
Verteilungseigenschaften der Renditen von Kryptowährungen: Sind sie mit Aktien vergleichbar?

ARMIN VARMAZ UND STEPHAN ABÉE

Armin Varmaz, Hochschule Bremen, E-Mail: armin.varmaz@hs-bremen.de
Stephan Abée, Hochschule Bremen, E-Mail: stephan.abee@hs-bremen.de

Zusammenfassung: Neben Bitcoin existieren über 1 500 weitere Kryptowährungen, die sich durch die Art der Nutzung oder durch die zugrunde liegende Blockchain-Technologie voneinander erheblich unterscheiden. Die meisten dieser Währungen lassen sich auf Börsen und Marktplätzen handeln und können als Investitionsobjekte dienen. In diesem Beitrag werden die empirischen Verteilungseigenschaften ihrer Renditen für einen sehr breiten Querschnitt untersucht und mit denen von Aktienrenditen verglichen. Die Renditen von Kryptowährungen weisen viele ähnliche Charakteristika zu den Aktienrenditen auf: Renditebeobachtungen häufen sich um den Erwartungswert, die Autokorrelation ist, wenn überhaupt, nur sehr schwach, das Phänomen des Volatility-Clusterings und der Asymmetrie von Gewinnen und Verlusten ist vorhanden, ein Faktor kann circa 60 Prozent der gemeinsamen Variation der Renditen erklären und es existiert ein Wochentageffekt. Dagegen können im Querschnitt der Kryptowährungen keine Heavy-Tails identifiziert werden und der Momentum-Effekt ist nur sehr schwach ausgeprägt. Die Ergebnisse lassen die Vermutung zu, nach der die Renditeeigenschaften von Kryptowährungen nicht wesentlich von denen der Aktien abweichen.

Summary: There are more than 1,500 other cryptocurrencies, which differ significantly from each other in terms of their usage or the underlying blockchain technology. Most of these cryptocurrencies can be traded on exchanges and can serve as investment instruments. In this paper, the empirical distribution properties of their returns for a very broad cross-section are examined and compared with those of stock returns. Returns on cryptocurrencies have several characteristics similar to equity returns: Returns are more likely observable around the averages; the autocorrelation of returns is very weak; the phenomenon of volatility clustering and the asymmetry of gains and losses do exist; the factor analysis of the returns reveals that one factor (the first principal component) explains about 60 percent of the common variation of returns; there is a weekday effect. However, there are some differences. For example, no heavy-tails can be identified and the momentum effect is only very weak. The results suggest that the stylized facts of cryptocurrency returns are not very different from stock returns.

→ JEL classification: G11, G15

→ Keywords: Kryptowährung, Bitcoin, Renditen, Verteilungen, PCA, Kryptoportfolios

I Einleitung

Kryptowährungen („Kryptos“) zeichnen sich im letzten halben Jahrzehnt durch einen Mittelzufluss von über 500 Milliarden US-Dollar und aktuell durch eine breite öffentliche Aufmerksamkeit aus.¹ In vielen Fällen handelt sich bei den Kryptos nicht um Währungen für den allgemeinen Zahlungsverkehr, sondern um sogenannte Tokens, die im Zuge von „Initial Coin Offering“ (ICO) zur Finanzierung von Unternehmensvorhaben in frühen Phasen der Öffentlichkeit angeboten werden.² In einer losen Analogie lassen sie sich im Sinne der Finanzierung und im Sinne der Kapitalmarkttheorie mit Aktien vergleichen. Daher ist das Ziel dieses Beitrags ein Vergleich der empirischen Verteilungseigenschaften von Kryptos mit denen von Aktien, indem die bekannten empirischen Regelmäßigkeiten der Aktienmärkte für die Krypto-Märkte analysiert werden. Die Finanzierung durch Tokenausgabe anstelle der Aktienemissionen erscheint als ein interessantes Forschungsfeld, um die Erkenntnisse der traditionellen Finanzierungs- und Kapitalmarkttheorie durch neue Beobachtungen zu überprüfen. Im Unterschied zu Venture-Capital-Gesellschaften und zum Crowdfunding, die jeweils ebenfalls Unternehmen in frühen Phasen finanzieren, ist der Zugang zu den Krypto-Daten vergleichsweise einfach und der Querschnitt der Daten breit. Zusätzlich handelt es sich dabei um tatsächliche Marktpreise, die in der Theorie die Allokations- und die Koordinationsfunktion auf den Märkten übernehmen. Dagegen handelt es sich bei den Daten von Venture-Capital-Gesellschaften oftmals um angenommene, berechnete Werte.

Die (implizite oder explizite) Annahme zahlreicher Kapitalmarkttheorien sind unabhängig und identisch verteilte (i. i. d.) Renditen, die einer Normalverteilung mit konstantem Erwartungswert und konstanter Varianz folgen.³ Diese Renditeeigenschaft resultiert aus der Annahme über die Nutzung neuer Informationen durch rationale, nutzenmaximierende Entscheider, wobei die zukünftigen Informationen annahmegemäß unbekannt und ex-ante zufällig sind sowie diskret (oder stetig) auf dem Markt erscheinen.⁴ Die Entscheider nehmen informationsinduzierte Handlungen vor, die eine Änderung der Preise hervorrufen. Im Zentrum der nachfolgenden Ausführung steht die Analyse der univariaten Renditegenerierungsprozesse, deren theoretische, unbdingte Verteilungseigenschaften aus den Kapitalmarkttheorien bekannt sind.⁵

Die Arbeiten von Fama (1963, 1965), Mandelbrot (1963, 1967), Mandelbrot und Taylor (1967) haben erhebliches Interesse an der Analyse der Verteilungseigenschaften von Aktienrenditen ausgelöst. Die Mehrzahl der empirischen Arbeiten lehnt die Annahme der Normalverteilung ab. Fama (1963, 1965) und Mandelbrot (1963) haben die stabile Pareto-Verteilung als eine alternative Verteilung für die Aktienrenditen vorgeschlagen. Trotz der anfänglichen Beliebtheit weist die stabile Pareto-Verteilung für die Aktienrenditen zwei Nachteile auf. Zum einen erlaubt die theoretische Verteilung bei spezifischen Verteilungsparametern eine unendlich hohe Varianz der Renditen. Gerade für die Risikoanalyse und -modellierung ist eine unendliche Varianz nachtei-

1 Eine Einführung in die Kryptowährungen wird von Glas und Poddig (2019) in diesem Heft geleistet.

2 Zu den ICOs vgl. z.B. Varmaz und Varmaz (2019) in diesem Heft.

3 Als ein Beispiel sei die „Portfolio-Selection-Theorie“ von Markowitz (1952) genannt. Vergleiche auch Aparicio und Estrada (2001).

4 In diesem Beitrag wird dem Informationsverständnis von Fama und Laffer (1971), Hirshleifer (1971), Hirshleifer und Riley (1979) gefolgt. Diese Definition ist auch konsistent mit der Definition von Shannon (1948) in der Kommunikationstheorie.

5 Die bedingten Renditenverteilungen werden in diesem Beitrag nicht untersucht. ARCH/GARCH-Modelle, die von Engle (1982) und Bollerslev (1986) eingeführt wurden, sind in diesem Zweig der empirischen Forschung besonders beliebt.

lig. Zum anderen belegen empirische Studien Verletzungen der theoretischen Aggregationsregel bezüglich der Volatilität, wenn beispielsweise die Datenfrequenz von Tages- auf Monats- oder Jahresdaten geändert wird.⁶ Die Ergebnisse bezüglich der Renditeeigenschaften von Renditen heben neben der stabilen Pareto-Verteilung besonders die t- und die Extremwertverteilung als geeignete Kandidaten hervor. Daher fokussieren sich die nachfolgenden empirischen Analysen auf diese drei theoretischen Verteilungen.

Die empirische Forschung hat neben der Ablehnung der Normalverteilung weitere Gegebenheiten (sogenannte Anomalien) identifiziert, die sich in nahezu allen Aktienrenditen beobachten lassen. Zur sprachlichen Unterscheidung zu den CAPM-Anomalien wird nachfolgend die Bezeichnung Stylized-Facts verwendet. Als Stylized-Facts werden die Eigenschaften von Aktienrenditen bezeichnet, die unabhängig von der betrachteten zeitlichen Periode oder des geografischen Marktes festgestellt worden sind. Als Beispiele seien die Kalenderanomalien, Heavy-Tails, Volatility-Clustering, Gewinn-Verlust-Asymmetrie und Momentum-Effekte et cetera genannt. Die Untersuchung von Kryptos in Bezug auf die Stylized-Facts wird ebenfalls Gegenstand der nachfolgenden Analysen sein.

