

Hochschule Darmstadt
Fachbereich Mathematik und
Naturwissenschaften & Informatik

**Wer finanziert den Immobilienboom,
Banken oder Investmentfonds?**

Abschlussarbeit zur Erlangung des akademischen Grades
Master of Science (M.Sc.)
im Studiengang Data Science

vorgelegt von

Valentina Cisternas Seeger

Referent : Prof. Dr. Christoph BECKER
Korreferent : Prof. Dr. Arnim MALCHEREK

Ausgabedatum : 08.08.2022

Abgabedatum : 24.01.2023

Erklärung

Hiermit erkläre ich, dass ich die vorliegende Arbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe.

Soweit ich auf andere Materialien, Texte oder Gedankengänge zurückgegriffen habe, enthalten meine Ausführungen vollständige und eindeutige Verweise auf die Urheber und Quellen. Dies gilt auch für Quellen, die ich selbst für andere Zwecke erstellt habe. Alle weiteren Inhalte der vorgelegten Arbeit stammen von mir im urheberrechtlichen Sinn, soweit keine Verweise und Zitate erfolgen.

Diese Arbeit ist in gleicher oder ähnlicher Form noch bei keiner Prüfung oder Prüfungsbehörde eingereicht worden.

Mir ist bekannt, dass ein Täuschungsversuch vorliegt, wenn die vorstehende Erklärung sich als unrichtig erweist.

Ort, Datum

Unterschrift

Danksagung

Ich möchte mich an dieser Stelle herzlichst bei Professor Dr. Becker und Professor Dr. Malcherek für das Lesen meiner Masterarbeit als Referenten bzw. Korreferenten bedanken. Einen besonderen Dank geht hierbei an Professor Dr. Becker für seine herausragende Betreuung, Zeit und Geduld. Der konstruktive Austausch hat mich sowohl fachlich als auch persönlich sehr bereichert. Mit seiner Begeisterungsfähigkeit in der Vorlesungen wurde sowohl mein Interesse für dieses Fachthema geweckt als auch das Verständnis für Zeitreihenanalyse und Finanzthemen ausgeweitet. Ein großer Dank geht auch an meine Familie, meine Freunde und Kommilitonen, die mich während der Erstellung meiner Masterarbeit unterstützt haben. Ob bei einem gemeinsamen Kaffee, bei einem gemeinsamen Spaziergang, bei einer gemeinsamen Aktivität oder einem Telefonat - ihre Tipps, Ablenkungen, und Unterstützung waren unbezahlbar für mich. Ich möchte mich an dieser Stelle speziell bei meinem Bruder Nico bedanken für seine konstante Unterstützung in jeglicher Form. Ein Dank an alle Korrekturleser, die sich allesamt die Zeit genommen haben, mir mit wertvollen Anmerkungen und Vorschlägen jederzeit zur Seite zu stehen. Ihre kritischen Anmerkungen haben dazu beigetragen, dass ich meine Arbeit auf ein höheres Niveau bringen konnte. Zuletzt möchte ich auch mir für die Geduld, Motivation und Ausdauer danken, die ich während der Erstellung meiner Masterarbeit aufgebracht habe.

abstract Who is financing real estate investments and driving the residential real estate boom in Germany - banks or investment funds? The purpose of this master's thesis is to examine this question by identifying and analysing possible drivers and risk factors on residential real estate prices. This thesis particularly focuses on the response of house price returns on financing shocks of banks or investment funds to understand possible risk factors. For this purpose, various VAR models were estimated and corresponding impulse-response diagrams were used for visualization. The results show that both banks and investment funds financed the real estate boom in Germany. The use of Q-VAR models, as an extension of VAR models with QR, broadens the understanding and explanation of extreme realizations and proves to be suitable in identifying real estate price risks. Using impulse response functions of Q-VAR models, the asymptotic distribution of real estate returns can be illustrated. Furthermore, the work shows that real estate funds and bank loans have distinct effects on different quantiles of real estate returns. Real estate funds prove an amplifying effect on house-price-at-risk, whereas the corresponding bank lending effect stabilizes the house-price-at-risk. Real estate funds can therefore act as a driver for volatility in real estate returns. Thus, also in real estate prices.

Keywords— financialization, real estate prices, real estate boom, Q-VAR, Quantile Regression, real estate financing, real estate funds, bank lending, risk factors

Zusammenfassung Wer finanziert den Immobilienboom in Deutschland: Banken oder Investmentfonds? Das Ziel dieser Masterarbeit ist es, bank- und fonds-spezifische Treiber zu analysieren und mögliche Risikofaktoren auf Wohnimmobilienpreisrenditen zu identifizieren. Dazu wurden verschiedene Regressionsmodelle angewendet. Zudem wurden Reaktionen von Wohnimmobilienpreisrenditen auf einen Finanzierungsschocks bei Banken oder Investmentfonds untersucht. Hierzu wurden verschiedene VAR-Modelle geschätzt und Impuls-Antwort Diagramme zur Visualisierung verwendet. Zur Analyse von möglichen Risikofaktoren wurden QR Modelle geschätzt. Die Verwendung von Q-VAR Modellen, als Erweiterung der VAR Modelle, verstärken das Verständnis und die Erklärung extremer Realisierungen. Zudem erweist sich die Impulsantwortfunktionen der Q-VAR-Modelle als hilfreiches Werkzeug zur Visualisierung der asymptotischen Verteilung von Immobilienrenditen und damit letztendlich auch zur Identifizierung von Immobilienpreisrisiken. Als Resultat zeigt sich, dass sowohl Banken als auch Investmentfonds den Immobilienboom in Deutschland finanzieren. Beim Vergleich privater Wohnungsbaukrediten für Neugeschäft und der Finanzierung über Fonds, erklären die Fonds 24% der Varianz in den Wohnimmobilienpreisen. Im Gegensatz dazu tragen Wohnungsbaukredite für private Haushalte für Neugeschäft nur 7% zur Aufklärung bei. Darüber hinaus zeigt diese Arbeit, dass Immobilienfonds und Bankdarlehen unterschiedliche Auswirkungen auf verschiedene Quantile der Immobilienrenditen haben. Immobilienfonds zeigen dabei einen verstärkenden Effekt auf das Verlustrisiko der Immobilienpreise, während die Bankkredite stabilisierend wirken. Immobilienfonds können daher als Treiber für die Volatilität bei Immobilienrenditen und damit auch Immobilienpreisen wirken.

Keywords— Finanzialisierung, Immobilienpreise, Immobilienboom, Q-VAR, Quantile Regression, Immobilienfonds, Bankkredite, Risikofaktoren, VAR

Inhaltsverzeichnis

Abbildungsverzeichnis	9
Tabellenverzeichnis	11
1. Einleitung	13
1.1. Motivation	14
1.2. Fragestellung und Ziele der Untersuchung	17
1.3. Vorgehen der Untersuchung	18
2. Literaturüberblick	20
2.1. Finanzielle Treiber von Immobilienpreisentwicklungen	20
2.2. Quantilsregression und Anwendungen im Finanzkontext	24
3. Theoretische Grundlagen und Methoden	28
3.1. Grundlagen der deutschen Immobilienwirtschaft	28
3.2. Grundlagen des Asset Pricings und Risikomanagements	32
3.3. Grundlagen der Quantilsregression	37
3.4. Grundlagen der Zeitreihenanalyse	41
3.4.1. Stationarität	43
3.4.2. Abhängigkeit zwischen den Zeitreihenwerten	46
3.4.3. Univariate Analysemethoden	47
3.4.4. Multivariate Analysemethoden	49
3.4.5. Impulse Antwort Funktion (IAF)	53
3.5. Quantil-Vektor Autoregressive Methoden	54
4. Daten	58
4.1. Datengrundlage	58

4.2. Datenvorverarbeitung	60
5. Ergebnisse und Diskussion	63
5.1. Finanzierungseinflüsse auf Immobilienpreisentwicklungen	64
5.1.1. Ergebnisse der Multiplen Linearen Regression	64
5.2. Wechselbeziehung zwischen Banken, Fonds und Immobilienpreisen	66
5.2.1. Ergebnisse des VAR Modells	66
5.3. Untersuchung von Risikofaktoren, Übertragungseffekten und Stress- Szenarien	70
5.3.1. Ergebnisse der univariaten Quantilsregressionsmodelle . .	70
5.3.2. Ergebnisse der multiplen Quantilsregressionsmodelle . . .	72
5.3.3. Ergebnisse der Q-VAR Modelle zur Untersuchung dynami- scher Risikoübertragungen	76
6. Fazit	79
6.1. Zusammenfassung	79
6.2. Schlussfolgerung und Einordnung in den Forschungsstand	80
6.3. Ausblick weiterführende Forschung	81
A. Anhang	83
A.1. Weitere VAR Modelle	83
A.1.1. Kreditvolumen zu BIP Verhältnis vs. Fondsvermögen . . .	83
A.1.2. Wohnbaukredite an Privatpersonen im Neugeschäft vs. Im- mobilienfonds	85
A.2. Parameterschätzer der Q-VAR(1) Modelle	89
Literaturverzeichnis	93

Abbildungsverzeichnis

3.1. Übersicht der Immobilienanlageformen in Deutschland	32
3.2. Die Verlustfunktion der Quantilsregression	40
4.1. relative Entwicklung der Bank-,Investmentfond- und Immobilienpreiszeitreihe(2010=100)	61
4.2. Veränderungsraten der Bank-,Investmentfond- und Immobilienpreiszeitreihe	62
5.1. Autokorrelation der Immobilienpreiszeitreihe	63
5.2. Autokorrelation der Renditezeitreihe R	64
5.3. Antwort der Wohnimmobilienpreise auf einen Einheitsschock der Bankkredite bzw. des Fondsvolumen	69
5.4. Koeffizientenschätzer für die Quantilsregression auf Immobilienrenditen	73
5.5. Prozentuale Veränderungen des Bankkredit und Fondsvolumen im Vergleich zu Immobilienrenditen	77
5.6. Impulse Antwort von verschiedenen Quantilen der Immobilienrenditen	78
A.1. Antwort der Wohnimmobilienpreise auf einen Einheitsschock der Bankkredite bzw. des Fondsvolumen	84
A.2. Zeitreihen für das VAR(2) Modell	85
A.3. Impuls Antwort Funktion: Neubauwohnungspreise	89
A.4. Parameterschätzer im Vergleich beider bivariaten Q-VAR(1) Modelle	90
A.5. Parameterschätzer des bivariaten Q-VAR(1) Modells für Immobilienfonds	91

Abbildungsverzeichnis

A.6. Parameterschätzer des bivariaten Q-VAR(1) Modells für Wohn- baukredite an Privatpersonen	92
--	----

Tabellenverzeichnis

5.1. Multiple Lineare Regression: Einflussstärke des Fonds- und Bankkreditvolumens auf Wohnimmobilienpreise	65
5.2. ADF-Test auf dem Level der Zeitreihen	67
5.3. ADF-Test auf den differenzierten Zeitreihen	68
5.4. Univariate Quantilsregression auf Wohnimmobilienrenditen . . .	71
5.5. Quantilsregression: Risikofaktoren auf Wohnimmobilienrenditen .	75

Abkürzungsverzeichnis

- AR** Autoregressiv
- ARMA** Autoregressiv Moving Average
- ACF** Autokorrelationsfunktion
- ADF-Test** Augmented Dickey-Fuller-Test
- AIC** Akaike Informationskriterium
- BIC** Bayes-Informationskriterium
- BIP** Bruttoinlands Produkt
- BP** Basispunkt
- EZB** Europäische Zentralbank
- IAF** Impuls-Antwort Funktion
- LTV** Loan-to-Value
- MA** Moving Average
- PACF** Partielle Autokorrelationsfunktion
- QR** Quantilsregression
- Q-VAR** Quantil Vektor Autoregressive
- R²** Bestimmtheitsmaß
- VAR** Vektor Autoregressive
- VECM** Vector Error Correction Model
- VIF** Variance Inflation Factor

1. Einleitung

Die Weltwirtschaftskrise von 2008 hat gezeigt, dass die globale Wirtschaft sehr sensibel auf Entwicklungen im Immobilienmarkt reagiert und dass Wechselwirkungen der verschiedenen Märkte weltweit Übertragungseffekte verursacht haben. Es steht daher außer Frage, dass in Immobilien investierende Akteure auf dem Finanzmarkt, die Nachfrage in Immobilien beeinflussen und damit die Preise stimulieren. Im Zuge der Finanzialisierung von Immobilienmärkten und der starken Aktivität von Fonds im Immobiliensektor stellt sich daher die Frage, ob nun die Finanzierungskanäle der Banken oder derjenigen der Investmentfonds ausschlaggebend für die Immobilienpreisentwicklung in Deutschland sind [Rottke and Voigtländer, 2017, S. 38 f.]. Die Immobilienpreise in Deutschland sind in dem letzten Jahrzehnt von einem positiven Aufwärtstrend geprägt und auch bei dem Volumen für Wohnbau-Kredite von Banken sowie dem Fondsvermögen von Investmentfonds lässt sich ein markanter Anstieg erkennen [Dahl and Goralczyk, 2017, S. 8] [Muñoz, 2020]. Dabei stellt sich die Frage, welche Investitionsform den Immobilienmarkt stärker beeinflusst: Ist es der Bankenmarkt, der durch Baukredite private Haushalte und kleine bis mittelständische Unternehmen finanziert, oder ist es der Kapitalmarkt, der vor allem von Investitionen institutioneller Investoren geprägt ist? Welche Finanzierungsarten beeinflussen stärker den Immobilienmarkt und welche Risiken bergen diese? Diese Fragen sollen in der vorliegenden Masterarbeit mithilfe von multivariaten Zeitreihenmodellen untersucht werden. Konkret werden dabei Vektor Autoregressive (VAR) Modelle anhand von Quantilsregressions Theorien auf Quantils Vektor Autoregressive (Q-VAR) Modelle erweitert, um Wechselwirkungen und Risikofaktoren entlang der Quantile zu identifizieren, wobei hierzu das Q-VAR Modell in Strukturform nach [Chavleishvili and Manganelli, 2019] genutzt wird. Die Quantilsregression (QR)

1. Einleitung

ist eine statistische Methode, um bedingte Quantile zu schätzen. Diese bieten eine systematische Strategie zur Untersuchung wie unabhängige Variablen die Lage, Skalierung und Form der ganzen Zielvariablen-Verteilung beeinflussen. Die QR ergibt nicht nur Informationen zur zentralen Lage, sondern auch zum gesamten Eindruck der bedingten Verteilungsfunktion und gilt daher als Verallgemeinerung oder auch Erweiterung der Mittelwertschätzung der klassischen linearen Regression [Koenker, 2005].

