei weiterhin erwähnt, dass in dieser Arbeit die aktuellsten Erweiterungspakete von *R* verwendet werden. Zu nennen sind hierbei u.a. die Erweiterungspakete *fACD*, *fields*, *fgarch*, *rgl*, *rugarch*, *sm* sowie *highfrequency*.

2.2.1 Umfang und Beschaffenheit des Datenmaterials

In dieser Arbeit werden für die Berechnung der Volatilität und der Handelswartezeiten, Datensätze (Kursreihen) von verschiedenen Unternehmen und Indizes verwendet. Zu diesen zählen primär die Daten bzw. die historischen Aktienkurse der Unternehmen Allianz und BMW, stellvertretend für deutsche Unternehmen, und die Daten/historischen Aktienkurse von ExxonMobil (im Folgenden: Exxon) und Wal-Mart Stores (im Folgenden: Walmart), stellvertretend für US-amerikanische Unternehmen. Die beiden zuletzt genannten

⁶Der Value-at-Risk ist ein Risikomaß, welcher genauer im Unterkapitel 2.6 eingeführt wird.

Unternehmen wurden ausgewählt, da diese die beiden größten Unternehmen sind (gemessen an dem Umsatz⁷), die im S&P 500 gelistet sind. Für die Klasse der Indizes werden vorrangig der deutsche DAX 30 (im Folgenden: DAX) und der US-amerikanische S&P-500⁸ verwendet. Für einige Analysen werden zusätzlich die Daten des FTSE 100⁹ und des Nikkei¹⁰ verwendet.

Die primären Datenbeispiele bzw. die dahinterstehenden Unternehmen sollen im Folgenden kurz mit einigen Unternehmenskennzahlen vorgestellt werden: Die BMW AG (mit der ISIN: DE0005190003) hatte im Geschäftsjahr 2013 einen Umsatz von 76,06 Mrd. (EUR) und beschäftigt insgesamt etwa 110.000 Mitarbeiter. Das Unternehmen wurde 1916 gegründet und hat seinen Hauptsitz in München/Deutschland. Es besitzt zum Ende des Beobachtungszeitraumes eine Marktkapitalisierung von etwa 58,42 Mrd. (EUR).¹¹

Die Allianz SE (mit der ISIN: DE0008404005) hatte im Geschäftsjahr 2013 einen Umsatz von 110,77 Mrd. (EUR) und beschäftigt insgesamt etwa 147.000 Mitarbeiter. Das Unternehmen wurde 1890 gegründet und hat seinen Hauptsitz ebenfalls in München/Deutschland. Es besitzt zum Ende des Beobachtungszeitraumes eine Marktkapitalisierung von etwa 63,26 Mrd. (EUR).¹²

Für verschiedene Analysen werden die Datensätze in der bearbeiteten Form verwendet. Dabei wurden aus den ultra-hochfrequenten Handelsdaten 1-minütige Handelsdaten generiert. Diese sollten nach den ultra-hochfrequenten Handelsdaten einen möglichst tiefen Einblick in das Handelsgeschehen des jeweiligen Unternehmens geben. Datenquelle für die Rohdaten und den in dieser Arbeit verwendeten ultra-hochfrequenten und hochfrequenten Daten ist die Datenbank: Thomson Reuters Tick History.¹³ Von den zur Verfügung stehenden ultra-hochfrequenten Daten wurden alle für diese Arbeit nicht relevanten Elemente entfernt. So sind bspw. alle Quotes, Käufer/Verkäufer IDs, Bid/Ask Kurse und Dividenden für die Untersuchungen in dieser Arbeit irrelevant. Die verwendeten Handelswartezeiten

⁷ Der Umsatz für Exxon lag im Jahr 2013 bei 438,25 Mrd. US-Dollar und für Walmart bei 476,2 Mrd. US-Dollar.

⁸ Standard & Poor 500 ist ein Aktienindex, der die Aktien von 500 der größten börsennotierten US-amerikanischen Unternehmen umfasst. Der S&P 500 ist nach der Marktkapitalisierung gewichtet und gehört zu den meistbeachteten Aktienindizes der Welt.

⁹ Der FTSE 100 Index ist der wichtigste britische Aktienindex. FTSE steht dabei für *Financial Times Stock Exchange*.

¹⁰ Der Nikkei ist Asiens bedeutendster Aktienindex und umfasst insgesamt 225 Aktien.

¹¹ Vgl. BMW Group: Geschäftsbericht, 2013.

¹² Vgl. Allianz: Konzern Geschäftsbericht, 2013.

¹³ Zu erreichen unter: <https://tickhistory.thomsonreuters.com>.

wurden direkt aus den Handelszeiten errechnet.¹⁴ Datenquelle aller niederfrequenten, bzw. täglichen Daten ist die Datenbank der historischen Kurse von „Yahoo Finance“.¹⁵

2.2.2 Anzahl und Verteilung von ultra-hochfrequenten Daten

Da bei ultra-hochfrequenten Daten jede einzelne Transaktion aufgezeichnet wird, ist die Anzahl der Beobachtungen erwartungsgemäß sehr hoch (siehe dazu auch die Ergebnisse der Tabelle 2.1).