Nach den empirischen Ergebnissen der vorliegenden Arbeit weisen die Renditen von Kryptos zahlreiche Stylized-Facts auf, die in analoger Weise für die Aktienrenditen dokumentiert sind. Die Analyse der Häufigkeitsverteilung zeigt im Vergleich zu der Normal- und t-Verteilung mit 10 und 100 Freiheitsgraden ein vermehrtes Auftreten der Renditen um den Erwartungswert auf. Allerdings können im Vergleich zu den theoretischen Verteilungen keine Heavy-Tails in den empirischen Krypto-Renditen (im Querschnitt) festgestellt werden. Die Autokorrelation der Krypto-Renditen ist im Querschnitt nur schwach ausgeprägt. Für die 1. Lag-Ordnung kann eine leicht erhöhte, negative Autokorrelation beobachtet werden. Die Asymmetrie zwischen den Gewinnen und Verlusten in Bezug auf die Anzahl und die Höhe der Renditen wird in analoger Weise für die Krypto-Renditen bestätigt. Das Phänomen des Volatility-Clusterings sowie des Wochentagseffektes sind ebenfalls vorhanden. Die in den Aktienrenditen weit verbreiteten Momentum-Effekte können für die Kryptos nicht in ähnlicher Weise bestätigt werden. Dieses Ergebnis ist nicht konsistent mit den früheren Arbeiten von (Hubrich (2017), Rohrbach, Suremann und Osterrieder (2017), die für einen deutlich geringeren Querschnitt der Kryptos Momentum-Effekte gefunden haben. Die Ergebnisse von Hauptkomponentenanalysen deuten auf die besondere Bedeutung der ersten Hauptkomponenten hin. Sie kann circa 60 Prozent der gemeinsamen Variation von Krypto-Renditen erklären.

Im nachfolgenden Kapitel 2 wird ein kurzer Literaturüberblick, gefolgt von der Beschreibung der Daten im Kapitel 3, gegeben. Die Ergebnisse der empirischen Untersuchungen werden im Kapitel 4 präsentiert. Ein Fazit wird im Kapitel 5 gezogen.

6 Ähnliche Ergebnisse bezüglich der fehlenden Aggregation der Volatilität wurden für die „Wurzel-T“-Regel festgestellt, vgl. z.B. Danielsson und Zigrand (2006), Wang, Yeh und Cheng (2011).

2 Literatur

Die spezifischen Verteilungseigenschaften von Renditen sind sowohl für die akademische Forschung als auch für die finanzwirtschaftliche Praxis bedeutend. Die genaue Verteilungsspezifikation ist beispielsweise eine grundlegende Voraussetzung für das Risikomanagement, weil die Definition geeigneter Risikokennziffern von der Renditeverteilung abhängt.⁷ Die Normalverteilung wird in der finanzwirtschaftlichen Literatur u.a. aufgrund des zentralen Grenzwertsatzes am häufigsten verwendet. Eine Vielzahl von Arbeiten hat jedoch Abweichungen von der Normalverteilung für die Aktienrenditen dokumentiert (für einen ersten Überblick vgl. z.B. Fama 1963, 1965, Mandelbrot 1963, 1967, Officer 1972, Hagerman 1978, Gray und French 1990, Mittnik und Rachev 1993, Tay und Wallis 2000, Cont 2001). Die stabile Pareto-Verteilung, die Extremwertverteilungen und die t-Verteilungen wurden als geeignete Kandidaten zur Modellierung der Rendite vorgeschlagen (vgl. Mittnik und Rachev 1993). Die t-Verteilung bietet dabei in gewöhnlichen Marktphasen eine gute Anpassungsgüte an. Die stabile Verteilung und die Extremwertverteilungen passen die Renditeverteilung vor allem in Stichproben mit „Crashes“ gut an. Für die Kryptos sind bislang nur vereinzelte empirische Analysen über die Verteilungseigenschaften vorgenommen worden. Diese Analysen werden in der vorliegenden Arbeit geleistet.

Ein Großteil der Stylized-Facts bezüglich der Aktienrenditen lässt sich anhand der Verstöße gegenüber der i.i.d. Eigenschaft und/oder der Normalverteilungsannahme in den traditionellen Kapitalmarktmodellen klassifizieren. Die Anzahl der in der Literatur dokumentierten Stylized-Facts ist hoch und daher ist jegliche Auswahl subjektiv und willkürlich. In den empirischen Untersuchungen werden folgende, subjektiv ausgewählte, Stylized-Facts berücksichtigt:

1. Autokorrelation von Renditen: Die Mehrzahl empirischer Studien hat keine signifikanten linearen Autokorrelationen feststellen können.⁸ Die Autokorrelation von Renditen wird als ein Hinweis auf ihre Prognostizierbarkeit interpretiert, die mit der klassischen Informationseffizienz nicht vereinbar ist.
2. Heavy-Tails: Die unbedingte empirische Renditeverteilung hat eine deutlich höhere Wahrscheinlichkeit für extreme Werte als es die Normalverteilung vorschlägt (vergleiche zum Beispiel Lamoureux und Lastrapes 1990, Poddig 1996, Cont 2001).
3. Asymmetrie zwischen Gewinnen und Verlusten: Die Anzahl der Perioden mit positiven und negativen Renditen sollten approximativ identisch sein, wenn die Renditen einer symmetrischen Verteilung (mit Erwartungswert von 0) folgen. Empirisch lassen sich mehr Perioden mit positiven als mit negativen Renditen beobachten. Gleichzeitig gibt es häufig zu extremen Preisrückgängen einer Periode keine äquivalent hohen Preisanstiege.

7 Die ökonomische Implikation der Verteilungsform lässt sich als ein Vergleich von der Rendite einer Periode zu der Summe der Rendite über sehr viele Perioden (nachfolgend: Gesamtrendite) veranschaulichen. Wenn die Renditen einer Normalverteilung folgen, dann wird (sehr wahrscheinlich) die Rendite einer Periode im Vergleich zur Gesamtrendite gering ausfallen. Die Nutzung der Normalverteilung wird gerade als die Summe von vielen kleinen Änderungen motivieren. Wenn die Renditen aus der Extremwertverteilung oder der t-Verteilung stammen, dann wird (sehr wahrscheinlich) die Gesamtrendite durch einige sehr hohe oder sehr niedrige Renditen determiniert. Folglich wird der Verlauf der Preisentwicklung eher durch sprunghafte Bewegungen gekennzeichnet sein.

8 Stellvertretend sei auf Fama (1970, 1991) verwiesen.

4. Volatility-Clustering: Die Kennzahlen zur Messung der (unbedingten) Volatilität zeigen eine hohe positive Autokorrelation über einen Zeitraum von mehreren Perioden an. Folglich neigen die Renditeschwankungen persistent in der Höhe zu bleiben (vgl. u.a. Campbell und Cochrane 2000, Andersen et al. 2001, Silvennoinen und Teräsvirta 2009).
5. Langsamer Rückgang der Autokorrelation von absoluten Renditen: Die Autokorrelation von absoluten Renditen sinkt langsam als eine Funktion der Zeit (vgl. McNeil und Frey 2000, Cont 2001).
6. Leverage-Effekt: Die gemessene Volatilität ist negativ mit den realisierten Renditen korreliert, das heißt positive (negative) realisierte Renditen geschehen in Zeiten mit niedriger (hoher) Volatilität (Campbell und Hentschel 1992).

Die saisonalen Regelmäßigkeiten, auch als Kalenderanomalien bezeichnet, in den Aktienrenditen stellen einen weiteren Stylized-Fact dar, der in der Literatur ausgiebig untersucht wurde. In diesem Zusammenhang sind der Januar-, der Monatswechsel-, der Feiertags-, der Halloween- sowie der Wochentageffekt, zum Beispiel der Montageseffekt, sehr gut dokumentiert.⁹ Aufgrund der sehr kurzen Datenhistorie für die Kryptos kann lediglich der Wochentageffekt sinnvoll ausgewertet werden. Der Wochentageffekt ist bislang in der Literatur in Bezug auf die Kryptos kein Gegenstand einer wissenschaftlichen Analyse gewesen.