1.1. Motivation

Im letzten Jahrzehnt zeichnete sich in Deutschland ein Immobilienboom ab, der von massiv steigenden Immobilienpreisen geprägt war [Dahl and Goralczyk, 2017, S.3].

Mit der Intervention der Europäischen Zentralbank (EZB) im Jahr 2012 zur Rettung von Staaten in der Finanzkrise sanken die Renditen festverzinslicher Anleihen wie Staatsanleihen, was unter anderem zu einem historisch niedrigen niedrigen Zinsniveau zur Folge hatte. Da das langanhaltende Niedrigzinsumfeld den Druck auf festverzinsliche Renditen von Staatsanleihen verstärkte, suchten institutionelle Investoren neue Renditeanreize in anderen Märkten wie dem Immobilienmarkt [Muñoz, 2020, S.4]. Institutionelle Investoren entdeckten den deutschen Immobilienmarkt als attraktive alternative Kapitalanlagemöglichkeit zum wertmindernden Anleihemarkt und dem volatilen Aktienmarkt [Waltersbacher, 2013] [Scharmanski, 2012]. Während viele europäische Länder eine Immobilienkrise erlebten, zeichneten sich bis dahin die Immobilienpreise in Deutschland als stabil ab und stagnierend in der Preisentwicklung [Wijburg and Aalbers, 2017, S.968]. Dies motivierte sowohl nationale als auch internationale Investoren um in den deutschen Immobilienmarkt - direkt oder indirekt über Investmentfonds oder anderen Finanzvehikeln - zu investieren. Zusätzlich wurden mit der Liberalisierung des Immobilienmarktes schrittweise der staatliche Wohnungsbau, Wohngenossenschaften und Sozialwohnungen privatisiert. Öffentliche, zum Beispiel soziale Wohnimmobilien wurden von Private Equity Fonds und Hedgefonds aufgekauft und deren teils spekulative Investments wurden später an börsennotierten Immobilienunter-

nehmen wie Vonovia und Deutsche Wohnen weiterverkauft [Wijburg and Aalbers, 2017, S.979-980].

Mit der Niedrigzins-Politik der Banken reduzierten sich zugleich die Kreditkosten, wodurch ein Anreiz für Privatpersonen und mittelständische Unternehmen geschaffen wurde, Kredite aufzunehmen und Immobilien zu kaufen.

Gleichzeitig erleben wir weltweit einen sozio-ökonomischen Wandel, der die Bedeutung des Finanzmärkte stärker hervorhebt [Epstein, 2005] und die Möglichkeit erweitert hat, verstärkt über neue Finanzprodukte Renditen zu erwirtschaften. Dieser Wandel wird als Finanzialisierung bezeichnet. Hierbei liegt der Fokus nicht mehr in der Produktion von Gütern und deren Nutzen, sondern primär auf dem Handel von Finanzprodukten zur Vermögensakkumulation [Krippner, 2005, S.174-175].

Auch der Immobiliensektor ist stark geprägt von der Finanzialisierung, was man vor allem an den zunehmenden kapitalmarktbasieren Anlagemöglichkeiten im Immobilienbereich erkennt. Zu der direkten Immobilienanlage, dem Kauf einer Wohnung, eines Hauses oder einer Gewerbeimmobilie, schließen sich neue indirekte Immobilienanlagen an. Dazu zählen offene und geschlossene Immobilienfonds, Private Equity Fonds, finanz-industrielle Wohnkonzerne bzw. Aktiengesellschaften sowie Real Estate Investment Trusts (REITs) [Rottke and Voigtländer, 2017, S.618]. Es ergibt sich für Anleger vermehrt die Möglichkeit, indirekt über den Kapitalmarkt in Immobilien zu investieren, wobei das direkte Eigentum in Anteile von Immobilien umgewandelt wird. Immobilien werden somit zu einem liquiden, investierbarem und global handelbaren Finanzanlageprodukt. Es eröffnen sich dadurch neue Möglichkeiten in Immobilien zu investieren, ohne selbst eine Immobilie zu besitzen oder verwalten zu müssen. Somit ergeben sich unterschiedliche Risiken und Rückgabemöglichkeiten für die Investoren, die ein breites Feld an Anlagebedürfnissen abdecken [Rettberg, 2007]. Da die indirekten Anlagemöglichkeiten im hohen Maße auf dem Kapitalmarkt gehandelt werden, verstärkt sich die Verflechtung des Kapitalmarktes mit dem Immobilienmarkt [Rottke and Voigtländer, 2017, S.714] und durch diese intensivierende Verzahnung kommt es zu mehr Immobilieninvestitionen mit steigenden Fondsvolumen bzw. dem Handel von Anteilsscheinen auf dem Kapitalmarkt. So hat sich in der

1. Einleitung

Eurozone sowohl der Anteil von Immobilieninvestmentfonds an den gesamten Immobilieninvestitionsströmen als auch ihr absoluter Wert von 2012 bis 2020 mehr als vervierfacht [Muñoz, 2020, S.42]. Dies führt zu einem Wandel im Umgang mit Immobilien, so dass eine Immobilie nicht nur als Wohnraum dient, sondern auch als Anlageprodukt [Gabor and Kohl, 2022] und als Kreditsicherheit an Attraktivität gewonnen hat [Rottke and Voigtländer, 2017, S.177]. Damit werden Immobilien immer mehr zu Vermögensgegenständen, die zur Vermögensakkumulation und als alternative Anlage zur Risikodiversifikation gemischter Multi-Asset-Portfolios verwendet werden. Der Wert der Nutzung einer Immobilie und die Schaffung von Lebensraum wird dem Profitgedanken untergeordnet, was weltweit soziale Probleme hervorbringt: Der Renditeappetit kann in Konsequenz zu einem sozialen Problem führen bedingt durch steigende Mieten, Zwangsräumungen und mehr (Siehe Bericht der UN [Farha, 2017]). Obwohl sich der Wunsch nach einem Eigenheim verstärkt - Immobilientransaktionen deutscher Haushalte nehmen zu - nimmt die Möglichkeit für bezahlbares Wohnen durch national steigende Miet- und Kaufpreise jedoch ab. Die verstärkte Nachfrage von institutionellen Investoren im Rahmen der Finanzialisierung führt daher auch zur negativen Auswirkungen eines Mangels an bezahlbarem Wohneigentum; eine zunehmende Zahl an Menschen in Deutschland kann sich keine Wohnimmobilie mehr leisten, da die Preise in vielen Gebieten außerhalb ihres Budgets liegen und sich immer mehr vom Einkommen entkoppeln [Dahl and Goralczyk, 2017, S.3]. In [Farha, 2017] wird die Auswirkung auf die soziale Rolle des Eigentums diskutiert und die Verantwortungsabgabe durch die Privatisierung des Marktes kritisiert, in dessen Folge das Menschenrecht auf Wohnen den Gesetzen des Marktes überlassen wird. Der UN Bericht [Farha, 2017] fordert daher einen Paradigmenwechsel, bei dem Wohnen wieder als fundamentales Menschenrecht anerkannt wird anstatt als handelbare «Ware». Staaten sollen daher zur Verantwortung gezogen werden, um bezahlbaren und sozialen Wohnraum zu schaffen und daher nicht nur auf die Regulierung des privaten Marktes zu vertrauen. Das Ziel ist hierbei den Trend entgegen zu wirken, dass institutionelle Investoren einen steigenden Anteil des Wohnimmobilienmarktes besitzen. Der Wohnungsmarkt scheint einem Markt für Finanzanlagen ähnlicher geworden zu sein, bei dem finanzielle Faktoren wie Zinssätze und Erwartungen an Kapi-

1.2. Fragestellung und Ziele der Untersuchung

talgewinne die wichtigste Rolle spielen. Gleichzeitig macht der Immobilienmarkt einen bedeutsamen Anteil der Gesamtwirtschaft aus. Schwankungen in den Immobilienpreisen haben verschiedene Effekte beispielsweise Vermögens-, Bilanz-, Vertrauens-, Spar- und Mieteffekte. Diese wirken sich allesamt direkt oder indirekt auf den Haushaltsverbrauch aus [Giuliodori, 2005]. Risiken, die zur Instabilität im Immobilienmarkt beitragen können, haben daher enorme Konsequenzen auf die Realwirtschaft, die Finanzwirtschaft, den Wohlstand und die Zufriedenheit der Gesellschaft. Die Ursachen von Hauspreisänderungen und ihren Auswirkungen ist zu einer bedeutenden Forschungspriorität geworden [Jorda and Taylor, 2015]. Neben der Sicherung der Preisstabilität [Rottke and Voigtländer, 2017, S.206], die das Zentrum politischer Maßnahmen sein sollten, werden vermehrt Analysen und Simulation durchgeführt, um extreme Hauspreisrisiken zu identifizieren und vorherzusehen, mit dem Ziel diese zukünftig zu vermeiden [Valckx et al., 2020]. Folglich haben die Zentralbanken und die Regierungen damit begonnen in den Markt einzugreifen und neue Mechanismen und Strategien entwickelt, um eine Preisstabilität zu gewährleisten. Das konstante Wachstum der Immobilienpreise ist auch der Nährboden für Risiken, wie beispielsweise eine übermäßige Verschuldung auf dem Wohnungsmarkt. Die Zentralbanken sind veranlasst, die Gründe für dieses Wachstum näher zu untersuchen und diese kritisch zu hinterfragen - Risiken in der Immobilienpreisentwicklung betreffen schließlich alle beteiligten Akteure im Wirtschaftssystem.

1.2. Fragestellung und Ziele der Untersuchung

Die vorliegende Forschungsarbeit untersucht im Kontext der Finanzialisierung des Wohnungsmarktes, ob die Immobilienpreisentwicklung in Deutschland stärker von Banken und Bankkrediten oder von Investmentfonds beeinflusst wird. Zudem werden Risiken, insbesondere Verlustrisiken, analysiert und es wird erörtert, ob und inwiefern deren Finanzierungskanal Risiken für Immobilienpreisschwankungen darstellen. Gleichzeitig soll die durchgeführte Analyse Aufschluss über die Nachfragegruppen im Immobilienmarkt und ihren Einfluss ableiten: Während Bankkredite vor allem von privaten Haushalten und Unternehmen genutzt wer-

1. Einleitung

den, investieren institutionellen Investoren größtenteils in Investmentfonds.

Hieraus ergeben sich folgende Forschungsfragen:

1. Forschungsfrage: Wer finanziert den Immobilienboom - Banken oder Investmentfonds?
2. Forschungsfrage: Wie beeinflussen Banken und Investmentfonds die Immobilienpreise und welche Chancen bieten bzw. Risikofaktoren bergen diese?
3. Forschungsfrage: Wie wirkt sich ein Schock bei den Banken bzw. den Investmentfonds auf die Immobilienpreisdynamiken aus?

1.3. Vorgehen der Untersuchung

Zur Beantwortung der eben vorgestellten Forschungsfragen bedarf es einer logischen und nachvollziehbaren Struktur der Ausarbeitung, deren grundlegender Aufbau nachfolgend dargestellt wird.

In diesem Kapitel wird die Einführung des Untersuchungsgegenstands sowie die Darstellung des Forschungsinteresses, das sich aus den drei zuvor erwähnten Forschungsfragen zusammensetzt, beschrieben.

Darauf aufbauend wird im zweiten Kapitel ein sowohl fachlich als auch technischer Literaturüberblick gegeben, um die Arbeit in den aktuellen Forschungsstand einzuordnen.

Das dritte Kapitel setzt den Fokus auf die theoretischen Rahmenbedingungen. Anhand der wissenschaftlichen Literatur soll ein Überblick der grundlegenden Konzepte, Elemente und Zusammenhänge der Immobilienwirtschaft sowie der Theorien der angewandten Methodik aufgezeigt werden.

Ausgehend von der Differenzierung zwischen Bank- und Kapitalmarkt werden im vierten Kapitel zentrale Einflussgrößen ausgewählt, die bei der Analyse und

1.3. Vorgehen der Untersuchung

der Auswertung verwendet werden, um die Forschungsfragen zu beantworten. Als Datengrundlagen dienen hierzu deutsche Immobilienangebotspreise, Immobilienindizes der BIS und Zeitreihen der Bundesbank Statistik, mithilfe deren ein praktischer Blickwinkel eingenommen werden kann.

Das fünfte Kapitel widmet sich der Beschreibung und Begründung der methodischen Vorgehensweise zur Beantwortung der Forschungsfragen und orientiert sich an den Aspekten der Datengrundlage, der Methodenauswahl und der Auswertungstechniken aus den vorherigen Kapiteln. Anhand der vorgestellten Methoden werden Treiber bestimmt, gemessen und deren Einfluss auf die Immobilienpreisentwicklung erarbeitet um diese mit den Forschungsergebnissen zu verknüpfen. Weiterhin werden die quantitativen Ergebnisse präsentiert und Erkenntnisse abgeleitet, die gleichzeitig in den Kontext der wissenschaftlichen Literatur gesetzt werden und zur Beantwortung der Forschungsfragen dienen.

Das sechste Kapitel dient der Zusammenfassung der Ergebnisse und der kritischen Reflexion der Daten und Methodik. Mit dem Fazit wird abschließend ein Ausblick auf weitere Forschungsprojekte gegeben.