Speziell über einen Zeitraum von mehreren Jahren kann die Anzahl der Beobachtungen schnell in einem hohen bis sehr hohen siebenstelligen Bereich liegen, was in Tabelle 2.1 anhand der in dieser Arbeit verwendeten Datensätze veranschaulicht wird. Damit zählen ultra-hochfrequente Daten bereits zu der Kategorie *Big Data*.¹⁶ Dieser Aspekt ist jedoch weniger problematisch, da mit der Rechenleistung von zeitgemäßen Computersystemen und aktuellen Analyseprogrammen wie *R* relativ leicht mit einer solchen Menge an Daten umgegangen werden kann. Weiterhin besteht immer die Möglichkeit, die Daten je nach Untersuchungsgegenstand zu bearbeiten oder zu filtern. Das bedeutet, es werden bspw. nur die Käufe, Verkäufe, Renditen oder (nach einer Berechnung) die Handelswartezeiten betrachtet. Eine weitere Eigenschaft, die aus Tabelle 2.1 entnommen werden kann, ist, dass die Anzahl an Beobachtungen (die der realisierten Trades) relativ stark variiert:

Tabelle 2.1: Exemplarische Beobachtungsanzahlen der ultra-hochfrequenten Daten

Untern./Index	Beobachtungszeitraum	Durchschn. Beob./Tag	Anzahl gesamt
Allianz	02.01.2006 - 31.09.2014	10.429	23,215.497
BMW	02.01.2006 - 31.09.2014	7.039	15,670.792
DAX 30	02.01.2006 - 31.09.2014	51.098	113,744.388

Die in der Tabelle genannten Beobachtungszeiträume für die ultra-hochfrequenten Daten umfassen jeweils 2.226 Handelstage. Während die BMW AG etwa 15,67 Millionen Beob-

¹⁴ Ein exemplarischer Teil (Fünf Minuten eines zufällig ausgewählten Tages und Unternehmens) dieses ultra-hochfrequenten Datensatzes ist in Anhang A.1 dargestellt.

¹⁵ zu erreichen unter: <https://de.finance.yahoo.com>.

¹⁶ Der Begriff Big Data ist ein Synonym für die Bedeutung großer Datenvolumen in verschiedensten Anwendungsbereichen, sowie der damit verbundenen Herausforderung, diese verarbeiten zu können. Er beschreibt Datenbestände, die aufgrund ihres Umfangs, ihres Unterschiedlichkeit oder ihrer Schnelligkeit nur begrenzt durch aktuelle Datenbanken und „Daten Management Tools“ verarbeitet werden können.

achtungen über die gesamte Periode aufweist (im Durchschnitt 7.039 pro Tag), besteht der Datensatz der Allianz SE aus insgesamt etwa 23,22 Millionen Beobachtungen (10.429 im Durchschnitt pro Tag).

Der Hauptgrund von variierenden Beobachtungsanzahlen ist die eigentliche Unternehmensgröße bzw. die Marktkapitalisierung des jeweiligen Unternehmens.¹⁷ Dabei spielt ein „Global Player“ erwartungsgemäß eine andere Rolle auf dem Finanzmarkt und wird öfter gehandelt als eine kleinere Aktiengesellschaft (Vgl. dazu auch die Aussagen aus Abschnitt 2.1.1). Der Datensatz des DAX 30 ist erwartungsgemäß um ein Vielfaches größer. Über den o.g. Beobachtungszeitraum wurden insgesamt 113,74 Millionen Trades aufgezeichnet (51.089 im Durchschnitt pro Tag).

2.3 Einführung in die Klasse der ARCH/GARCH Modelle

Grundlage für das von Bollerslev 1986 eingeführte *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) Modell ist das 1982 von Engle eingeführte *Autoregressive Conditional Heteroskedasticity* (ARCH) Modell. Diese Modelle gehören mittlerweile zu den wichtigsten Modellen im Bereich der ökonometrischen Analyse von Finanzmärkten. Grundsätzliche Motivation für die Entwicklung des ARCH Modells war die Untersuchung der Entwicklung der Volatilität und der Volatilitätscluster in Finanzzeitreihen. In diesem Zusammenhang galt es, die zeitabhängige (bedingte) Standardabweichung im Verlauf darzustellen. Bis zu der Einführung dieses Modells war die gängigste Methode eine feste Anzahl von Beobachtungen zu wählen und für diese dann die Standardabweichung zu bestimmen. Die vordefinierte Beobachtungsanzahl wurde bei diesem Modell sequentiell über die zu betrachtende Zeitreihe „geschoben“, womit sukzessive die Standardabweichung bestimmt wurde. Bei dieser *rolling window* Methode hatten jedoch alle Beobachtungen das gleiche Gewicht. Engle verstand es, dass näher zurückliegende Beobachtungen ein höheres Gewicht haben sollten als weiter zurückliegende und entwickelte daraufhin das ARCH Modell. Bei dem ARCH Modell hängen die bedingten Varianzen von den quadrierten vergangenen Werten der Zeitreihe ab. Fortan war es also möglich, die variierende bedingte Varianz von Finanzzeitreihen mit einem Modell darzustellen. Aufgrund der außerordent-

¹⁷ „Der gesamte Marktwert des Eigenkapitals eines Unternehmens entspricht dem Marktpreis der Aktie mal die Anzahl an Aktien. Der Marktwert einer Aktie hängt nicht von den historischen Kosten der Vermögensgegenstände des Unternehmens ab, sondern vielmehr davon, was diese nach Ansicht der Investoren in Zukunft erwirtschaften.“ (Vgl. Berk und DeMarzo Grundlagen der Finanzwirtschaft, 2011).

Die parametrische und semiparametrische Analyse von
Finanzzeitreihen

Neue Methoden, Modelle und
Anwendungsmöglichkeiten

Peitz, C.

2016, XXIV, 260 S. 144 Abb. in Farbe., Softcover

ISBN: 978-3-658-12261-4