Eine weitere Regelmäßigkeit in den Aktienrenditen bezieht sich auf die Klasse der Momentum- und Reversaleffekte. Die empirische Analysen von De Bondt and Thaler (1984 und 1987), Jegadeesh und Titman (1993) zeigen die Persistenz der vergangenen, kurzfristigen Performance in Querschnitt von US-Aktien auf. Beispielsweise werden die Aktien mit einem hohen vergangenen Momentum im Querschnitt auch in Zukunft eine höhere Performance im Vergleich zu den Aktien mit einem niedrigen Momentum aufweisen (vgl. u.a. Asness, Moskowitz und Pedersen 2013). Nachfolgende Studien haben diese Effekte für andere Anlageklassen, Zeiträume und geografische Märkte bestätigt (vgl. Jegadeesh und Titman 1993, Lakonishok, Shleifer und Vishny 1994, Schierck, De Bondt und Weber 1999, Glaser und Weber 2003, Cochrane 2011). Für die Kryptos sind empirische Analysen zu den Momentum- und Short-Term-Reversal-Effekten ebenfalls durchgeführt worden (vergleiche Hubrich 2017, Rohrbach, Suremann und Osterrieder 2017). Die vorliegende Arbeit erweitert die bisherigen Ansätze in Bezug auf drei Aspekte. Erstens, die bisherigen Arbeiten bezogen sich auf ein eher kleines Anlageuniversum von Kryptos. In der vorliegenden Arbeit werden nahezu alle Kryptos untersucht, wodurch der Querschnitt der Analyse deutlich größer wird und der „Survivorship-Bias“ minimiert wird.¹⁰ Zweitens, die Auswahl der Stichprobe zur Vermeidung von „Survivorship-Bias“ wird sehr sorgfältig gegenüber anderen Einflüssen abgewogen. Drittens, es wird hier untersucht, ob es eine gemeinsame Variation der Renditen von Momentum- und Reversal-Portfolios gibt.

9 Stellvertretend für Vielzahl von Studien vgl. Dzhavarov und Ziemba (2010).

10 Vgl. hierzu auch die Ausführungen in Glas und Poddig (20119). Survivorship-Bias beschreibt die nachträgliche, implizit oder explizit vorgenommene Entfernung von gescheiterten Kryptos aus der Stichprobe. Somit werden nur die erfolgreichen Kryptos analysiert.

Die Auswahl der Stylized-Facts ist indes unvollständig und lässt weitere Fragestellungen aus der empirischen Kapitalmarktforschung offen. Dazu zählen u.a. die Fragen nach der Stationarität und Ergodizität der Krypto-Renditen sowie nach der Kleinstichprobenproblematik.¹¹

3 Daten

Die täglichen Daten sind durch mehrere API-Schnittstellen von Krypto-Börsen und Krypto-Datenanbietern für den Zeitraum 31.12.2014 bis 31.1.2018 bezogen. Insgesamt sind die Daten von 72 Krypto-Börsen und über Crypto-Compare abgefragt worden. Die nachfolgenden Analysen beziehen sich auf die Tageschlusskurse in US-Dollar. Um die Zuverlässigkeit der Daten zu erhöhen, werden in einem ersten Schritt nur die Daten zu einem Krypto von der Krypto-Börse mit dem jeweils höchsten Handelsvolumen von und zu US-Dollar herangezogen. Somit sollten extreme Preisausschläge vermieden werden, die auf fehlende Liquidität zurückzuführen gewesen wären. In einem zweiten Schritt werden die Korrelationen zwischen den Schlusskursen eines Kryptos von der handelsvolumenstärksten Börse mit den Schlusskursen von Crypto-Compare für dasselbe Krypto verglichen. Es werden alle Kryptos aus der Stichprobe entfernt, deren Korrelation unter 0,95 ist.¹² Mit den gültigen Schlusskursen werden stetige Renditen bestimmt. Die Stichprobenbereinigungen zielen auf die Erhöhung der Datenvalidität ab. Sie könnten ebenfalls in der gleichen Weise von einem tatsächlichen Investor zum Zeitpunkt der Beobachtung durchgeführt werden und beeinflussen die nachfolgenden Ergebnisse nicht.

Gemäß Ince und Porter (2006) können auch kommerzielle Datenbanken erhebliche Qualitätsmängel aufweisen. Ihrem Vorschlag folgend werden die Beobachtungen aus der Stichprobe entfernt, deren kumulierte stetige Rendite über zwei aufeinander folgenden Tagen höher als 138,63 Prozent (entspricht 300 Prozent diskrete Rendite) ist. Derartig hohe positive Renditen können auf Datenbankfehler zurückzuführen sein. Ferner führen viele Börsen die Preise von Kryptos auch dann fort, wenn gar kein Handel stattfindet oder die Kryptos bereits vom Markt verschwunden sind.¹³ Daher werden die Beobachtungen aus der Stichprobe entfernt, für die sich der Schlusskurs im Vergleich zum Vortag nicht ändert. Nach der Bereinigung der Daten gemäß der beschriebenen Methode von Ince und Porter (2006) werden die stetigen Renditen zusätzlich durch das (1-Prozent-, 99-Prozent-)Winsorizing um Ausreißer bereinigt.

Eine weitere Besonderheit im Bereich von Kryptos kann zur Verzerrung der Ergebnisse führen. Die Mehrzahl von Kryptos dient der Finanzierung von Unternehmen und Unternehmensprojekten in sehr frühen Phasen. Diese Finanzierung wird im Kryptobereich als „Initial Coin Offering“ (ICO) bezeichnet. In der Studie von Varmaz und Varmaz (2019) und indirekt in der Studie von Adhami, Giudici und Martinazzi (2017) wird ein erhebliches Underpricing von ICOs für die ersten 30 Tage aufgedeckt. Die aktuelle Stichprobe bezieht sich auf einen relativ kurzen Zeitraum,

11 Mit der Kleinstichprobenproblematik ist die eher geringe Anzahl der Beobachtungen in empirischen Stichproben gemeint, während die statistische Theorie in der Regel von einer sehr großen Anzahl der Beobachtungen ausgeht. Für eine Diskussion bei einer finanzwirtschaftlichen Anwendung vgl. Scherer (2002).

12 Diese heuristische Festlegung erfolgt aufgrund teilweise fehlender Werte. Durch unterschiedliche Zeitreihenhistorien können sich unterschiedliche Standardabweichungen ergeben, die trotz identischer gültiger Werte zu einer Korrelation unter 1 führen.

13 Ähnliche Ergebnisse zeigen Ince und Porter (2006) auch für kommerzielle Datenbankanbieter auf.

Tabelle 1

Deskriptive Statistiken zum Panel der stetigen Renditen aller Kryptos sowie zur Anzahl der Kryptos pro Periode

	Rendite in Prozent	Anzahl
Median	0,23	547
Mittel	0,16	668
25-Prozent-Perzentil	-3,84	482
75-Prozent-Perzentil	4,02	863
Std.	15,28	273
# Beob.	688 978	
p-Wert	0,00	

Std. zeigt die Standardabweichung, # Beob. die Anzahl der Beobachtungen und p-Wert die Irrtumswahrscheinlichkeit des einfachen t-Testes auf Mittelwerte an.

der durch eine Vielzahl zeitlich geclusterter, stattfindender ICOs gekennzeichnet ist. Um die Auswirkung des Underpricings auf die Ergebnisse in dieser Studie zu senken, werden 30 Renditebeobachtungen nach dem ICO aus der Stichprobe entfernt.


In der Tabelle 1 sind deskriptive Statistiken zur bereinigten Stichprobe über die stetigen Renditen und die Anzahl von Kryptos zusammengefasst. Die Spalte „Rendite“ in Prozent bezieht sich auf ein Panel der täglichen Renditen aller Kryptos für den gesamten Zeitraum. Der Median der Renditen ist positiv und leicht höher als der Mittelwert. Typischerweise wird für die Aktienrenditen das umgekehrte Ergebnis beobachtet. Der Mittelwert der Krypto-Renditen ist mit einer Irrtumswahrscheinlichkeit von nahezu 0 Prozent signifikant von null zu unterscheiden. Die Standardabweichung im Panel der Renditen ist mit 15 Prozent pro Tag deutlich höher im Vergleich zu den Aktien.¹⁴ Die Anzahl der Kryptos schwankt im Zeitablauf erheblich und liegt im Mittel bei circa 670 Kryptos.