2. Literaturüberblick

Das vorliegende Kapitel hat das Ziel, durch einen Literaturüberblick die wichtigsten Erkenntnisse der bisherigen Forschung zusammenzufassen. Der Bezug hierbei ist zweigeteilt: Zunächst werden finanzielle Einflüsse und deren Art der Wirkung auf Immobilienpreisentwicklungen zusammengefasst, wobei der Fokus auf Einflussfaktoren von Investmentfonds und Banken gesetzt wird. Im Anschluss wird die QR im Rahmen von Zeitreihenmethoden als eine technische Methode und ihre Entwicklung vorgestellt, die sich für die Untersuchung als gut geeignet erwiesen hat. Es wird ein Überblick über den aktuellen Stand der Forschung sowohl fachspezifisch als auch technisch gegeben, der relevant ist, um die vorliegende Arbeit einzuordnen und zu platzieren. Die thematische Untersuchung sammelt Erkenntnisse bisheriger Literatur in Bezug auf die Forschungsfragen. Die technische Recherche stellt die Entwicklung der QR als statistischen Methode im Zeitreihenkontext vor und begründet dessen Anwendung zur Beantwortung der Forschungsfragen, wodurch die anschließende empirische Analyse untermauert wird.

2.1. Finanzielle Treiber von Immobilienpreisentwicklungen

[Muñoz, 2020] zeigt, dass in Europa Immobilienfonds den Immobilienboom stark beeinflussen und dass die Einführung einer Beleihungsgrenze marktbasierter Finanzierung durch Fonds die Immobilienpreise glätten könnte. Ihm zufolge wirken sich bankbasierte Einflüsse weniger stark auf die Immobilienpreisentwicklung aus als diejenigen des marktbasierten Finanzsystems. Zudem betont er den starken Anstieg der Mietpreise und Preisdislokationen, die vor allem verstärkt während

2.1. Finanzielle Treiber von Immobilienpreisentwicklungen

der Corona-Pandemie aufgetreten sind.

[Cvijanovic et al., 2021] belegt, dass institutionelles Kapital für Volatilität und Unsicherheit im amerikanischen Immobilienmarkt sorgt und es eine strukturelle Veränderung der Risiken schafft. So entdeckt [Cvijanovic et al., 2021] ebenfalls den Anstieg von Immobilienpreisrisiken mit dem Markteintritt von Blackstone, die sich als signifikanter Risikofaktor zeigten. Blackstone ist eine US-amerikanische Investmentgesellschaft, einer der weltgrößten Investoren in Bereich Alternativen Anlagen inklusive Immobilien und Anbieter von Immobilienfonds [Faber, 2009]. [Banti and Phylaktis, 2022] untersucht REITs und sieht diese als Treiber für hohe Immobilienpreise weltweit in Ländern mit stärkeren marktbasiereten Rentensystem. REITs ermöglichen ausländischen Investoren in lokalen Immobilienmärkten einzusteigen und bilden somit einen Transmissionskanal für lokale und globale finanzielle Schocks in den Immobilienmarkt. Zum Beispiel belegte hier [Hu et al., 2022] durch Anwendung eines VAR-Modells, dass spekulativer Kapitalzufluss durch ausländischen Immobilieninvestments und privaten Fonds die Immobilienpreise in China signifikant in die Höhe getrieben hat. Hier wurde gezeigt, wie die enorme Größe und die kurzfristigen Anlagecharakteristiken zur Beschleunigung der Volatilität auf den heimischen Immobilien beitragen. Dabei verursachte Fondskapital den zweitgrößten Anteil an den Schwankungen der chinesischen Immobilienpreise. Eine Studie [Yang and Rehm, 2021] identifiziert kausale Zusammenhänge zwischen spekulativen Wohnungsinvestitionen über bankbasierter Finanzierung und langfristigen Hauspreissteigerungen in Auckland (Neuseeland). Da die meisten Haushalte Kredite aufnehmen müssen um eine Immobilie zu erwerben, spielen Kreditkonditionen eine entscheidende Rolle in der Hauspreisdynamik. Diese hängen wiederum von der Geldpolitik, dem Zinsniveau und der Geschäftspolitik der Banken ab [Lecat and Mésonnier, 2005, S.28]. Laut Aalbers [Aalbers, 2008] ermöglichen Immobilienkredite nicht nur Privatpersonen den Besitz von einem Eigenheim, sondern führen auch zu höheren Immobilienpreisen. Er begründet dies vor allem an der lockeren Immobilien-Kreditvergabe, die vonseiten der Banken genutzt wurde, um ihren Markteinfluss auszudehnen. Wechselwirkungen zwischen dem Bankmarkt und dem Immobilienmarkt werden vielseitig untersucht und verschiedene Szenarien werden diskutiert. Dabei wird vor allem der

2. Literaturüberblick

Einfluss des Wohnbalkredites und deren Effektivzins auf Immobilienpreise in verschiedenen Ländern empirisch erörtert, besonders in Immobilienboomphasen und in Immobilienkrisen. In den meisten Industrieländern zeigt sich historisch betrachtet ein zeitlicher Zusammenhang zwischen deregulierten Kreditmaßnahmen und anschließenden Immobilienbooms [Lecat and Mésonnier, 2005, S.34]. Bidirektionale Effekte zwischen Hauspreisen und Hypothekenvolumen zeigen beispielsweise [Anundsen and Jansen, 2013], [Adelino et al., 2012] [Pavlov and Wachter, 2011] sowie [Brissimis and Vlassopoulos, 2009]. Nach [Taltavull de La Paz and White, 2012] führt die Veränderung des Wohnbalkreditvolumens zu Hauspreissteigerungen sowohl in Spanien als auch in Großbritannien. [Gimeno and Martínez-Carrascal, 2010] findet im spanischen Markt zusätzlich die Erkenntnis, dass das Ungleichgewicht der Immobilienkrediten zwar zu langfristig sinkenden Immobilienpreisen führt aber kurzfristig zu einer Steigerung der Immobilienpreise geführt hat. Zudem kommen [Gimeno and Martínez-Carrascal, 2010] zu dem Ergebnis, dass sowohl das Wachstum der Hauspreise vor einem Jahr als auch vor einem Quartal die Hauspreisentwicklung beeinflusst hat. Auf dem Hongkonger Immobilienmarkt werden lang- und kurzfristige Beziehungen zwischen Immobilienpreisen und Immobilienkrediten der Banken untersucht. Hier zeigt sich, dass die Anstiege der Immobilienpreise positiv und signifikant mit dem Wachstum der langfristigen Immobilienfinanzierungen zusammenhängen. Es wird jedoch nicht festgestellt, dass diese Immobilienpreise erheblich beeinflussen [Gerlach and Peng, 2005].

[Wilhelmsson, 2020] identifiziert im schwedischen Wohnimmobilienmarkt eine kausale bidirektionale Beziehung zwischen Zinsen und Immobilienpreise, die sich sowohl direkt als auch indirekt über den Bankkredit-Kanal auswirkt. Im untersuchten Zeitraum hat die Rolle des Bankkredit-Kanals zugenommen und es zeigt sich eine höhere Aufmerksamkeit bei der Bevölkerung für Kreditzinsen. Die Untersuchung zeigt auch, dass Transmissionseffekte von Zinsänderungen oder Bankkrediten über die Zeit variieren. Er kommt zu dem Schluss, dass die steigende Zinssensitivität (höhere Beleihungsbegrenzung und mehr variable Zinsraten) dazu geführt hat, dass der Immobilienmarkt stärker von der Finanzwirtschaft abhängt als noch vor einer Dekade. Laut [Kohl, 2020] führen zusätzliche Hypothekar-Kredite nicht zu mehr Wohnungsangebot, sondern treiben die Haus-

2.1. *Finanzielle Treiber von Immobilienpreisentwicklungen*

preise in die Höhe und wirken sich zudem baudeprimierend aus. Über ein VECM werden in [Shida, 2022] in einem Panel von 21 Ländern verschiedene makroökonomische Determinanten der Immobilienpreisentwicklung untersucht. Dabei wurden positive Effekte seitens der Bankkredite auf die Wohnungspreise und negative Effekte vonseiten des Pro-Kopf-Einkommens, dem Wohnungsbestand und der Zinssätze entdeckt. In Anlehnung an die globale Wirtschaftskrise von 2008 untersucht [Cerutti et al., 2017, S.22] den Zusammenhang zwischen Kreditboom und Wirtschaftsboom und der Entwicklung des Immobilienmarktes. Über eine Panel-Regression wurde der Einfluss von Hausfinanzierungen und Immobilienbooms in einem Panel von mehreren Ländern untersucht, wonach ein Kreditboom die Wahrscheinlichkeit eines Immobilienbooms positiv beeinflusst. Er betont die starke Verbundenheit beider Märkte und entdeckt, dass historische Hauspreisbooms häufiger in Zeiten von Kreditbooms entstanden sind. Fallende Hauspreise haben starken Einfluss auf Ausfallrisiken und Schuldanstieg. Daher sei der Eingriff der Politik im Kreditmarkt essenziell, um Hauseigentümerschaft sowie soziale Stabilität und Wirtschaftswachstum zu fördern. Immobilienpreise reagieren sehr sensibel auf nationalen Hypothekenkreditzinsen und beeinflussen die Hauspreisdynamiken [Baffoe-Bonnie, 1998]. Ein negativer Einfluss des Zinssatzes des Hypothekarkredits auf Immobilienrenditen zeigt sich in [Forster and Sun, 2022]. Mit den Analysen in [Hanck and Prüser, 2020] und [BIS, 2022a] werden Treiber steigender Immobilienpreise untersucht und sinkende Zinsen werden als entscheidend für die Prognose steigender oder fallender Preise identifiziert. Der Kreditvergabebezug ist von 2013 bis Ende 2021 stark rückläufig gewesen und in der Coronapandemie sind die Wohnimmobilienpreise erneut erheblich angestiegen mit einem Realwachstum von 4% während der Pandemie. Gleichzeitig sank der Hypothekenkreditzins europaweit zu einem historischen Tief. [BIS, 2022a] stuft daher steigende Leitzinsen als Risiko einer Trendwende im Immobilienmarkt ein.

2.2. Quantilsregression und Anwendungen im Finanzkontext

In diesem Abschnitt wird die Entwicklung und bisherige Anwendung von Quantilsregression (QR) auf Basis von Zeitreihen im Finanzkontext beschrieben. Die Untersuchung ermöglicht uns aktuelle Methoden zu identifizieren, die für die Beantwortung der Fragestellungen relevant und nützlich sein könnten und hilft die Arbeit in den aktuellen Forschungsstand einzugliedern. Obwohl QR als Methode schon seit 1978 existiert, wurde sie erst ab 1987 auf den Zeitreihenanalysekontext durch die Einführung von Quantil autoregressiven (Q-AR) Modellen angewendet [Koenker and Xiao, 2006]. Dabei wurden eindimensionale Modelle, unter anderem autoregressive Modelle, Unit Root Modelle [Koenker and Xiao, 2006], als auch multidimensionale Modelle wie Vektor-autoregressive [Cecchetti and Li, 2008] und kointegrierte Modelle [Xiao, 2009] vorgestellt und sowohl für stationäre als auch nicht-stationäre Zeitreihen erweitert. Es wurden ab 2009 nicht nur Methoden zum Niveau von Zeitreihen, sondern auch zu deren Volatilität angewendet, beispielsweise die bedingte Quantils-Autoregression für Volatilitätsmodelle wie GARCH [Xiao and Koenker, 2009]. Die Vermischung von Machine Learning Methoden wurde 2016 mit der Untersuchung des Value at Risks unter Nutzung von QAR mit neuronalen Netzen etabliert [Xu et al., 2016]. In 2021 wurden die QR Methoden auf Paneldaten angewendet mit der Einführung von House-price-at-Risk [Valckx et al., 2020]. Mehrdimensionale und damit dynamische Modelle von verschiedenen Datentypen und VAR-Formen wurden erstmalig 2008 mit dem Q-VAR Modell im Finanzkontext angewendet [Cecchetti and Li, 2008], zum Beispiel durch Manganelli für heterogene, daher verschieden-frequente Daten in einem Bayesian Mixed-Frequency Q-VAR Modell [Iacopini et al., 2022] und für VAR Modell in Strukturform [Chavleishvili and Manganelli, 2019]. Durch die Nutzung nichtlinearer Beziehungen entlang von makroökonomischen Variablen zeigte sich, dass Q-VAR Modelle als Methode im Vergleich zum Standard VAR Modell besser extreme Realisierungen, welche sich in den Randbereichen der Verteilung befinden, schätzen können [Chavleishvili and Manganelli, 2019]. Dies eröffnete eine breite Auswahl an statistischen Werkzeugen zur Untersuchung von Risiken,