In der Literatur wird auf die Asymmetrie zwischen positiven und negativen Aktienrenditen hingewiesen. Die Boxplots in der Abbildung 1 stellen einen Versuch dar, die Relationen zwischen positiven und negativen Krypto-Renditen zu untersuchen. Für den linken Boxplot mit der Bezeichnung „Anzahl“ wird die Kennzahl „Asymmetrie-Anzahl“ bestimmt, indem für jeden Krypto die Anzahl der positiven Renditen durch die Anzahl der negativen Renditen geteilt wird. Der Median der Kennzahl ist deutlich über Eins und deutet auf eine höhere Anzahl von positiven Renditen hin. Bei der Interpretation der Ergebnisse ist jedoch der signifikant positive Mittelwert für die Renditen der Stichprobe zu beachten. Bei einer symmetrischen Verteilung mit einem positiven Mittelwert beziehungsweise Median ist auch die Wahrscheinlichkeit von positiven Renditen höher. Daher reflektiert möglicherweise das Ergebnis lediglich diese Verteilungseigenschaft. Der mittlere Boxplot mit der Bezeichnung „Mittelwert“ veranschaulicht die Kennzahl „Asymmetrie-Mittel“, für die für jeden Krypto der Mittelwert der positiven Renditen durch den Mittelwert der absoluten negativen Renditen geteilt wird. Der Median von Asymmetrie-Mittel ist leicht unterhalb

14 Vgl. z.B. Fieberg, Varmaz und Poddig (2016). Annualisiert mit der Wurzel-T-Regel entspricht sie einer Volatilität von circa 287 Prozent.

Abbildung 1

Boxplot der Kennzahlen Asymmetrie-Anzahl, Asymmetrie-Mittel sowie gewichteten Asymmetrie-Mittel



von eins. Somit scheinen die mittleren Renditen von positiven und negativen Beobachtungen sich zu entsprechen. Allerdings ist die Anzahl positiver Renditen in der Stichprobe höher. Der rechte Boxplot mit der Bezeichnung „Mittelwert gewichtet“ korrigiert daher um die unterschiedliche Anzahl von positiven und negativen Beobachtungen bei der Berechnung der jeweiligen Mittelwerte. In diesem Boxplot wird die in der Literatur beobachtete Asymmetrie zwischen den positiven und negativen Renditen auch für die Kryptos deutlich. Tendenziell können somit die Befunde für die Aktien über die Asymmetrie der Gewinne und Verluste bestätigt werden.

4 Ergebnisse

4.1 Verteilungseigenschaften

Eine relativ einfache Möglichkeit der Analyse von Verteilungseigenschaften ist die Konstruktion von Häufigkeitsverteilungen. Dabei wird für jeden Krypto der empirische Anteil der Beobachtungen innerhalb einer vorgegebenen Standardabweichung um den Mittelwert bestimmt. Anschließend wird der empirische Anteil mit dem theoretischen Anteil verglichen, der sich ergeben würde, wenn die Renditen aus einer ausgewählten theoretischen Verteilung gezogen wären. Für den Vergleich werden die Standardnormalverteilung sowie die t-Verteilung herangezogen. Die Normalverteilung stellt den Standardvergleich dar. Die t-Verteilung kann die empirisch beobachtete Eigenschaft von Heavy-Tails bei Aktienrenditen durch die geeignete Wahl des Verteilungsparameters (Anzahl von Freiheitsgraden) besser als die Normalverteilung anpassen. Daher wird sie auch berücksichtigt.

Tabelle 2

Anteil der erwarteten und empirisch festgestellten Beobachtungen in Prozent für unterschiedliche Sigma-Bereiche um den Erwartungswert

Sigma	0,5	1	1,5	2	3	4	5
Theoretisch							
Standard	38,29	68,27	86,64	95,45	99,73	99,99	100,00
t(100)	38,18	68,03	86,32	95,18	99,66	99,99	100,00
t(10)	37,21	65,91	83,55	92,66	98,67	99,75	99,95
Empirisch							
Mittel	50,64	71,91	83,29	92,39	99,90	100,00	100,00
Median	49,17	71,50	83,16	93,47	100,00	100,00	100,00
Min	28,00	60,78	70,45	81,44	90,48	94,32	98,89
Max	88,10	91,49	94,59	100,00	100,00	100,00	100,00

Standard (t) beschreibt die Standardnormalverteilung (t-Verteilung). Die Werte in den Klammern bei der t-Verteilung zeigen die Anzahl der Freiheitsgrade an.

Die Tabelle 2 stellt die Ergebnisse eines Vergleichs der empirischen und theoretischen Anteile der Beobachtungen innerhalb vorgegebener Standardabweichungsintervalle (Sigma-Intervall) um den Erwartungswert dar. In der Tabelle werden die Anteile für die Sigma-Intervalle 0,5, 1, 1,5, 2, 3, 4 und 5 angegeben. Für die empirischen Anteile werden deskriptive Statistiken ausgewiesen. Beispielsweise wird im 0,5-Sigma-Intervall für die Standardnormalverteilung (t(10), t(100)) ein Anteil von 38,29 Prozent (37,21 Prozent, 38,18 Prozent) der Beobachtungen erwartet. Der empirische Anteil beträgt im Mittel (Median) 50,64 Prozent (49,17 Prozent), das heißt circa die Hälfte aller Beobachtungen liegt im 0,5-Sigma-Intervall. Die Häufung der Daten um den Erwartungswert wird ebenfalls für die Aktien beobachtet.¹⁵ Im Unterschied zu den Ergebnissen für Aktien sind die empirischen Verteilungen im Mittel weniger stark durch extreme Beobachtungen geprägt. Selbst im Vergleich zur Normalverteilung ist der Anteil extremer Beobachtungen nicht als besonders auffällig einzustufen. Für die Aktienmärkte sind Renditebeobachtungen selbst außerhalb des 5-Sigma-Intervalls für den Querschnitt aller Aktien nicht untypisch.

Die Vergleiche der Häufigkeiten geben einen ersten Einblick über die Verteilungseigenschaften von Krypto-Renditen. Für eine detaillierte Analyse werden die euklidischen Distanzen $d(F(x), F(\hat{x}))$ zwischen einer ausgewählten theoretischen Verteilungsfunktion $F(x)$, die auf die Renditen eines Kryptos angepasst wird, und der empirischen Verteilungsfunktion $F(\hat{x})$ bestimmt.¹⁶ Den Ergebnissen für Aktienrenditen folgend werden für die empirischen Analysen die t-Verteilung, die Normalverteilung, die verallgemeinerte Extremwertverteilung vom Typ 1 sowie die stabile Pareto-Verteilung herangezogen. Die euklidischen Distanzen werden jeweils für die gesamte Bandbreite der Verteilung sowie für die untersten und obersten 50 Beobachtungen bestimmt.

15 Stellvertretend für eine sehr hohe Zahl von Studien vgl. Fama (1965).

16 Ähnliche Auswertungen werden beispielsweise von Mitnik und Rachev (1993) für die Renditen von S&P500 Aktien durchgeführt.

Tabelle 3

Deskriptive Statistiken der euklidischen Distanzen zwischen der empirischen Verteilungsfunktion und der jeweiligen theoretischen Verteilungsfunktion

Panel A: Alle Daten				
	t-Vert.	Norm	EW	ST
Median	0,823	0,733	1,493	0,355
Mittel	1,180	1,041	1,802	1,147
25-Prozent-Perzentil	0,457	0,388	0,861	0,263
75-Prozent-Perzentil	1,740	1,560	2,583	0,581
Std.	0,941	0,811	1,101	3,341
# Beob.	1 146	1 146	1 146	1 146
Panel B: Die untersten 50 Beobachtungen				
Median	0,269	0,283	0,290	0,120
Mittel	0,308	0,337	0,335	0,277
25-Prozent-Perzentil	0,196	0,147	0,208	0,089
75-Prozent-Perzentil	0,339	0,508	0,397	0,182
Std	0,218	0,210	0,201	0,880
Panel C: Die obersten 50 Beobachtungen				
Median	0,289	0,299	0,295	0,104
Mittel	0,335	0,343	0,432	0,257
25 Prozent Perzentil	0,217	0,180	0,233	0,076
75 Prozent Perzentil	0,381	0,499	0,540	0,153
Std.	0,215	0,197	0,294	0,870

t-Vert. (Norm, EW, ST) steht für die t-Verteilung (Normalverteilung, verallgemeinerte Extremwertverteilung vom Typ 1, stabile Pareto-Verteilung Std. zeigt die Standardabweichung an. # Beob. ist die Anzahl der Beobachtungen.