2.2. Quantilsregression und Anwendungen im Finanzkontext

die besonders im Wirtschaftskontext relevant sind. Daher werden nun die vorgestellten Methoden mit Asset-Pricing-orientierten, makroökonomischem Anwendungsbereich eingesetzt, die zur Untersuchung von Anlageklassen und ihrer Relation zu Markttreibern dienen. Trotz des steigenden Interesses von politischen Entscheidungsträgern, sowohl ökonomische als auch finanzielle Indikatoren entlang der ganzen Verteilung zu verstehen und zu prognostizieren, bleibt die Literatur zu Q-VAR Modellen sehr limitiert. Dies betont die Relevanz, diesen Bereich an Untersuchungen auszudehnen, um das Auftreten verstärkt-aufretender, extremer exogener Schocks (Corona-Pandemie, der Krieg, die globalen Lieferengpässe) besser verstehen und quantitativ beschreiben zu können. Anwendungsbereiche der QR sind divers [Fitzenberger and Koenker, 2002] und finden sich im Finanzkontext vermehrt in der Schätzung und der Prognosen extremer Risiken. Der Vorteil der alternativen Nutzung von flexibleren Modellen wie QR ist, dass hierbei keine Verteilungsannahme getroffen werden muss. Dem Gegenüber stehen Schätzungen mittels Modellen unter Normalverteilungsannahme, bei denen viele wirtschaftliche Variablen asymmetrische Verteilungseigenschaften besitzen, die in ihrer Aussagekraft problematisch sind. So werden variablen-spezifische Risikomaße entwickelt und mit QR in Verbindung gesetzt. Zu dem VaR, der Verlustrisiken für Renditen ermittelt und schätzt, bildet sich der GDP-at-risk [Adrian et al., 2019], [Adams et al., 2021] für Wirtschaftswachstumsrisiken, Inflation-at-Risk [Ghysels et al., 2018] für Inflationsrisiken und Housing-at-risk [Valckx et al., 2020] für spezifische Immobilienpreisrisiken. Gleichzeitig wurden spezifische Einflussfaktoren dieser Risiken untersucht. Da diese Risiken sich auf den Randbereichen (engl. tails) der ökonomischen Variablenverteilung befinden, werden die Einflussfaktoren auch Tail-Abhängigkeiten genannt. Tail-Abhängigkeiten dienen auch zur Untersuchung von Tail-spezifischen Übertragungseffekten innerhalb und zwischen verschiedenen Märkten. Damit können verschiedene heterogene Wirkungseffekte und deren Intensitäten identifiziert werden und Risikoübertragungseffekte in verschiedenen Assetklassen [Ando et al., 2018], zwischen verschiedenen Finanzmärkten [Xie, 2021], und zwischen Banken und Finanzmärkten [Shahzad et al., 2019] evaluiert werden. Diese Übertragungseffekte können asymmetrische Reaktionen auslösen, die in Abhängigkeit zur jeweiligen Phase des Wirtschaftszyklus ste-

2. Literaturüberblick

hen. Dabei wurden die Verbundenheit und die dynamischen Effekte auf Aktienmärkten [Shahzad et al., 2021] und dem Kryptomarkt [Chowdhury et al., 2022] genauer erörtert. Auch wenn Übertragungsrisiken mit klassischen VAR Modellen geschätzt werden können, zeigt [Chavleishvili and Manganelli, 2019], dass Risiken dabei im Vergleich zum Q-VAR eher unterschätzt werden und erweitert die Anwendungen auf Stresstests. Auch die Identifikation von Boom und Busts in Assetklassen konnte mithilfe von QR identifiziert werden [Sousa and Machado, 2006]. QR-spezifische Analysen auf Immobilienzeitreihen sind jedoch überschaubar: Vor allem der Effekt von Immobilien und Aktienbooms auf das GDP-at-Risk wurde hier untersucht [Cecchetti and Li, 2008]. Ziel war es dabei die Rolle der Bank-Deregulierung, der Kreditvergabe, der Zinsen und der internationalen Liquidität zu untersuchen, da diese die Wahrscheinlichkeit eines Immobiliencrashes beeinflussen können. Mit einem Quantile Autoregressive Distributed Lag (Q-ADL) Modell werden Anwendung auf Immobilienpreis Renditen untersucht, die heterogene Dynamiken der Antwortvariable durch exogene Schocks auslösen [Galvao JR. et al., 2013].

Zusammenfassend zeigen die Untersuchungen:

1. Unter Nutzung verschiedener Methoden wurde bereits die Wechselbeziehung zwischen Wohnbalkrediten, Hypothekenzinsen und Leitzinsen auf Immobilienpreisen untersucht. Analysemethoden hierfür waren größtenteils VAR Modelle und ihre nicht-stationäre Variante, die Vector Error Correction Modelle (VECM). Es wurden bereits positive Einflüsse von Bankkrediten und in Deutschland negative Einflüsse von Kredit und Leitzinsen auf Immobilienpreise identifiziert. Analysen zu Einflüssen von Immobilienfonds auf Immobilienpreise gab es dagegen bisher noch nicht in Deutschland. In Ländern mit marktbasierendem Finanzsystemen wie in Großbritannien oder in den USA zeigten Analysen von Kapitalmarkt-Vehikeln, wie zum Beispiel REITs, einen positiven Einfluss auf den Immobilienboom haben. Zusätzlich zeigte sich hier eine Erhöhung der Volatilität beim Eintritt marktbasierter Finanzierungsvehikel.
2. Mithilfe von QR können Einflussfaktoren sowohl in Boom als auch in Krisenzeiten untersucht und geschätzt werden. Innerhalb dynamischer Model-

2.2. *Quantilsregression und Anwendungen im Finanzkontext*

le, bieten Q-VAR Modelle zusätzlich zu den VAR Modellen eine Erweiterung von Stress-Szenarien zur Untersuchung von Übertragungseffekten und Wechselwirkungen zwischen verschiedenen Märkten, die entlang der Quantile heterogene Reaktionen äußern können. Dabei kann ein umfassenderes Bild von Marktrisiken identifiziert, exploriert und evaluiert werden. Gleichzeitig können mögliche Entwicklungen wie auch Übertragungseffekte simuliert werden. Weiterhin bietet das QR Modell robustere Schätzungen als das klassische lineare Regressionsmodell [Koenker, 2005] und gelten auch dann, wenn die Normalverteilungsannahme nicht gegeben ist.

Die vorliegende Arbeit zielt darauf ab, die bestehenden Lücke in der Literatur zu schließen, indem mit Hilfe von QR die Auswirkungen von marktbasierem bzw. bankbasierem Kapital auf Immobilienpreisentwicklungen in Deutschland untersucht wird und damit einen Beitrag zur Einordnung der Bedeutung der Finanzialisierung auf die Immobilienpreise in Deutschland geleistet wird. Die Erweiterung der Risikoanalysen mithilfe von Q-VAR Modellen könnte zu gewinnbringenden und bisher unerforschten Erkenntnissen führen, die die Einzigartigkeit dieser Arbeit hervorhebt.

3. Theoretische Grundlagen und Methoden

3.1. Grundlagen der deutschen Immobilienwirtschaft

Der Immobilienmarkt gliedert sich in den Kauf- und den Mietmarkt. Deutschland hat einen großen Mietmarkt und ist in der Europäischen Union mit ca. 50% das Land mit der niedrigsten Wohneigentumsquote [Eurostat, 2022]. Eine wichtige Rolle spielt hierbei die deutsche Wohnungspolitik, die Anreize für das Mieten schafft und den Mietmarkt entsprechend reguliert. Während historisch in anderen Ländern die Wohnungsraumversorgung stark Markt-geregelt verlief, war in Deutschland die öffentliche Hand noch stärker in den Haus- und Wohnungsmarkt involviert [Schneider and Wagner, 2015]. Schrittweise wurde dieser Markt jedoch liberalisiert und privatisiert [Wijburg and Aalbers, 2017]. Während nach der Jahrtausendwende laut Angaben der OECD die realen Wohnimmobilienpreise in Australien, Frankreich, Großbritannien, Irland, Spanien, in den USA und in einer Vielzahl weiterer Länder um 40% gestiegen sind und mit der Weltfinanzkrise 2008 eine Preiskorrektur erlebten, zeigten die Preise in Deutschland und den Niederlanden einen stabilen Verlauf [Voigtländer, 2012]. Mit der Hoffnung, dass der deutsche Immobilienmarkt nachziehen wird, weckte dieser großes Interesse bei diversen Investoren [Just, 2010]. Nach der europäischen Schuldenkrise 2012 startete der Boom auf Immobilien auch in Deutschland. Gründe für die hervorhebende Stabilität des Wohnmarktes in Deutschland waren der gut-entwickelte Mietmarkt, die niedrigen Wohneigentumsquoten und der konservative Kreditver-

3.1. Grundlagen der deutschen Immobilienwirtschaft

gabestandard der Banken [Schneider and Wagner, 2015].

Bankmarktfinanzierung: der klassische Weg der Immobilieninvestition

Der Markt für Immobilienfinanzierungen wird in Deutschland traditionell von Bankdarlehen dominiert. Der Erwerb einer Immobilie wird in der Regel nur zu einem kleinen Teil mit Eigenkapital getätigt, zum größten Teil wird der Kauf der Immobilie jedoch mit Fremdkapital über ein Bankkredit finanziert [Rottke and Voigtländer, 2017, S.713]. Hierbei spielen die Zinsbindung, die Beleihungshöhe (Loan-to-Value) oder auch die Refinanzierung der Banken eine große Rolle. Dabei ist die Beleihungshöhe das entscheidende Maß für das Risiko einer Finanzierung. In Deutschland ist das Beleihungsverhältnis bei 60% und damit sehr konservativ im Vergleich zu den angelsächsischen Ländern, wie Großbritannien und USA [Rottke and Voigtländer, 2017, S.688]. Der Beleihungswert bestimmt die deutsche Immobilienfinanzierung und beschreibt den Wert, von dem mit hoher Sicherheit erwartet werden kann, dass er sich langfristig zu jedem beliebigen Zeitpunkt realisieren lässt [Rottke and Voigtländer, 2017, S.688-689]. In Deutschland dominiert die festverzinsliche und langfristige Zinsbindung, die meist über 5 – 10 Jahre festgesetzt wird [Rottke and Voigtländer, 2017, S.691]. Damit zählt der deutsche Bankmarkt zu einer der konservativsten Kreditmärkten in Europa [Schneider and Wagner, 2015].

Die Europäische Zentralbank (EZB) hat dabei eine gesonderte Rolle als Bank: Sie beeinflusst über den Leitzins das Angebot und die Nachfrage für Wohnimmobilien und stimuliert Marktpreise und ihre Volatilität [Rottke and Voigtländer, 2017, S.206]. Das zentrale Ziel der EZB ist Preisstabilität und Wirtschaftsstabilität zu gewährleisten. Mit der Reduzierung des Leitzinses kann sowohl die Geldversorgung verstärkt als auch die Attraktivität von festverzinslichen Anlagen wie Anleihen auf Vermögenswerte wie Aktien oder Immobilien verlagert werden. Die steigende Nachfrage nach Immobilien stößt dabei aufgrund einer limitierten Anzahl von Objekten und der zeitlich verzögerten Reaktion der Neuschaffung auf eine kurzfristig unelastisches Angebot [Voigtländer, 2012].

Immobilien stellen dabei die am weit verbreitetste Sicherheit für Kredite dar, wodurch der Anstieg der Immobilienpreise direkt die Möglichkeit der Kreditver-

3. Theoretische Grundlagen und Methoden

gabe erhöht. Durch den damit verbundenen Wirtschaftsaufschwung entsteht ein Rückkopplungsprozess, welcher sich wieder auf die Nachfrage nach Immobilien auswirkt [Voigtländer, 2012, S.587].

Kapitalmarktfinanzierung – die indirekte Immobilieninvestition Auf dem Kapitalmarkt treten zwei Arten von Kapitalanlegern auf: private Anleger und institutionelle Anleger. Während private Personen und Haushalte als private Anleger agieren, gelten professionelle Anleger wie Investmentfonds, Vermögensverwalter, Versicherungen als institutionelle Anleger [Ernst and Schurer, 2015, S.23]. Der Kapitalmarkt bietet längerfristige Anlagen und Aufnahmen von Kapital mit Fokus auf verbrieftete Finanztitel, wie beispielsweise verbrieftete Kredite (Anleihen) und Beteiligungen (Aktien). Der Kapitalmarkt lässt sich in ein börslich und ein außerbörsliches Segment unterteilen. Börslich organisierte Kapitalmärkte weisen den höchsten Organisationsgrad mit ausgeprägter Standardisierung auf und haben zusätzlich eine Stückelung der Gesamtemission z.B. in einzelne Aktien. Dies gewährleistet eine hohe Handelbarkeit der Wertpapiere, was besonders für Kleinaktionäre attraktiv ist. Der außerbörsliche Markt ist weniger organisiert und basiert auf dem over-the-counter (OTC) Handel d.h. auf den individuellen Beziehungen zwischen Anbietern und Nachfragern [Gromer, 2012, S.36 f.].

Bei Immobilien unterteilen sich die Anlageoptionen in direkte und indirekte Anlageformen. Man unterscheidet zwischen direktem Erwerb von Immobilien am Immobilienmarkt und verbrieften Immobilienanlageprodukten, sogenannten indirekten Immobilienanlagen, welche über den Kapitalmarkt erworben werden. Eine indirekte Anlage beschreibt den Anteil eines Fonds oder einer Gesellschaft, die Immobilieneigentum besitzt. Immobilienfonds sind auf Immobilieninvestitionen spezialisierte Investmentfonds und gelten als „der Klassiker unter den indirekten Immobilienanlagen“ [Vornholz, 2022, S.6]. Hierbei wird ein Anleger nicht der unmittelbare Besitzer einer Immobilie, sondern erwirbt lediglich Anteile an dem im Fonds gesammelten Vermögen. Über die Akquise von Anteilsscheinen werden Immobilienprojekte finanziert. Das gesammelte Kapital wird von einer zwischengeschalteten Gesellschaft verwaltet mit dem Ziel aus Mieteinkünften, Wertsteigerungen und Verkäufen der Immobilien Gewinne für die Anleger zu

3.1. Grundlagen der deutschen Immobilienwirtschaft

erwirtschaften [Vornholz, 2022, S.6]. Man unterscheidet zwischen offenen und geschlossenen Immobilienfonds:

- Geschlossene Immobilienfonds sammeln über einen festgelegten Zeitraum Kapital institutioneller Investoren und werden im Anschluss geschlossen, sobald ein festgelegtes Fondsvermögen erreicht ist um einzelne Immobilienprojekte zu finanzieren. Nur das bis dahin eingesammelte Kapital finanziert das Projekt und bis zur Fertigstellung an den Fonds gebunden [Gromer, 2012, S.46].
- Offene Immobilienfonds können in Immobilien-Publikumsfonds und Immobilien-Spezialfonds unterteilt werden. Die Investorengruppen der offenen Immobilien-Publikumsfonds bestehen aus privaten und institutionellen Anlegern, die jederzeit Anteilsscheine erwerben und an die Kapitalanlagegesellschaft (KAG) zurückgeben können. Immobilien-Spezialfonds richten sich ausschließlich an institutionelle Anleger. Sowohl in Spezialfonds als auch in Publikumsfonds liegt keine Begrenzung in Bezug auf das Fondsvermögen, der Fond-Laufzeit und die Anzahl der umlaufenden Anteilsscheine, über die die Immobilienprojekte finanziert werden und der Anteilshaber vor [Gromer, 2012, S.41 f.].