In Tabelle 3 sind die deskriptiven Statistiken über die euklidischen Distanzen für die ausgewählten Verteilungen dargestellt. Die Ergebnisse sind insoweit überraschend, weil mit der Ausnahme der Extremwertverteilung vom Typ 1 die euklidischen Distanzen im Mittel approximativ gleich hohe Werte aufweisen, wenn alle Daten analysiert werden (Panel A). Somit können die t-Verteilung, die Normalverteilung sowie die stabile Pareto-Verteilung im Mittel die empirischen Renditeverteilungen gleich gut wiedergeben. Das Ergebnis für die Extremwertverteilung vom Typ 1 ist nicht überraschend, weil nach der Tabelle 2 die Häufigkeit extremer Werte für die Kryptos im Mittel sehr gering ist. Der Mittelwert der euklidischen Distanzen für die stabile Pareto-Verteilung ist jedoch stark verzerrt, da dieser höher als das 75-Prozent-Perzentil ist. Wenn die Analyse auf die Mediane abgezielt wird, scheint die stabile Pareto-Verteilung einen Vorteil aufzuweisen. In Panel B beziehungsweise C werden die euklidischen Distanzen für die untersten beziehungsweise obersten 50 Beobachtungen ausgewiesen. Die Ergebnisse bleiben in der Tendenz ähnlich mit leichten Vorteilen für die stabile Pareto-Verteilung.

Die Ergebnisse in diesem Abschnitt deuten insgesamt nicht auf spezifische Unterschiede von Krypto-Renditen im Vergleich zu den Aktienrenditen hin, die in der Literatur diskutiert werden.

Wenn eine Besonderheit hervorgehoben werden soll, wäre es die im Mittel überraschend gute Anpassung der Normalverteilung an die Krypto-Renditen.¹⁷

4.2 Autokorrelation und Volatility-Clustering

Die Untersuchung der Autokorrelation von Aktienrenditen stellte historisch die frühen Versuche dar, ihre Prognostizierbarkeit und mittelbar die Informationseffizienz der Märkte zu untersuchen. Das mehrheitliche Ergebnis dieser Studien ist das Fehlen einer ökonomisch und/oder statistisch signifikanten Autokorrelation.¹⁸ Ausgeprägte, hohe und persistente Autokorrelationen würden im Widerspruch zu der Informationseffizienz der Märkte stehen, weil sich dann durch Analysen vergangener Preisbewegungen einfach eine Handelsstrategie ableiten ließe.¹⁹ In diesem Abschnitt werden die Untersuchungen von Autokorrelationen auf die Kryptos übertragen. Mithilfe der Autokorrelationen lassen sich auch Aussagen über mögliches unbedingtes Volatility-Clustering treffen. Dazu wird in der Literatur vorgeschlagen, die Autokorrelation von absoluten Renditen sowie von quadrierten Renditen zu untersuchen.²⁰ Gemäß der Ergebnisse für die Aktienrenditen wird eine hohe Autokorrelation von absoluten und von quadrierten Renditen erwartet. Die Autokorrelation sollte zusätzlich nur langsam abfallen, um ein (unbedingtes) Volatility-Clustering anzuzeigen.

Eine einfache Darstellung der empirischen Autokorrelationen verschiedener Lag-Ordnungen gibt die Abbildung 2. Die Boxplots repräsentieren die wichtigsten Kennzahlen über die Autokorrelationen pro Lag-Ordnung. Insgesamt scheint im Querschnitt keine ausgeprägte Autokorrelation ab der 2. Lag-Ordnung zu existieren. In der Abbildung 2 sind zur Orientierung die 10 Prozent und 90 Prozent Perzentile der Autokorrelationen der jeweiligen Lag-Ordnung eingezeichnet. Die Autokorrelation für die 1. Lag-Ordnung ist erwartungsgemäß im Mittel und absolut höher als die restlichen. Sie ist (im Mittel und absolut) etwas höher als die Autokorrelationen für die Aktienmärkte, die sich um circa 0,1 bewegt.²¹ Überraschend ist ihr negatives Vorzeichen im Querschnitt der Kryptos. Für die Aktienrenditen wird in den empirischen Studien mehrheitlich eine positive Autokorrelation erster Ordnung berichtet. Eine positive (negative) Autokorrelation spricht für eine kurzfristige Beibehaltung (Umkehrung) der Entwicklung von Renditen.

Die Abbildung 3 stellt die Autokorrelation absoluter Renditen (Abbildung 3(a)) und quadrierter Renditen (Abbildung 3(b)) dar. In Übereinstimmung mit den Ergebnissen für die Aktienrenditen sind diese Autokorrelationen positiv und hoch. Die Ergebnisse geben erste Hinweise auf (unbedingtes) Volatility-Clustering in den Krypto-Renditen. Die hohe Autokorrelation absoluter Renditen in den niedrigen Ordnungen deutet auf gleich hohe Schwankungen von Renditen hin, die aufeinanderfolgen. Somit folgen auf hohe (niedrige) Renditeschwankungen auch hohe (niedrige)

17 Die Analysen für einzelne Kryptos können abweichende Ergebnisse liefern. Für eine Analyse der (bedingten) Verteilungseigenschaften von Bitcoin vgl. Osterrieder und Lorenz (2017).

18 Vgl. u.a. Fama (1970 und 1991), Pagan (1996), Lux und Marchesi (1999).

19 Solche Handelsstrategien werden auch als Statistical-Arbitrage beziehungsweise Technische Analyse bezeichnet.

20 Die Nutzung von absoluten und quadrierten täglichen Renditen als ein Proxy für die Volatilität ist gängige Praxis in der empirischen Kapitalmarktforschung, vgl. z.B. Campbell et al. (2001).

21 Für eine Diskussion über die ökonomische und statistische Signifikanz der Autokorrelation von Renditen vgl. z.B. Campbell et al. (1997), Deetz et al. (2009) und Sidorovitch (2010).

Abbildung 2

Boxplot für die Autokorrelation unterschiedlicher Lag-Ordnungen über alle Kryptos





Abbildung 3


Boxplots der Autokorrelation unterschiedlicher Lag-Ordnungen über alle Kryptos

(a) Absolute Renditen



Fortsetzung Abbildung 3

(b) Quadrierte Renditen



Schwankungen. Die niedrigere Autokorrelation höherer Ordnungen für die absoluten Renditen deutet auf wechselnde Phasen von hohen und niedrigen Renditeschwankungen hin. Der in der Abbildung 3(b) dargestellte Verlauf der Autokorrelation für die quadrierten Renditen zeichnet im Mittel ein sehr ähnliches Bild. Dort lassen sich auch Hinweise auf die Autokorrelation der Volatilität finden.

Die Autokorrelation der gewöhnlichen, der absoluten und der quadrierten Krypto-Renditen lässt sich für praktische Zwecke kaum von den Werten für die Aktienrenditen unterscheiden. Nachrichtlich kann berichtet werden, dass die Autokorrelation der im Querschnitt gleichgewichteten Rendite aller Kryptos „Marktrendite“ ebenfalls keine Besonderheiten aufweist.