Die Immobilie wird von einer Sachanlage zu einer Finanzanlage. Vorteile der indirekten Anlage im Vergleich zur direkten sind eine höhere Fungibilität (Handelbarkeit), ein homogenerer Markt, Teilbarkeit, geringere Investitionskosten und führen daher zu niedrigeren Markteintrittsbeschränkungen. Die Verzahnung von Immobilien- und Kapitalmarkt geht dabei mit Finanzprodukten einher, die indirekte Anlagealternativen zur klassischen direkten Investition in Immobilien bieten. Die dabei entstehenden Immobilienkapitalmärkte eröffnen Immobilienunternehmen neue Möglichkeiten der Kapitalbeschaffung zusätzlich zur klassischen Bankenfinanzierung [Rottke and Voigtländer, 2017, S.716]. Obwohl weiterhin der physische Immobilienmarkt die bestimmende Größe im Zusammenhang von Immobilieninvestments ist, hat die finanzielle Dimension der indirekten Anlagen zunehmend an Bedeutung gewonnen [Gromer, 2012, S.40]. Während Aktien, Anleihen und Fondsanteile als liquide Finanzprodukte gelten um Kapital anzulegen,

3. Theoretische Grundlagen und Methoden

galt die Immobilie lange Zeit als eine illiquide Kapitalanlage. Dies hat sich geändert mit dem Wachstum an Immobilien-Anlageprodukten auf dem Kapitalmarkt. So bildeten sich in Deutschland Wohnungsaktiengesellschaften wie die Vonovia bzw. Deutsche Wohnen [Wijburg and Aalbers, 2017, S.980], die inzwischen einen beträchtlichen Wohnungsbestand besitzen und im DAX 40 Aktienindex gelistet sind [Arnold et al., 2017, S.33]. Auch Real Estate Investment Trusts (REITs) oder diverse Fonds gewinnen an Bedeutung. Abbildung 3.1 illustriert die möglichen Anlageformen in Immobilien und ordnet diese den jeweiligen Kapitalmärkten zu.

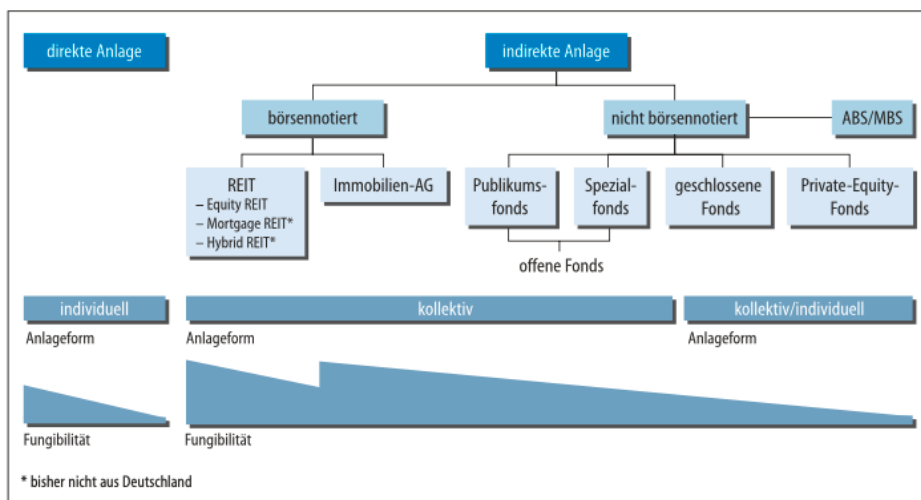


Abbildung 3.1.: Immobilienanlageformen [Rottke and Voigtländer, 2017, S. 618]

3.2. Grundlagen des Asset Pricings und Risikomanagements

Asset Ein Asset ist die englische Bezeichnung eines Vermögensobjektes und damit eine Position auf der Aktivseite der Bilanz [Eller, 2010, S.144]. Ein Asset ist ein Vermögensgegenstand, welcher über Zeit einen Nutzen bietet und von dem zukünftige Zahlungen erwartet werden [Cochrane, 2001, S.3]. Dazu gehören

3.2. Grundlagen des Asset Pricings und Risikomanagements

Aktien (stocks), Anleihen bzw. Anteile von Gesellschaften (bonds), Immobilien (real estate), Rohstoffe (commodities), Derivate (derivates) und Fremdwährungen (foreign exchange). Für eine Immobilie ist der zukünftige Nutzen sowohl die Mieteinnahme, das Wohnen in der Immobilie, als auch dessen Wertsteigerung.

Eine zentrale Frage mit der sich der Bereich Asset Pricing beschäftigt, ist die Preisfindung des jeweiligen Assets. Das übergeordnete Ziel ist der individuelle, rationale Konsum oder die Nutzenmaximierung: Dabei gelten Assets als wertvoll, wenn sie über die Zeit einen hohen und stabilen Nutzen versprechen. Zudem sollen Assets einen stabilen und regelmäßigen Nutzen über Boom- und Krisenzeiten hinweg garantieren: wichtig sind die erwarteten Gewinne und Renditen, die in der Zukunft erzielt werden [Cochrane, 2001]. Dabei liegt der Fokus der Anleger darin, mit Hilfe positiver theoretischer Modelle Voraussagen zu treffen, die den erwarteten Preis in der Zukunft - sowohl zu Boom als auch in Krisenzeiten - abbilden können.

Boom Ein Boom beschreibt im Allgemeinen eine Hochkonjunkturphase. Die Nachfrage ist merklich erhöht in Relation zum Angebot und dies wirkt sich auf den Preis aus, was zu einer Überbewertung und den Aufbau einer Preisblase führt [Eller, 2010, S.188].

Crash Die Bezeichnung Crash beschreibt einen wirtschaftlichen Absturz und kommt ursprünglich aus der Börsensprache. Es beschreibt einen unerwarteten Preisverfall des Assetwertes zum Beispiel beim Platzen einer Spekulationsblase [Eller, 2010, S.166].

Investment Als Investment wird die Handlung einer Geldanlage definiert, um in der Zukunft eine finanzielle Belohnung zu erhalten. Ein Investor legt sein Geld mit der Hoffnung, in der Zukunft mehr Geld zu erwirtschaften, an. Dies beinhaltet zwei Elemente: den Geldaufwand und einen zukünftigen Geldertrag entweder in Form eines Einkommensflusses oder einer Kapitalsumme in der Zukunft d.h. ein Zuwachs im Marktpreis der Anlage zum Verkaufszeitpunkt [Jones and Trevillion, 2022, S.4]. Die Motive für Investments sind dabei divers wie zum Beispiel:

3. Theoretische Grundlagen und Methoden

- Anlagemotiv: dauerhafte Ausschüttung von Erträgen aus angelegtem Kapital (durch Mieten, Dividenden, Zinsen)
- Sachwertmotiv: Sachwertbeteiligung zur Vermeidung von Geldverlust nach Inflation
- Spekulationsmotiv: Gewinnerzielung über Kauf und Verkauf und Wertsteigerung
- Mitsprache und Beherrschungsmotiv: Mitentscheidung durch Kauf von Anteilen in einer KAG oder AG [Ernst and Schurer, 2015, S.29]

Rendite Mit Rendite wird oft der mit einer Kapitalanlage über einen bestimmten Zeitraum erzielte Erlös im Verhältnis zu dessen ursprünglichen Anlagebetrag bezeichnet [Ernst and Schurer, 2015, S.52]. Renditen beschreiben die Veränderung der Preise P_t bzw. Preisschwankungen

$$R_t = P_t - P_{t-1}$$

und werden oft in Log-Renditen ausgedrückt [Ernst and Schurer, 2015, S.71] d.h. über die logarithmierte Preisveränderung

$$r_t = \log\left(\frac{P_t}{P_{t-1}}\right) = \log(P_t) - \log(P_{t-1}).$$

Der Vorteil dabei ist, dass die prozentuale Veränderung über die Zeit in einem stabilen Band beschrieben werden kann, in der Hoffnung, einen stabilen Zusammenhang zu finden. In der Sprache der Zeitreihenanalyse werden stationäre Zeitreihen betrachtet, da die Verteilung dieser Zeitreihen sich stabil über die Zeit in einem festen Band bewegen (Siehe Abschnitt 3.4.1).

Volatilität Die Volatilität beschreibt die durchschnittliche Schwankungsspanne von Marktpreisen bzw. Marktpreisveränderungen. Um Vergleiche zu ziehen, wird sie oft in Prozent pro Jahr angegeben. Zur empirischen Berechnung der Volatilität

3.2. Grundlagen des Asset Pricings und Risikomanagements

wird die Standardabweichung herangezogen. Damit gibt die Volatilität Auskunft über das mit einer Finanzanlage verbundene Risiko [Eller, 2010, S.62].

Basispunkt Ein Basispunkt (BP) beschreibt ein Hundertstel eines Prozents (1 BP = 0,01 Prozentpunkte). Bei kleinen Abweichungen einer Rendite wird häufig der Begriff BP verwendet [Eller, 2010, S.78].

Risiko Der Risikobegriff ist weitreichend und nicht eindeutig definiert. Laut [Ernst and Schurer, 2015, S.83] kann er folgendes beschreiben:

- Die Abweichung von geplanten und erwarteten Größen
- Negative Abweichungen vom Erwartungswert,
- Vorstellung denkbarer Verluste oder auch
- Gewinnchancen.

Risikomodelle versuchen die Einflüsse durch zum Beispiel Konjunkturschwankungen und Änderungen der Konsumententwicklung auf den Preis und die Werthaltigkeit einer Anlage zu quantifizieren. Eine Anlage ist umso risikoreicher je mehr sich der Preis der Anlage negativ beeinflussen lässt. Zur Quantifizierung von Risiken werden Eingangsgrößen in Risikomodellen genutzt. Hierbei unterscheidet man hier zwischen zweiseitigen, einseitigen und anderen Risikomaßen.

Die zweiseitigen Risikomaße beziehen entsprechend ihrer Namensgebung beide Seiten der Renditeverteilung in Form von positiver und negativer Abweichung vom Erwartungswert in die Berechnung des spezifischen Risikomaßes ein. In diesem Fall beschreibt der sich links vom Erwartungswert befindliche Teil der Renditeverteilung die Verluste (engl. Downside risk) und der sich rechts vom Erwartungswert befindliche Teil der Renditeverteilung die Gewinne (engl. Upside risk). Die Varianz und Standardabweichung stellen unter Annahme normalverteilter Renditen beliebige Risikomaße dar. Die Volatilität, auch Standardabweichung, beschreibt die Streuung von Preisänderungen von Anlagen. Auch die Kovarianz stellt ein weitere Risikomaß zur Bestimmung des Gleichlaufs zweier Zufallsvariablen da [Ernst and Schurer, 2015, S.85].

3. Theoretische Grundlagen und Methoden

Einseitige Risikomaße betrachten nur den linken Teil der Risikoverteilung, daher lediglich die der Verluste. Der Value at Risk (VaR) fokussiert sich auf Verluste einer Renditezeitreihe und schätzt den potentiellen Verlust zu einem festgelegten Zeitraum mit festgelegter Prognosesicherheit. Die Risiken des Finanzinstruments werden dabei durch die Wahrscheinlichkeitsverteilung ihrer Rendite bestimmt. Bei diesem Risikomaß werden Wertschwankungen einer Anlage innerhalb eines bestimmten Betrachtungszeitraums mit einem bestimmten Konfidenzniveau berechnet und die Risiken entsprechend abgeschätzt. Es beschreibt, welchen Wert der Verlust einer bestimmten Risikoposition mit einer gegebenen Wahrscheinlichkeit innerhalb eines gegebenen Zeithorizonts nicht überschreitet. Somit beschreibt der VaR den möglichen Wertverlust mit festgelegter Prognosesicherheit und quantifiziert die Gefahr von Preisschwankungen gehaltener Finanzprodukte und die Möglichkeit erhebliche Verluste erleiden zu können. Das Risiko beschreibt daher die Unsicherheit, die Preisschwankungen bzw. negative Abweichung am Markt [Ernst and Schurer, 2015, S.86].

Sei $\{r_t\}_{t=1}^T$ die Renditezeitreihe einer Anlage und $\tau \in (0, 1)$ ein Quantil. Dann ist τ (100 τ %) VaR zur Zeit t , abgekürzt durch VaR_t , definiert durch

$$P(r_t > -VaR_t | \mathcal{F}_{t-1}) = \tau$$

mit \mathcal{F}_{t-1} als Informationsmenge zum Zeitpunkt $t - 1$.

Der VaR besagt „Wir sind zu X Prozent sicher, dass wir in den nächsten N Perioden nicht mehr als VaR Euro verlieren werden“. Der Verlust in N Perioden wird nur mit einer Wahrscheinlichkeit von $1 - \tau$ überschritten. Die Funktion hängt vom Zeithorizont N und dem Konfidenzniveau α ab. Daher ist mathematisch gesehen der VaR das τ -Quantil der Renditeverteilung. Da die Normalverteilungsannahme der Renditeverteilung in der Praxis nicht immer gegeben ist bietet die QR, die wir im nächsten Abschnitt vorstellen werden, eine weitere Möglichkeit die Quantilsfunktion des VaR zu modellieren. Der VaR wird dabei semiparametrisch geschätzt und ermöglicht das Einbeziehen weiterer unabhängiger Einflussfaktoren. Das VaR und weitere Quantile können dann dynamisch über ein Zeitreihenmodell

modelliert werden, was durch Q-VAR Modelle ermöglicht wird (Siehe Abschnitt 3.5).

3.3. Grundlagen der Quantilsregression

Nicht immer ist es von Interesse zu untersuchen, welche Effekte im Erwartungswert auf eine Zielvariable wirken, sondern im Wirtschaftskontext stehen Verluste und ihre Einflussfaktoren im Fokus. So ist es von Relevanz zukünftige Down-Side Risiken auf Hauspreise, sogenannte Hauspreise-at-Risk Einflüsse zu identifizieren um vorbeugend einzugreifen zu können. Bei der Analyse solcher Tail-Abhängigkeiten oder extremer-Verlust-Einflüssen erweist sich die Quantilsregression (QR) als sinnvolles Mittel, während übliche Schätzungen mittels dem Erwartungswert diese Effekte nicht nachweisen können. Die QR ermöglicht es Effekte auf jegliches Quantil der Zielvariablenverteilung zu untersuchen und soll im Folgenden näher erläutert werden basierend auf [Koenker, 2005].

Definition 1 (Quantilsfunktion). *Sei $\tau \in (0, 1)$ und Y eine Zufallsvariable. Dann ist das τ ($\tau * 100\%$)-Quantil*

$$q_\tau = \inf\{y \in \mathbb{R} \mid P(Y \leq y) \geq \tau\} = \inf\{y \in \mathbb{R} \mid F_Y^{-1}(\tau)\}.$$

Die Quantilsfunktion ist somit die inverse Verteilungsfunktion der Zufallsvariable und ordnet jeder Zahl zwischen null und eins den kleinsten Wert zu an dem die Verteilungsfunktion diesen Wert überschreitet. Veranschaulicht an einem Beispiel betrachten wir den Median einer Stichprobe, welcher dem 50%-Quantil entspricht. Dieser unterteilt die Daten in zwei gleichgroße Anteile. Die Wahrscheinlichkeit liegt somit bei 50%, dass eine beliebige Realisierung der Zufallsvariable unter oder über dem Median liegt. Dies lässt sich auch auf bedingte Verteilungsfunktionen übertragen.

Definition 2 (Bedingte Quantilsfunktion). *Seien Y und X Zufallsvariablen und bezeichne $F_{Y|X=x} = F_x(y)$ die bedingte Verteilung von Y gegeben $X = x$. Das*

3. Theoretische Grundlagen und Methoden

bedingte τ -Quantil, notiert als $q_\tau(Y | \mathbf{x})$, von Y bedingt auf x ist eine Funktion

$$q_\tau(Y | x) = \inf\{y \in \mathbb{R} \mid F_x(y) \geq \tau\} \equiv (F_x(y))^{-1}(\tau). \quad (3.1)$$

Die QR bietet eine Methode zur Schätzung bedingter Quantilsfunktionen. Während die klassische lineare Regression den Erwartungswert der bedingten Verteilung schätzt, schätzt die lineare QR ein beliebiges bedingtes Quantil. Dadurch lassen sich bestimmte Gruppen aus der Stichprobe genauer untersuchen und spezifische Effekte schätzen. So liefert die Methode auch Informationen über Randbereiche von Verteilungen, die sich als interessant erweisen können.

Von der linearen Regression zur QR In der linearen Regression wird der empirische Erwartungswert der Zielvariablen-Stichprobe (y_1, \dots, y_T) durch das Lösen von

$$\min_{\mu \in \mathbb{R}} \sum_{i=1}^T (y_i - \mu)^2$$

gefunden. Der bedingte Erwartungswert von Y gegeben x ist hierbei

$$\mu(x) = x^T \beta \quad \text{mit} \quad \min_{\beta \in \mathbb{R}^p} \sum_{i=1}^T (y_i - x^T \beta)^2.$$

Bei der Bestimmung der bedingten τ -Quantilsfunktion geht man ähnlich vor. Das τ Stichprobenquantil löst das Minimierungsproblem

$$\min_{q_\tau \in \mathbb{R}} \sum_{i=1}^T \rho(y_i - q_\tau),$$

wobei ρ die Verlustfunktion darstellt. Die bedingte τ -Quantilsfunktion wird dabei folgendermaßen geschätzt

$$\hat{q}_\tau(Y | x) = x^T \beta(\tau).$$

Dann ergibt sich der Schätzer

$$\hat{\beta}(\tau) = \min_{\beta(\tau) \in \mathbb{R}^p} \sum_{i=1}^T \rho(y_i - x_i^T \beta(\tau))$$

3.3. Grundlagen der Quantilsregression

und bildet damit die grundlegende Überlegung der QR, die in [Koenker, 2005] entwickelt wurde. Die Regressionsgleichung ist im Prinzip analog zur linearen Regression mit dem Unterschied, dass hier nicht der erwartete Mittelwert sondern das erwartete Quantil geschätzt wird. Die Parameterschätzer bedingen somit auf das gewählte Quantil und können daher entlang der Quantile variieren. Der Parameterschätzer β quantifiziert damit die erwartete Änderung in der Verteilung von Y für den Quantilspunkt q_τ , wenn x sich um eine Einheit erhöht. Zu beachten ist, dass eine Einheitsänderung in dem bedingten QR-Modell eine Änderung in der Verteilung von Y und nicht eine Änderung in der erwarteten Ausgabe ist. Anstatt der durchschnittlichen Änderung in Y wird somit die durchschnittliche Änderung des τ -Quantils von Y bedingt auf die Änderung in x bestimmt. Da die Parameter entlang der Quantile variieren können, bedarf die Parameterschätzung einen besonderen Umgang mit den Residuen, der im nächsten Abschnitt genauer erläutert wird [Koenker, 2005].

Ein Beispiel für ein multivariates Quantilsregressionsmodell wäre

$$Y_t = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon_t.$$

Die dazugehörige bedingte Quantilsfunktion von Y lautet dann

$$q_\tau(Y \mid x = (x_1, x_2)) = \beta_0 + \beta_1 x_1 + \beta_2 x_2.$$

Gesucht wird ein Schätzer

$$\hat{\beta} = (\hat{\beta}_0(\tau), \hat{\beta}_1(\tau), \hat{\beta}_2(\tau)).$$

Lösen des Optimierungsproblem zur Parameterschätzung der QR. Wie auch in der linearen Regression werden die Parameterschätzer durch Minimierung der Residuen geschätzt. Die QR unterscheidet sich dabei jedoch in der Wahl der Verlustfunktion. Zur Bestimmung der Parameterschätzer in der QR werden die Residuen über den sogenannten Pinball-Loss in Abhängigkeit des Quantils τ minimiert. Die Methode basiert auf der Idee, die Daten in zwei Gruppen zu unterteilen - diejenigen die unterhalb und oberhalb des Quantils liegen - und die dazugehörigen absoluten Residuen verschieden stark zu bestrafen. Der Residuenvektor

3. Theoretische Grundlagen und Methoden

wird somit in einen positiven und negativen Teil zerlegt.

Definition 3. Sei $\{(x_1, y_1), \dots, (x_T, y_T)\}$ eine beliebige Stichprobe. Der Pinball-Loss, auch Check Funktion oder Pinball Verlustfunktion genannt, ist definiert durch

$$\rho_\tau(\varepsilon_i) = \begin{cases} \tau\varepsilon_i & \text{for } \varepsilon_i > 0, \\ (1 - \tau)|\varepsilon_i| & \text{for } \varepsilon_i < 0, \end{cases} \quad (3.2)$$

mit $|\cdot|$ als Absolutwert und ε_i als Abweichung von y_i und dem geschätzten Quantil $q_\tau(Y | x_i)$. Demnach ist bei positivem Fehler y_i oberhalb des geschätzten Quantils und bei negativem Fehler unterhalb des geschätzten Quantils. Dementsprechend werden die absoluten Abweichungen mit τ bzw. mit $(1 - \tau)$ gewichtet.




Abbildung 3.2.: Pinball-Loss: Verlustfunktion für Quantile mit $\tau = 0.25$ aus [Koenker, 2005]

Unter der Annahme das $q_\tau(\varepsilon | x) = 0$ ergibt sich der Quantilsregressions-Schätzer $\hat{\beta}(\tau)$, definiert als

$$\hat{\beta}(\tau) = \operatorname{argmin}_{\beta \in B} \sum_{t=1}^T \rho_\tau(y_t - q_\tau(Y | x)) = \operatorname{argmin}_{\beta \in B} \sum_{t=1}^T \rho_\tau(y_t - x^T \beta).$$

Im Vergleich zur Kleinsten-Quadrate-Parameterschätzung bei der die Residuen quadriert werden, werden bei QR die absoluten Residuen verwendet und in Abhängigkeit vom Quantil gewichtet. Im Fall von $\tau = 0.5$ wird der Median bestimmt und dabei wird der bekannte Mean Absolute Error bzw. die gemittelte Summe der

3.4. Grundlagen der Zeitreihenanalyse

absoluten Abweichungen genutzt. Der Vektor $\beta^T \mathbf{x}$ ist dann der bedingte Stichproben Median von Y . Die dabei entstehende Regressionsgerade zerlegt die Daten in zwei Anteile, die im Fall vom Median gleichgroß sind und die Residuen gleichstark gewichtet. In der Regel werden die Daten entsprechend des gewählten Quantils in zwei verschieden große Anteile zerlegt und somit bildet die gewählte Verlustfunktion eine asymmetrische Gewichtung der absoluten Residuen.

Zusammenfassend ist es möglich die Effekte aller unabhängigen Variablen auf die gesamte bedingte Verteilung der Zielvariable zu modellieren und somit ein vollständigeres Bild, als bei den üblichen Erwartungswertmodellen zu erhalten. Durch die neue Form der Analyse von Zusammenhängen zwischen erklärenden und abhängigen Variablen können auch viele restriktive Annahmen der klassischen Regressionsmodelle relaxiert werden. Im Detail verzichtet man auf die Bedingung der Homoskedastizität und den Residuen wird auch keine bestimmte Verteilungsfunktion zu Grunde gelegt [Koenker, 2005]. Die normalverteilte Verteilungsannahme ist somit bei der QR nicht Voraussetzung und erlaubt es damit auch zuverlässigere Inferenzen für asymmetrisch und nicht-normalverteilte Zielvariablen abzuleiten. Besonders im wirtschaftlichen Kontext ist die Nutzung der QR daher entscheidend, da das Wirtschaftswachstum [Adrian et al., 2019, S.2], die Inflation [Ghysels et al., 2018, S.2] und oft auch Renditen [André et al., 2017, S.1] asymmetrische Verteilungen annehmen. Weiterhin gelten Quantile als Ausreißerresistent, womit die QR auch als robust gegen Ausreißer gilt. Schließlich ermöglicht die QR die direkte Ableitung von Tail-Abhängigkeiten unter der betrachteten Zielvariable. Eine indirekte Modellierung von Zeitreihenmodellen mit variierenden ersten bzw. zweiten Momenten ist daher bei Verwendung der QR nicht mehr nötig.

3.4. Grundlagen der Zeitreihenanalyse

Eine Zeitreihe ist eine geordnete Sammlung von wiederholten Beobachtungen, die sequentiell über die Zeit gemessen wurden. Da vergangene Werte keine exakten Prognosen für die zukünftigen Werte geben, spricht man oft von stochastischen Zeitreihen oder auch von stochastischen Prozessen. In der Zeitreihentheorie wer-

3. Theoretische Grundlagen und Methoden

den wiederholte Beobachtungen einer Reihe von Zufallsvariablen $X = (X_t)_{t=1, \dots, T}$ betrachtet. In der Praxis liegen diese in Form von Realisierungen (x_1, x_2, \dots, x_T) vor. Dabei wird angenommen, dass die Zeitabstände - dies können z.B. Tage, Monate, Quartale oder Jahre sein - äquidistant sind [Chatfield, 2004, S.11]. Die grundlegende, gemeinsame Verteilung der Zufallsvariablen ist im Allgemeinen nicht gegeben und wird über ein Wahrscheinlichkeitsmodell der gemeinsamen Verteilung geschätzt. Über den Mittelwert, die Varianz und den Kovarianzen lassen sich bereits viele Informationen über die Verteilung ableiten, welche daher von großer Bedeutung bei der Analyse von Zeitreihen und der Ableitung von passenden Modellen sind. Eine gute Übersicht über die Grundlagen der Zeitreihentheorie ist in [Tsay, 2002] zu finden. Bei der Betrachtung mehrerer Zeitreihen gleichzeitig werden diese meist als Vektor $\mathbf{X}_t = (X_{1t}, X_{2t}, \dots, X_{pt})^T$ mit $t = 1, \dots, T$ dargestellt. Um die Notation zu vereinfachen wird der Index t in Kontexten unterdrückt, in denen er keine Verwirrung verursacht.

Eigenschaften einer Zeitreihe. Nützliche Statistiken zur Analyse von Finanzzeitreihen sind die vier Momente einer Verteilung:

- Der Mittelwert $\mu = \mathbb{E}[X]$ misst die zentrale Lage der Verteilung,
- die Varianz $\sigma^2 = \text{Var}[X] = \mathbb{E}[X - \mathbb{E}[X]]^2$ misst die Variabilität,
- die Schiefe beschreibt die Symmetrie um den Mittelwert und ist approximiert durch das standardisierte 3. Moment

$$S(X) = \mathbb{E} \left(\frac{(X - \mu)^3}{\sigma^3} \right),$$

- die Wölbung bzw. Kurtosis misst das Randverhalten und wird mit dem standardisierten 4. Moment approximiert

$$K(X) = \mathbb{E} \left(\frac{(X - \mu)^4}{\sigma^4} \right).$$

Die Höhe der Tails gibt Aufschluss über das Schwankungsverhalten der Zeitreihe. Bei besonders vielen Werten in den Ausläufen spricht man von sogenannten heavy

3.4. Grundlagen der Zeitreihenanalyse

tails. Besonders im Risikomanagement, spielt die Randverteilung eine zentrale Rolle.