4.3 Saisonale Effekte und Kennzahleneffekte

Die saisonalen Effekte, die auch als Kalenderanomalien bezeichnet werden, sind Regelmäßigkeiten von Aktienrenditen, die sich in bestimmten Abständen und zu bestimmten Kalenderzeiten wiederholen (vgl. French 1980, Keim 1983). Der Wochentageffekt (auch Wochenendeffekt) wird zu diesen Kalenderanomalien gezählt. Der Wochentageffekt zeichnet sich für die Aktien durch im Mittel negative Montags- und positive Freitagsrenditen aus. Weil es scheinbar keinen besonderen Grund gibt, warum die Renditen an einem bestimmten Tag unterschiedlich zu anderen Tagen sein sollen, werden die Wochentageffekte häufig als ein Beleg gegen traditionelle Kapitalmarktmodelle benutzt. French (1980) untersucht zwei Modelle, die konkurrierende Voraussagen über die Höhe der Periodenrenditen anbieten. Nach der Kalenderzeit-Hypothese findet der Renditegenerierungsprozess kontinuierlich statt. Weil die Aktien über das Wochenende nicht gehandelt werden, sollte ihre Rendite am Montag dreimal so hoch sein wie an anderen Handelstagen. Analoges gilt für die Renditen nach Feiertagen, an denen die Börsen geschlossen sind. Nach der Handelszeit-Hypothese findet die Erwartungsbildung nur während der Handelszeiten statt. Da-


Abbildung 4

Median und mittlere Rendite von Kryptos für Wochentage

(a) Median



(b) Mittelwert



her sollte die erwartete Rendite in jeder Zeitperiode identisch sein. Überraschenderweise sind die Ergebnisse von French (1980) für den US-amerikanischen Markt mit keiner Hypothese konsistent, weil die Montagsrendite signifikant negativ ist, während die Rendite anderer Tage positiv ist.

Die Abbildung 4 fasst die Mediane und die Mittelwerte der Renditen für alle Wochentage zusammen. Im Unterschied zu den Aktienrenditen sind die Montagsrenditen positiv, am höchsten und signifikant von Null unterschiedlich.²² Die Dienstagrenditen, die die zweithöchsten Werte aufweisen, sind statistisch nicht von Null zu unterscheiden. Die hohen Renditen am Montag

22 Die Signifikanzergebnisse sind nicht tabelliert und werden nachrichtlich genannt.

Tabelle 4

Portfolios

Strategie	1	2	3	4	5	6	7	8	9	10
Median der Portfoliorenditen										
Mom	-0,035	0,080	0,109	0,026	0,143	0,126	0,132	0,170	0,229	0,154
Reversal	0,065	-0,066	0,133	0,186	0,193	0,217	0,176	0,251	0,193	-0,113
Std(30)	0,066	0,658	0,524	0,528	0,091	0,369	0,195	0,182	0,027	0,162
Mittelwert der Portfoliorenditen										
Mom	-0,168	0,019	-0,015	0,017	-0,107	-0,142	0,132	0,095	0,185	0,079
Reversal	-0,052	-0,142	0,108	0,064	0,174	0,010	0,201	0,134	0,166	-0,163
Std(30)	-0,103	0,515	0,232	0,317	-0,223	-0,398	0,054	0,105	0,016	0,144
Standardabweichung der Portfoliorenditen										
Mom	0,4669	0,5381	0,5370	0,3955	0,4732	0,6021	0,4154	0,4510	0,4397	0,4511
Reversal	0,5457	0,4662	0,3883	0,4229	0,4379	0,4273	0,4289	0,4275	0,4537	0,6290
Std(30)	1,5356	0,7622	0,6266	0,9915	1,0568	1,4341	0,3976	0,3612	0,9515	0,4426
Mittelwert der Sortierungsvariable pro Portfolio										
Mom	-1,912	-0,980	-0,506	-0,178	0,140	0,360	0,594	0,681	1,037	1,757
Reversal	-0,665	-0,392	-0,201	-0,071	0,114	0,107	0,154	0,204	0,401	0,816
Std(30)	0,001	0,005	0,006	0,006	0,007	0,008	0,017	0,033	0,047	0,088

In der Tabelle sind die Mediane, Mittelwerte und die Standardabweichungen der Renditen von zehn Portfolios, die aus Sortierungen basierend auf Momentum (Mom), Short-Term-Reversal (Reversal) sowie dem gleitenden Durchschnitt der Volatilität vergangener 30 Tagesrenditen (Std(30)) gebildet sind. Alle Zahlen sind in Prozent angegeben (das Prozent-Zeichen ist weggelassen). Die Portfolios sind am Ende eines Monats auf der Basis vergangener Sortierungsvariablen gebildet und einen Monat lang gehalten. Die Portfoliorenditen wurden gleichgewichtet und täglich neu berechnet.

wären konsistent mit der Kalenderzeit-Hypothese, wenn die Kryptos nicht jeden Tag gehandelt werden könnten.²³

Der letzte Vergleich zwischen den Krypto-Renditen und den Aktienrenditen bezieht sich auf die Analyse von sortierten Portfolios. Für die Bildung von sortierten Portfolios werden Sortierungsvariablen benötigt, für die ein linearer Zusammenhang zu den erwarteten Renditen vermutet wird. Für die Aktienmärkte liegt eine nahezu unüberschaubare Anzahl potenzieller Sortierungsvariablen vor.²⁴ Aufgrund der Datenverfügbarkeit werden als Sortierungsvariablen das (12,2)-Momentum, das kurzfristige Reversal sowie die historische Volatilität der Kryptos festgelegt. Das (12,2)-Momentum ist täglich basierend auf der kumulierten Rendite der letzten 12 Monate, aber ohne die Berücksichtigung des jüngsten, unmittelbar vorangegangenen Monats, berechnet. Der jüngste Monat wird aufgrund des kurzfristigen Reversal-Effekts weggelassen, der von Jegadeesh (1990) dokumentiert wurde. Dieser kurzfristige Reversal-Effekt wird ebenfalls als die zweite Sor-

23 Wie stark über das Wochenende in den Krypto-Märkten gehandelt wird, ist nicht Gegenstand des vorliegenden Beitrages. Es bleibt eine spannende Frage, in wie weit ein potenziell niedriges Handelsvolumen über das Wochenende und/oder die Abwesenheit von Marktteilnehmern den Erwartungsbildungsprozess beeinflussen.

24 Für einen Vergleich von 100 Anomalien vergleiche Jacobs (2015).

tierungsvariable herangezogen und als die kumulierte Rendite des jüngsten unmittelbar vorangegangenen Monats berechnet. Die historische Volatilität wird als die Standardabweichung der letzten 30 Handelstage bestimmt. Die Auswahl der historischen Volatilität ist durch den Leverage-Effekt motiviert, der als Stylized-Fact für die Aktienrenditen gilt. Die Mittelwerte der Sortierungsvariablen sind in der Tabelle 4 für verschiedene Portfolios angegeben.

Die Portfoliobildung wird basierend auf den Sortierungsvariablen vorgenommen. Dabei werden für jede Sortierungsvariable jeweils zehn Portfolios gebildet. Am Ende eines jeden Monats werden die Kryptos nach der jeweiligen, aufsteigend sortierten Variable in 10 Portfolios sortiert und einen Monat lang gehalten. Die gleich gewichteten Portfoliorenditen werden täglich berechnet. Die Mediane, Mittelwerte und die Standardabweichungen der täglichen Renditen für die zehn Portfolios sind ebenfalls in der Tabelle 4 zusammengefasst.

Die Ergebnisse für die Kryptos sind nicht konsistent mit den typischen Ergebnissen für Aktien. Der Momentum-Effekt, der nahezu in allen geografischen Märkten festgestellt wurde, ist lediglich in Ansätzen erkennbar. Dieser Befund ist nicht durch eine geringe Anzahl von Kryptos in den Portfolios zu erklären, aber eventuell durch die sehr kurze Zeitreihe. Ein linearer Zusammenhang zwischen dem Reversal und den erwarteten Portfoliorenditen sowie zwischen der historischen Volatilität und den erwarteten Portfoliorenditen lässt sich nicht erkennen. Die Ergebnisse in der Tabelle 4 sind auch nicht konsistent mit den Ergebnissen vorangegangener Studien für die Kryptos, die jedoch mit deutlich kleineren Querschnitten operierten (Hubrich 2017, Rohrbach, Suremann und Osterrieder 2017). Möglicherweise sind ihre Ergebnisse durch Survivorship-Bias positiv verzerrt.