Für das gesuchte Modell mit bedingten Wahrscheinlichkeiten im Finanzanwendungsbereich ist die Normalverteilung

$$f(X_t | X_1, \dots, X_{t-1}, \theta) \sim \mathbb{N}(\mu_t, \sigma_t^2), \quad \theta = (\mu_t, \sigma_t^2)$$

von gängigem Gebrauch. Die dazugehörige Likelihood Funktion ist

$$f(X_1, \dots, X_T; \theta) = f(X_1; \theta) \prod_{t=2}^T \frac{1}{\sqrt{2\pi}\sigma_t} \exp\left(-\frac{(X_t - \mu_t)^2}{2\sigma_t^2}\right)$$

und dient dazu die Parameter θ aus den Realisierungen zu schätzen um Prognosen für μ und σ zu geben. Geschätzt werden diese mittels der Maximum Likelihood Schätzung

$$\theta_{\text{MLE}} = \underset{\theta}{\operatorname{argmax}} \log(f(X_1; \theta)) - \frac{1}{2} \sum_{t=2}^T \left(\log(2\pi) + \log(\sigma_t^2) + \frac{(X_t - \mu_t)^2}{\sigma_t^2} \right)$$

oder auch der klassischen Kleinste-Quadrate-Schätzung. Damit können Modelle gefunden werden, die das Niveau, die Varianz und beliebige Quantile der Verteilung vorhersagen können.

3.4.1. Stationarität

Zur Analyse von Zeitreihen zählt die sogenannte Stationarität als eine zentrale Eigenschaft, die zu untersuchen ist. Sie garantiert, dass Zeitreihen zeitlich stabile Eigenschaften besitzen. Dabei unterscheidet man zwischen strikter und schwacher Stationarität.

Definition 4 (Stationäre Prozesse). Sei $X = (X_t)_{t \in \mathbb{Z}}$ eine reelwertige Zeitreihe.

a) X ist strikt stationär \iff

$$(X_{t_1}, \dots, X_{t_n}) \sim (X_{t_1+h}, \dots, X_{t_n+h}) \quad \forall t_1, \dots, t_n, h.$$

b) X ist schwach stationär \iff der Prozess hat eine endliche Varianz und die

3. Theoretische Grundlagen und Methoden

Mittelwertfunktion

$$\mu_X(t) = \mathbb{E}(X_t), \quad t \in \mathbb{Z},$$

sowie die Autokovarianzfunktion

$$\gamma_X(t, t+h) = \text{Cov}(X_t, X_{t+h}), \quad t, h \in \mathbb{Z},$$

sind unabhängig von t und es gilt

- $\mu_X(t) \equiv \mu, \quad \forall t \in \mathbb{Z},$
- $\gamma_X(t, t+h) \equiv \gamma_X(h), \quad \forall t, h \in \mathbb{Z}.$

Somit ist ein stochastischer Prozess strikt stationär, wenn alle Verteilungsfunktionen von Zufallsvariablen des Prozesses unabhängig vom Untersuchungszeitpunkt t identisch sind (zeitinvariante Verteilung). Dies ist oft nicht gegeben, daher findet in der Praxis meist nur die schwache Stationarität ihre Anwendung. Diese besagt, dass Erwartungswerte, Varianz und Kovarianz gegenüber der Zeit unabhängig sind und damit über die Zeit stabile Eigenschaften aufweisen. Die Zeitreihe variiert um ein konstantes Band und ist in Erwartung fix.

Zerlegung von Zeitreihen. Empirische Zeitreihen weisen verschiedene systematische Muster wie Trends, Zyklen und Saisoneffekte auf. Der Trend beschreibt die Langzeitrichtung einer Zeitreihe und kann entweder den Zuwachs oder die Senkung in den Daten beschreiben. Über die Zeit häufen sich dabei die Beobachtungswerte entlang des Trends. Der Saisoneffekt beschreibt saisonale Einflüsse, die die Daten beeinflussen. So können zum Beispiel bestimmte Monate einen besonders großen Effekt auf die Zeitreihe haben. Ein Zyklus weist ein wellenförmiges Verhalten im Niveau der Daten auf und tritt z.B. auf wenn die Zeitreihe von Konjunkturzyklen betroffen ist. Oftmals werden Trend und Zyklus in eine Komponente zusammengefasst [Chatfield, 2004, S.12].

Jede Zeitreihe lässt sich in drei Komponenten unterteilen, die die Werte der Zeitreihe bestimmen: Die Trendkomponente, die saisonalen Komponente und die stationäre Komponente. Bei der Untersuchung von stabilen Eigenschaften ist die

3.4. Grundlagen der Zeitreihenanalyse

Bereinigung von Trends und saisonalen Effekten ein gängiger Prozess in der exploratorischen Analyse. Der Trend kann dabei deterministisch oder stochastischer Natur sein. Der deterministische Trend kann dabei linear, quadratisch oder exponentiell sein. Im letzteren Fall kann mittels Transformation durch Logarithmieren der Trend linearisiert werden. Zur Bereinigung des Trends gibt es verschiedene Möglichkeiten wie sogenannte lineare Filter zum Differenzieren oder Glätten der Zeitreihe. In einem Trend-stationären Modell können die Beobachtungen entweder additiv oder multiplikativ über die Komponenten ausgedrückt werden. In einem globalen Modell können saisonale Effekte und Trendeffekte über eine Regression einbezogen werden, während in lokalen Modellen lineare Filter wie das Differenzieren genutzt werden, um mit den Komponenten umzugehen. Bei einem multiplikativen Modell werden die Komponenten mit Hilfe der Logarithmus-Funktion linearisiert und in ein additives Modell umgewandelt.

Integrierte Prozesse. Nicht immer ist Stationarität der Zeitreihe gewährleistet. Dann nennt man Zeitreihen nicht-stationär oder integrierte Prozesse. In dem Fall liegt ein deterministischer oder stochastischer Trend vor, der durch Differenzieren beseitigt und in einen stationären Prozess umgewandelt werden kann. Wie oft differenziert werden muss, damit die Zeitreihe stationär wird, bestimmt der Grad der Integrität.

Kointegration. Besonders bei der Analyse von Wechselwirkungen zwischen zwei nicht stationären Zeitreihen kann das Phänomen der Kointegration auftreten. Es besagt, dass zwei nicht stationäre Prozesse eine stabile Wechselwirkung aufweisen. Mit Hilfe von Regressionsanalysen lässt sich eine stabile Wechselwirkung festlegen, die zu stationären Residuen führt und damit stabile Eigenschaften zwischen den Zeitreihen identifiziert. Besonders bei der Untersuchung von Wechselwirkungen in einem System von Zeitreihen ist die Kointegration von zentraler Bedeutung [Wooldridge, 2009, S.646].

Die Prüfung von Stationarität kann mit Hilfe des Augmented-Dickey-Fuller (ADF) Test, auch bekannt als Unit Root Test, durchgeführt werden. Der statistische Test testet hier auf Einheitswurzeln um nicht-stationäre Prozesse zu identifizieren, d.h. bei Nullstellen auf dem Einheitskreis ist der Prozess nicht stationär und

3. Theoretische Grundlagen und Methoden

muss differenziert werden, um in einen stationären Prozess umgewandelt zu werden. Wird die Nullhypothese verworfen, so hat die Zeitreihe keine Einheitswurzel und ist somit stationär [Wooldridge, 2009, S.641].

3.4.2. Abhängigkeit zwischen den Zeitreihenwerten

Die Korrelation zwischen der untersuchten Variable und ihren vergangenen Werten ist im Fokus der Zeitreihenanalyse. Die Korrelationen werden serielle Korrelationen oder auch Autokorrelationen genannt und bilden das grundlegende Werkzeug zur Untersuchung von zeitlichen Abhängigkeiten in Zeitreihen. Folgende Instrumente werden für die Identifizierung der Abhängigkeiten zwischen den Zeitreihenwerten verwendet und im Folgenden erläutert: Autokorrelationsfunktion (ACF) und Partielle Autokorrelationsfunktion (PACF).

Wenn in einer schwach stationären Zeitreihe X_t die lineare Abhängigkeit zwischen X_t und seinen vergangenen Werten X_{t-l} von Interesse ist, wird das Konzept der Korrelation verallgemeinert zur Autokorrelation. Der Korrelationskoeffizient zwischen X_t und X_{t-l} wird Lag-1 Autokorrelation von X_t genannt und üblicherweise mit ρ_l bezeichnet. Unter der Annahme schwacher Stationarität ist ρ_l eine Funktion von l [Tsay, 2002].

Definition 5 (Autokorrelationsfunktion). *Die ACF definiert sich durch*

$$\rho_l = \frac{\text{Cov}(X_t, X_{t-l})}{\sqrt{\text{Var}(X_t) \text{Var}(X_{t-l})}} = \frac{\text{Cov}(X_t, X_{t-l})}{\text{Var}(X_t)}.$$

Hier wird die Eigenschaft $\text{Var}(X_t) = \text{Var}(X_{t-l})$ für eine schwach stationäre Zeitreihe verwendet. Aus der Definition folgt, dass $\rho_0 = 1, \rho_l = \rho_{-l}$ und $-1 \leq \rho_l \leq 1$. Darüber hinaus ist die schwach stationäre Zeitreihe nicht autokorreliert, genau dann wenn $\rho_l = 0$ für alle $l > 0$ [Tsay, 2002, S.24].

Die Idee der partiellen Autokorrelation basiert auf der Berechnung der Autokorrelation zweier Zeitreihenvariablen X_t und X_{t+k} unter der Bedingung, dass die dazwischen liegenden Zeitreihenvariablen nicht in Betracht gezogen werden. Es wird also der direkte Einfluss von X_t auf X_{t+k} gemessen. PACF ist ein nützliches Werkzeug zur Bestimmung der p-Ordnung eines ARMA-Modells [Tsay, 2002,

S.36].

Definition 6 (Partielle Autokorrelationsfunktion). *Die PACF wird wie folgt definiert*

$$\pi(l) = \text{Corr}(X_{t+l}, X_t \mid X_{t+1}, X_{t+2}, \dots, X_{t+l-1}).$$

Somit ist $\pi(l)$ die partielle Autokorrelation der Zeitreihe $X = (X_t : t \in \mathbb{Z})$ zum Lag l ([Kreiß and Neuhaus, 2006, S. 40])

In diesem Abschnitt wurden die Methoden zur Identifizierung der Abhängigkeiten zwischen den Zeitreihenwerten erläutert. In Abschnitt 3.4.3 und 3.4.4 werden weiterführend die Modelle für die univariate und multivariate Zeitreihenanalyse beschrieben.

3.4.3. Univariate Analysemethoden

Jede stationäre Zeitreihe kann durch einen $AR(p)$ oder einen $MA(q)$ Prozess approximiert werden und bedingen dabei auf vergangene Lags oder vergangene stochastische Einflüsse (Schocks) der Zeitreihe. Deren Kombination bilden die $ARMA(p, q)$ Prozess. Durch diese Modelle kann die dynamische Struktur der Zeitreihe beschrieben werden. Hierzu bedarf es zunächst die Definition des White Noise.

Definition 7 (White Noise). *Eine Zeitreihe Z_t wird White Noise bzw. weißer Rausch genannt, wenn Z_t eine Sequenz von unabhängigen und identisch verteilten Zufallsvariablen ist mit endlichem Mittelwert und endlicher Varianz. Wenn für die Zeitreihe $Z_t \sim N(0, \sigma^2)$ gilt, spricht man von Gaußschen White Noise Prozessen. Für White Noise Zeitreihen sind alle ACFs null.*

Definition 8. *Das $ARMA(p, q)$ Modell hat die Form*

$$X_t = \phi_0 + \sum_{i=1}^p \phi_i X_{t-i} + Z_t - \sum_{j=1}^q \theta_j Z_{t-j} \quad (3.3)$$

mit Z_t als White Noise Zeitreihe und p, q als nicht-negative ganze Zahlen. Das AR und das MA Modell sind Spezialfälle des $ARMA(p, q)$ Modells.

3. Theoretische Grundlagen und Methoden

Zur Identifikation des passenden Modells können verschiedene Werkzeuge verwendet werden um den Grad p und q zu bestimmen. Anhand der PACF bzw. ACF kann die Ordnung des Modells bestimmt werden oder es können auch Informationskriterien wie zum Beispiel das AIC-Kriterium genutzt. Als Faustregel gilt: Klingen die Autokorrelationen im ACF Diagramm und brechen die partiellen Korrelationen am Lag p im PACF Diagramm ab, so wird ein AR(p) Modell angewendet. Im umgekehrten Fall, brechen die Autokorrelationen im ACF Diagramm am Lag q ab wird ein MA(q) Modell angewendet. Klingen die Autokorrelationen in beiden Diagrammen ab, so wird ein ARMA(p,q) Modell herangezogen [Tsay, 2002, S.48].

Definition 9 (Akaike-Informationskriterium). *Nach dem Akaike-Informationskriterium (AIC) wird das Modell gewählt, das*

$$AIC = -2L(\theta) + 2k$$

minimiert. Dabei ist $L(\theta)$ die Likelihoodfunktion und $k = p + q + 1$ bzw. $k = p + q$ mit oder ohne konstanten Term. Die Variable k dient dabei als Bestrafungsterm um hoch parametrisierte Modelle zu penalisieren.

Definition 10 (Bayesian-Informationskriterium). *Nach dem Bayes-Informationskriterium (BIC) wird das Modell gewählt, das*

$$BIC = -2L(\theta) + k * 2\log(n)$$

minimiert. Dabei ist $L(\theta)$ die Likelihoodfunktion und $k = p + q + 1$ bzw. $k = p + q$ mit oder ohne konstanten Term und Stichprobengröße n .

Der Bestrafungsterm wirkt damit stärker auf hochparametrisierte Modelle als bei dem AIC-Kriterium.