4.4 Hauptkomponentenanalyse

In einem letzten Schritt wird die gemeinsame Variation von Krypto-Renditen analysiert. Speziell wird mit der Hauptkomponentenanalyse (PCA) untersucht, wie viel der gemeinsamen Variation von Krypto-Renditen durch die Hauptkomponenten erklärt werden kann. Die Durchführung der PCA ist an unterschiedliche Bedingungen geknüpft, von den für die nachfolgende Analyse vor allem diese Eigenschaften der Stichprobe bedeutend sind:²⁵

1. Die Anzahl der Zeitpunkte soll viel größer als die Anzahl der Assets sein. Dieser Eigenschaft genügt für praktische Zwecke kein Wertpapiermarkt.
2. Die Wahrscheinlichkeit, die richtige Anzahl von Hauptkomponenten zu identifizieren, sinkt mit zunehmendem residualem Risiko der einzelnen Wertpapiere.

Die beiden Eigenschaften treffen im negativen Sinne auch für die vorliegende Stichprobe zu. Durch den relativ kurzen Zeitraum, für den die Krypto-Renditen vorliegen, und die vergleichsweise hohe Anzahl von Kryptos im Querschnitt ist die erste Eigenschaft nicht erfüllt. Die Ergebnisse aus den vorangegangenen Kapiteln deuten auf sehr hohe residuale Risiken hin. Nach der Tabelle 1 ist die Standardabweichung von täglichen Renditen im Panel aller Kryptos circa 15,28 Prozent. Wenn die Standardabweichung abweichend zur Tabelle 1 zuerst für jedes Krypto einzeln bestimmt und dann davon der Mittelwert gebildet wird, liegt sie bei 15,01 Prozent. Durch die


25 Eine ausführliche Darstellung wird in Connor (1984) gegeben.

Bildung von Portfolios lässt sich die Standardabweichung der Renditen erheblich reduzieren. Nach den Ergebnissen aus der Tabelle 4, in der die Standardabweichungen für unterschiedliche Portfolios berichtet werden, liegt das tägliche Portfoliorisiko zwischen 0,5 Prozent und 1,5 Prozent. Somit ist das Potenzial für die Risikodiversifikation und somit auch die Höhe des residualen Risikos erheblich.

Basierend auf den Arbeiten von Connor (1984), Connor und Korajczyk (1989) sind in der Literatur verschiedene Lösungsansätze formuliert worden, um mit beiden Problemen der PCA in der empirischen Forschung umzugehen (Ludvigson und Ng 2007). Ein möglicher Ansatz besteht in der Bildung von Portfolios, um einerseits das residuale Risiko zu senken und andererseits die Anzahl der Objekte im Querschnitt zu reduzieren (Connor und Korajczyk 1986). Die Portfoliobildung hat mehrere Freiheitsparameter, die vom Forscher subjektiv vorzugeben sind. Dazu zählen die Anzahl der zu bildenden Portfolios sowie die Art der Portfoliobildung, für die prinzipiell sehr viele Alternativen existieren. Für die nachfolgenden Analysen werden 30 gleichgewichtete Zufallsportfolios gebildet. Dabei wird jedes Krypto zufällig genau einem Portfolio zugeordnet. Mit der subjektiv gewählten Anzahl der Portfolios werden zwei Ziele verfolgt. Zum einen soll die Anzahl der Kryptos in jedem Portfolio für eine ausreichende Diversifikation sorgen. Im Schnitt werden in jedem Portfolio pro Zeitpunkt circa 22 Kryptos sein, da die mittlere Anzahl der Kryptos pro Zeitpunkt 668 beträgt (vergleiche Tabelle 1). Diese mittlere Anzahl von Kryptos pro Portfolio kann als ausreichend angesehen werden, um eine naive Diversifikation zu erreichen, wenn sich die Ergebnisse von Aktienmärkten auf die Kryptos übertragen lassen. Zum anderen soll mit 30

Abbildung 5


Portfoliorenditen



In der Abbildung sind die Boxplots für die mittleren täglichen Renditen der 30 Zufallsportfolios jeweils über 10 000 Läufe dargestellt.

Abbildung 6

Portfoliovarianzen



In der Abbildung sind die Boxplots für die Standardabweichungen der täglichen Renditen der 30 Zufallsportfolios jeweils über 10000 Läufe dargestellt.

Abbildung 7

Boxplot der Eigenwerte von 30 Hauptkomponenten





Abbildung 8

Boxplot der Anteile erklärter Varianz für 30 Hauptkomponenten



Zufallsportfolios die Anzahl der zu untersuchenden Objekte im Querschnitt noch hinreichend hoch für die PCA sein. Mithilfe der 30 Portfolios können grundsätzlich 30 Hauptkomponenten bestimmt und ihr jeweiliger Einfluss auf die Variation der Portfoliorenditen analysiert werden. Die gewählte Vorgehensweise induziert jedoch Zufälligkeiten bei der Portfoliobildung, die die Aussagekraft der gewonnenen Ergebnisse einschränken könnten. Um den Einfluss der Zufälligkeit zu minimieren, wird die beschriebene Vorgehensweise im Rahmen einer Simulation zehntausendmal wiederholt.

Die Ergebnisse für die Zufallsportfolios sind in den Abbildungen 5 und 6 veranschaulicht. Die Renditen der Portfolios weisen ähnliche Eigenschaften auf, daher besteht kein Grund zur Annahme einer besonderen Systematik, die durch die Bildung der Portfolios induziert werden könnte.

Die aggregierten Ergebnisse bezüglich der Eigenwerte sowie der erklärten Anteile für die 30 Hauptkomponenten sind in den Abbildungen 7 und 8 durch Boxplots dargestellt. Die Boxplots veranschaulichen die wichtigsten deskriptiven Statistiken pro Hauptkomponente über alle Simulationen. Nach der Auswertung scheint die erste Hauptkomponente mit Abstand den größten Einfluss aufzuweisen.²⁶ Die erste Hauptkomponente erklärt im Schnitt 57 Prozent der Variation von Portfoliorenditen. Diesen Befund gibt es analog auf den Aktienmärkten. Die Hauptkomponenten 2 bis 4 tragen ebenfalls zur Erklärung der gemeinsamen Kovarianz jedoch in einem sehr

26 Detaillierte Ergebnisse sind auf Anfrage erhältlich.

viel geringeren Ausmaß bei. Insgesamt erklären die ersten drei Hauptkomponenten circa 70 Prozent der gemeinsamen Variation der Zufallsportfoliorenditen.

5 Fazit

Das Ziel des Beitrags ist die Analyse der empirischen Verteilungseigenschaften von Krypto-Renditen. Nach den empirischen Ergebnissen der vorliegenden Arbeit weisen die Renditen von Kryptos zahlreiche Stylized-Facts auf, die in analoger Weise für die Aktienrenditen in der Literatur dokumentiert sind. Dazu gehören u.a. die gute Anpassungsgüte von Normal- und t-Verteilung an die Krypto-Renditen, die fehlende Autokorrelation sowie die Asymmetrie zwischen den Gewinnen und Verlusten in Bezug auf die Anzahl und die Höhe der Renditen. Das Phänomen des Volatility-Clusterings sowie des Wochentageffektes sind ebenfalls vorhanden, woraus sich weitere interessante Forschungsfragen ergeben. Die in den Aktienrenditen weit verbreiteten Momentum-Effekte können für die Kryptos nicht in ähnlicher Weise bestätigt werden. Die Ergebnisse von mehreren Hauptkomponentenanalysen zeigen auf die Bedeutung der ersten drei Hauptkomponenten hin, die zusammen zwischen 60 Prozent und 70 Prozent der gemeinsamen Variation erklären können.

Literaturverzeichnis

- Adhami, S., C. Giudici und S. Martinazzi (2017): Why Do Businesses Go Crypto? An Empirical Analysis of Initial Coin Offerings. SSRN Electronic Journal. doi: 10.2139/ssrn.3046209.
- Andersen, T. G. et al. (2001): The distribution of realized stock return volatility. *Journal of Financial Economics*. Elsevier, 61 (1), 43–76.
- Aparicio, F. M. und J. Estrada (2001): Empirical distributions of stock returns: European securities markets, 1990–95. *The European Journal of Finance*. Taylor Francis, 7 (1), 1–21.
- Asness, C. S., T. J. Moskowitz und L. H. Pedersen (2013): Value and momentum everywhere. *The Journal of Finance*. Wiley Online Library, 68 (3), 929–985.
- Bollerslev, T. (1986): Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31, 307–327.
- Campbell, J. Y. et al. (1997): *The econometrics of financial markets*. Princeton University press, Princeton, NJ.
- Campbell, J. Y. et al. (2001): Have individual stocks become more volatile? An empirical exploration of idiosyncratic risk. *The Journal of Finance*, 56 (1), 1–43.
- Campbell, J. Y. und J. H. Cochrane (2000): Explaining the poor performance of consumption-based asset pricing models, *The Journal of Finance*, 55 (6), 2863–2878.
- Campbell, J. Y. und L. Hentschel (1992): No news is good news. *Journal of Financial Economics*, 31 (3), 281–318.
- Cochrane, J. H. (2011): Presidential address: Discount rates. *The Journal of Finance*, 66 (4), 1047–1108.
- Connor, G. (1984): A unified beta pricing theory. *Journal of Economic Theory*. Elsevier, 34 (1), 13–31.
- Connor, G. und R. A. Korajczyk (1986): Performance measurement with the arbitrage pricing theory. A new framework for analysis. *Journal of Financial Economics*, 15 (3), 373–394.

- Connor, G. und R. A. Korajczyk (1989): An intertemporal equilibrium beta pricing model. *Review of Financial Studies*, 2 (3), 373–392.
- Cont, R. (2001): Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance*, 1 (2), 223–236.
- Danielsson, J. und J. P. Zigrand (2006): On time-scaling of risk and the square-root-of-time rule. *Journal of Banking and Finance*, 30 (10), 2701–2713.
- De Bondt, W. F. M. und R. H. Thaler (1984): Does the Stock Market Overreact? *Journal of Finance*, 40 (3), 793–805.
- De Bondt, W. F. M. und R. H. Thaler (1987): Further evidence on investor overreaction and stock market seasonality. *Journal of Finance*, 42 (3), 557–581.
- Deetz, M. et al. (2009): An evaluation of conditional multi-factor models in active asset allocation strategies: an empirical study for the German stock market. *Financial Markets and Portfolio Management*, 23 (3), 285–313.
- Dzhavarov, C. und W. T. Ziemba (2010): Do seasonal anomalies still work? *Journal of Portfolio Management*, 36 (3), 93.
- Engle, R. F. (1982): Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50, 987–1007.
- Fama, E. F. (1963): Mandelbrot and the stable Paretian hypothesis. *The Journal of Business*, 36 (4), 420–429.
- Fama, E. F. (1965): The Behavior of Stock-Market Prices. *The Journal of Business*, 38 (1), 34–105.
- Fama, E. F. (1970): Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25, 383–417.
- Fama, E. F. (1991): Efficient capital markets: II. *The Journal of Finance*, 46, 1575–1617.
- Fama, E. F. und A. B. Laffer (1971): Information and capital markets. *The Journal of Business*, 289–298.
- Fieberg, C., A. Varmaz und T. Poddig (2016): Covariances vs. characteristics: what does explain the cross section of the German stock market returns? *Business Research*, 9 (1), 27–50.
- French, K. R. (1980): Stock returns and the weekend effect. *Journal of Financial Economics*, 8 (1), 55–69.
- Glaser, M. und M. Weber (2003): Momentum and Turnover: Evidence from the German Stock Market. *Schmalenbach Business Review*, 55, 108–135.
- Goyal, A. und P. Santa-Clara (2003): Idiosyncratic risk matters! *The Journal of Finance*, 58 (3), 975–1007.
- Gray, J. B. und D. W. French (1990): Empirical comparisons of distributional models for stock index returns. *Journal of Business Finance & Accounting*, 17 (3), 451–459.
- Hagerman, R. L. (1978): More evidence on the distribution of security returns. *The Journal of Finance*, 33 (4), 1213–1221.
- Hirshleifer, J. (1971): The private and social value of information and the reward to inventive activity. *The American Economic Review*, 61 (4), 561–574.
- Hirshleifer, J. und J. G. Riley (1979): The analytics of uncertainty and information-an expository survey. *Journal of Economic Literature*, 17 (4), 1375–1421.
- Hubrich, S. (2017): Know when to hodl them, know when to fohl them: An Investigation of Factor Based Investing in the Cryptocurrency Space. *SSRN Electronic Journal*, 1–54. 10.13140/RG.2.2.35090.96969.
- Ince, O. S. und R. B. Porter (2006): Individual equity return data from Thomson Datastream: Handle with care! *Journal of Financial Research*, 29 (4), 463–479.

- Jacobs, H. (2015): What explains the dynamics of 100 anomalies?, *Journal of Banking and Finance*, 57, 65–85.
- Jegadeesh, N. (1990): Evidence of predictable behavior of security returns. *The Journal of Finance*, 45 (3), 881–898.
- Jegadeesh, N. und S. Titman (1993): Returns to buying winners and selling losers: Implications for stock market efficiency. *The Journal of Finance*, 48 (1), 65–91.
- Keim, D. B. (1983): Size-Related Anomalies and Stock Return Seasonality: Further Empirical Evidence. *Journal of Financial Economics*, 12 (1), 13–32.
- Lakonishok, J., A. Shleifer und R. W. Vishny (1994): Contrarian investment, extrapolation, and risk. *The Journal of Finance*, 49 (5), 1541–1578.
- Lamoureux, C. G. und W. D. Lastrapes (1990): Heteroskedasticity in stock return data: volume versus GARCH effects. *The Journal of Finance*, 45 (1), 221–229.
- Ludvigson, S. C. und S. Ng (2007): The empirical risk-return relation: A factor analysis approach. *Journal of Financial Economics*, 83 (1), 171–222.
- Lux, T. und M. Marchesi (1999): Scaling and criticality in a stochastic multi-agent model of a financial market. *Nature*, 397 (6719), 498–500.
- Mandelbrot, B. (1963): The variation of certain speculative prices. *The Journal of Business*, 36 (4), 394–419.
- Mandelbrot, B. (1967): The variation of some other speculative prices. *The Journal of Business*, 40 (4), 393–413.
- Mandelbrot, B. und H. M. Taylor (1967): On the distribution of stock price differences, *Operations Research*, 15 (6), 1057–1062.
- Markowitz, H. (1952): Portfolio selection. *Journal of Finance*, 7 (1), 77–91.
- McNeil, A. J. und R. Frey (2000): Estimation of tail-related risk measures for heteroscedastic financial time series: an extreme value approach. *Journal of Empirical Finance*, 7 (3), 271–300.
- Mittnik, S. und S. T. Rachev (1993): Modeling asset returns with alternative stable distributions. *Econometric reviews*, 12 (3), 261–330.
- Officer, R. R. (1972): The distribution of stock returns. *Journal of the American Statistical Association*, 67 (340), 807–812.
- Osterrieder, J. und J. Lorenz (2017): A statistical risk assessment of bitcoin and its extreme tail behavior. *Annals of Financial Economics*, 12 (01), 1750003.
- Pagan, A. (1996): The econometrics of financial markets, *Journal of Empirical Finance*, 3 (1), 15–102.
- Poddig, T. (1996): *Analyse und Prognose von Finanzmärkten*. Bad Soden, Uhlenbruch.
- Rohrbach, J., S. Suremann und J. Osterrieder (2017): Momentum and Trend Following Trading Strategies for Currencies Revisited-Combining Academia and Industry. SSRN. doi:10.2139/ssrn.2949379.
- Scherer, B. (2002): Portfolio resampling: Review and critique. *Financial Analysts Journal*, 58 part 6, 98–102.
- Schiereck, D., W. De Bondt und M. Weber (1999): Contrarian and momentum strategies in Germany. *Financial Analysts Journal*, 55, 104–116.
- Shannon, A. (1948): *A Mathematical Theory of Communication*. Urbana: University of Illinois Press.
- Sidorovitch, I. (2010): *Bewertungsmechanismen und der Stand der Integration auf dem europäischen Aktienmarkt*. Berlin/Heidelberg, Pro Business.
- Silvennoinen, A. und T. Teräsvirta (2009): Multivariate GARCH models. In: *Handbook of financial time series*. Springer, 201–229.

- Tay, A. S. und K. F. Wallis (2000): Density forecasting: a survey. *Journal of Forecasting*, 19 (4), 235–254.
- Wang, J. N., J. H. Yeh und N. Y. P. Cheng (2011): How accurate is the square-root-of-time rule in scaling tail risk: A global study. *Journal of Banking and Finance*, 35 (5), 1158–1169.