Nach der Wahl des passenden Modells müssen noch diagnostische Checks durchgeführt werden, welche die Güte der Modellanpassung überprüfen, wobei hier die Untersuchung der Residuen zentral ist. Dabei wird überprüft, ob weitere Informationen in den Residuen enthalten sind bzw. Autokorrelationen in den Residuen vorliegen. Für diese Prüfung bietet sich der Ljung-Box Test an, mit dem getestet

werden kann, ob die Residuen einem White Noise Prozess folgen und stationär sind oder ob noch Autokorrelationen enthalten sind. Die Teststatistik ist

$$Q(m) = T(T + 2) \sum_{l=1}^m \frac{\rho_l^2}{T - l}$$

mit Nullhypothese $H_0 : \rho_1 = \dots = \rho_m = 0$ und Alternativhypothese $H_a : \rho_i \neq 0$ für ein $i \in \{1, \dots, m\}$. Unter der Annahme der Nullhypothese ist $Q(m)$ asymptotisch eine Chi-Quadrat Zufallsvariable mit m Freiheitsgraden. Diese wird somit abgelehnt, wenn $Q(m) > \chi_\alpha^2$ gilt [Tsay, 2002, S. 25].

3.4.4. Multivariate Analysemethoden

Bei der Untersuchung von dynamischen Strukturen einer Variable können diese nicht nur von der eigenen Vergangenheit sondern auch von vergangenen Werten anderer Variablen abhängen. Diese Idee greift das folgende Modell auf und modelliert Vektor-basiert mehrere Zeitreihenvariablen gleichzeitig. Demnach ist eine multivariate Zeitreihe ein Vektor aus mehreren Einzelzeitreihen, die auch Komponenten genannt werden. Das Modell liefert Prognosen mehrerer Zeitreihen gleichzeitig und beschreibt interdependente Beziehungsstrukturen untereinander. Oft spricht man dann auch von einem System von Variablen, in dem die Variablen Zielvariablen und erklärende Variablen zugleich sind. Hierbei wird jede Variable als eine Funktion aller anderen Variablen des Modells formuliert, wobei die jeweils anderen Variablen zeitlich verzögert in die jeweilige Gleichung eingehen werden. Zur Identifikation von Interdependenzen innerhalb eines Systems von Variablen gelten Vektorautoregressionsmodelle als nützliches Werkzeug.

Definition 11 (Vektor Autoregressive Modell). *Das Vektor Autoregressive Modell, kurz VAR Modell, beschreibt ein System von Regressionen. Sei $\mathbf{X}_t = (X_{1t}, \dots, X_{kt})^T$ eine multivariate Zeitreihe mit k Zeitreihen im System zur Zeit t . Dann ist \mathbf{X}_t ein sogenannter VAR Prozess der Ordnung 1 oder VAR(1), wenn es dem Modell*

$$\mathbf{X}_t = \phi_0 + \Phi \mathbf{X}_{t-1} + \mathbf{u}_t \quad (3.4)$$

folgt mit ϕ_0 als k dimensionaler Vektor, Φ und \mathbf{X}_{t-1} als $k \times k$ Matrix und \mathbf{u}_t als

3. Theoretische Grundlagen und Methoden

Reihe von unkorrelierten Zufallsvektoren mit $\mathbb{E}(u_t) = 0$ und Kovarianzmatrix Σ_u . Die Kovarianzmatrix ist positiv definit, da sonst die Dimension von \mathbf{X}_t reduziert werden [Tsay, 2002].

Zur Veranschaulichung betrachte man den bivariaten Fall, d.h. $k = 2$. Dann ist $\mathbf{X}_t = (X_{1t}, X_{2t})^T$ und $\mathbf{u}_t = (u_{1t}, u_{2t})^T$.

Das $VAR(1)$ Modell besteht aus zwei Regressionsgleichungen

$$\begin{aligned} X_{1t} &= \phi_{10} + \Phi_{11}X_{1,t-1} + \Phi_{12}X_{2,t-1} + u_{1t}, \\ X_{2t} &= \phi_{20} + \Phi_{21}X_{1,t-1} + \Phi_{22}X_{2,t-1} + u_{2t}, \end{aligned} \quad (3.5)$$

wobei Φ_{ij} das (i, j) Element der Koeffizientenmatrix Φ und ϕ_{i0} das i -te Element von ϕ_0 ist.

In der ersten Gleichung beschreibt Φ_{12} den bedingten Effekt von $X_{2,t-1}$ auf X_{1t} . Gilt $\Phi_{12} = 0$, bedeutet dies, dass X_{1t} nicht von $X_{2,t-1}$ abhängt und nur von der eigenen Vergangenheit beeinflusst wird. Gleiches lässt sich auf Φ_{12} und die zweite Gleichung übertragen. Unter gleichzeitiger Betrachtung der Gleichungen in (3.5) lassen sich folgende Beziehungsstrukturen ableiten: Wenn $\Phi_{12} = 0$ und $\Phi_{21} \neq 0$ dann gibt es eine einseitige Beziehung von X_{1t} auf X_{2t} . Gilt $\Phi_{12} = \Phi_{21} = 0$, so sind X_{1t} und X_{2t} entkoppelt und damit unabhängig voneinander. Wenn $\Phi_{12} \neq 0$ und $\Phi_{21} \neq 0$, dann herrscht eine Feedback Beziehung zwischen den beiden Zeitreihen.

Im Allgemeinen misst damit die Koeffizientenmatrix Φ die dynamische Abhängigkeit aller Variablen im System. Dabei können simultane Beziehungen, gleichlaufende Beziehungen oder entkoppelte Zeitreihenkomponenten auftreten. Das $VAR(1)$ Modell basiert demnach auf einem Regressionsmodell unter Betrachtung bis zu einem Schritt bzw. Lag in die Vergangenheit. Dies kann auf bis zu p Schritten erweitert und mit dem $VAR(p)$ Modell verallgemeinert werden unter Betrachtung von p Perioden in die Vergangenheit.

Definition 12 (Vector AR(p) Prozess).

Die Zeitreihe \mathbf{X}_t folgt einem $VAR(p)$ Modell, wenn folgendes erfüllt ist

$$\mathbf{X}_t = \phi_0 + \Phi_1 X_{t-1} + \dots + \Phi_p \mathbf{X}_{t-p} + u_t, \quad p > 0. \quad (3.6)$$

3.4. Grundlagen der Zeitreihenanalyse

Somit beschreibt p die Anzahl der Lags, auf die das Modell aufbaut. Das $VAR(p)$ Modell beruht somit auf dem $AR(p)$ Modell mit dem Unterschied, Vektoren als Zielvariablen zu nutzen und damit mehrere Variablen gleichzeitig zu modellieren. Der große Unterschied zum $AR(p)$ Modell ist, dass Lags der anderen Zielvariablen auch in den Modellen enthalten sind. Da \mathbf{X}_t ein Vektor der Dimension k ist, sind somit k Zielvariablen im Modell enthalten.

Mit Hilfe des AIC und BIC Kriteriums kann das optimale Lag bestimmt werden. Die Schätzung des ausgewählten Modells verläuft dann über die Methode der Kleinsten Quadrate oder der Maximum Likelihood Methode. Für die Modelldiagnostik müssen Inkonsistenzen ausgeschlossen werden. Dies verläuft analog zu eindimensionalen Modellen über die Überprüfung der Residuen auf Autokorrelationen mit Hilfe des Portmanteau Tests. Mit dem multivariaten Portmanteau Test wird über die Statistik das Vorhandensein von Auto bzw. Kreuzkorrelation in einer Vektorzeitreihe \mathbf{X}_t getestet. Damit ist

$$Q_k(m) = T^2 \sum_{\ell=1}^m \frac{1}{T-\ell} \text{tr} \left(\widehat{\mathbf{\Gamma}}_{\ell} \widehat{\mathbf{\Gamma}}_0^{-1} \widehat{\mathbf{\Gamma}}_{\ell} \widehat{\mathbf{\Gamma}}_0^{-1} \right), \quad (3.7)$$

mit geschätzter Korrelationsmatrix $\Sigma_u = \widehat{\mathbf{\Gamma}}_0$ und dessen Schätzung zum Lag- ℓ $\widehat{\mathbf{\Gamma}}_{\ell}$ [Tsay, 2002, S.308].

Die zentrale und restriktive Bedingung für die Nutzung von VAR Modellen ist die Stationarität des Modells [Lütkepohl, 2005, S. 26]. Stabile VAR Prozesse implizieren Stationarität [Lütkepohl, 2005, S. 24], weswegen man die Stationarität aller Zeitreihenkomponenten vor der Modellierung mit dem Unit Root Test überprüft. Im Fall von nicht-stationären Zeitreihen, werden diese durch Differenzieren oder durch andere Filter je nach Anwendungsfall in stationäre Zeitreihen transformiert. Zusätzlich lässt sich eine Alternative zum VAR Modell für kointegrierte Zeitreihen nutzen, welche es ermöglicht nicht-stationären Zeitreihen mit gleichem stochastischen Trend in einem Modell zu modellieren. Dieses Modell lautet Vector-Error-Correction Modell (VECM), da hierbei die Fehlerterme in Abhängigkeit des gemeinsamen Trends zwischen den Zeitreihen korrigiert werden [Wooldridge, 2009].

3. Theoretische Grundlagen und Methoden

VAR Modell in Strukturform. Die Modellierung des VAR Modells beruht auf der Vorstellung, dass die Variablen des Modells in jeder Periode von stochastischen Einflüssen, sogenannten Schocks, beeinflusst werden. Da diese Schocks nicht direkt beobachtbar sind, müssen Annahmen getroffen werden, die eine Identifikation der Schocks ermöglichen. Grundlegend ist dabei die Annahme, dass die unbeobachtbaren Schocks nicht miteinander korrelieren, denn nur so können die Wirkungen eines isolierten Schocks im Zeitverlauf auf das System untersucht werden. Diese Idee greift das VAR Modell in Strukturform auf, welches eine Abwandlung des verallgemeinerten VAR Prozesses ist. Es ermöglicht im dynamischen Modell Übertagungseffekte zu identifizieren, d.h. welchen Einfluss hat ein Schock in der einen Variable in den folgenden Perioden auf die anderen Variablen. Dies tritt auf wenn die Varianz-Kovarianz-Matrix Σ_u eine Diagonalmatrix ist. In dem Fall können auch kontemporäre Effekte auftreten. Diese können noch weiter eingeschränkt werden in dem die Varianz-Kovarianz-Matrix weiter eingeschränkt wird.

Definition 13. *VAR Modell in Strukturform Das VAR(1) Modell in Strukturform*

$$\tilde{X}_t = \omega + A_0 \tilde{X}_t + A_1 \tilde{X}_{t-1} + \epsilon_t, \quad \epsilon_t \sim i.i.d. (0, \Sigma)$$

mit A_0 und A_1 Koeffizientenmatrizen der Dimension $k \times k$ und ω als $k \times 1$ Konstantenvektor und ϵ_t als $k \times 1$ Vektor von *i.i.d.* strukturellen Schocks mit Erwartungswert null und Σ als Diagonalmatrix. Weiterhin nehmen wir in unserem Modell an, dass die Matrix A_0 eine untere Dreiecksmatrix ist mit Nullwerten in den Diagonaleinträgen.

Weiterhin gilt folgende Umformung von VAR in Strukturform zur Standard VAR Modell:

$$\tilde{X}_t = \omega + A_0 \tilde{X}_t + A_1 \tilde{X}_{t-1} + \epsilon_t,$$

$$\tilde{X}_t - A_0 \tilde{X}_t = \omega + A_1 \tilde{X}_{t-1} + \epsilon_t,$$

$$(I - A_0) \tilde{X}_t = \omega + A_1 \tilde{X}_{t-1} + \epsilon_t,$$

$$\tilde{X}_t = (I - A_0)^{-1} \omega + (I - A_0)^{-1} A_1 \tilde{X}_{t-1} + (I - A_0)^{-1} \epsilon_t.$$

Somit kann das strukturelle VAR Modell in eine reduzierte Form umgewandelt werden mit Konstantenvektor $\phi = (I - A_0)^{-1} \omega$, Koeffizientenmatrix $\Phi_1 = (I -$

$A_0)^{-1}A_1$ und Fehlerterm $u_t = (I - A_0)^{-1}\varepsilon_t$.

3.4.5. Impulse Antwort Funktion (IAF)

Die Langzeitbeziehungen zwischen Variablen im VAR Modell lassen sich nicht direkt von der Parametermatrix ablesen. Daher werden sogenannte Impulse Antwort Funktionen (IAF) als Werkzeug genutzt um VAR Modelle zu interpretieren. Fällt in einer Variable ein einmaliger Schock auf, so wird die Reaktion der anderen Variablen im VAR Modell entlang der Zeit beobachtet. Dabei beschreibt die Impulse Response Funktion bzw. Impuls Antwort Funktion die Art und Dauer, mit der sich ein Schock bzw. Impuls, der zu ein Zeitpunkt t auftritt, auf spätere Zeitreihenwerte auswirkt.

Tritt zum Zeitpunkt t in (3.5) ein Einheitsschock in u_{1t} auf, beeinflusst dieser simultan X_{1t} . In der nächsten Periode $t + 1$ kann zusätzlich zur ersten Variable X_{1t+1} auch die zweite Variable X_{2t+1} beeinflussen. Diese zeitverzögerten Einflüsse werden in der Impulse Antwort Funktion erkenntlich. Über einen längeren Zeitraum kann die Auswirkung eines Schocks in einer Variable auf weitere Variablen verfolgt werden.

Ist das VAR Modell stationär, so hat das zugrundeliegende Polynom ihre Nullstellen außerhalb des Einheitskreises. In dem Fall lässt sich das VAR Modell in ihre Moving Average Repräsentation darstellen:

$$X_t = u_t + \sum_{i=1}^{\infty} \theta_i u_{t-i}. \quad (3.8)$$

Die Darstellung zeigt explizit den Effekt eines vergangenen Schocks u_{t-1} ($i > 0$) auf die gegenwärtige Zeitreihe X_t . Die Koeffizientenmatrix θ_i beschreibt dann die Impulse Antwort Funktion des VAR Modells. Für eine schwach stationäre Zeitreihe gilt, dass die Koeffizienten exponentiell abklingen bei steigendem i . Genauer wird bei der Impulse Antwort Reaktion der marginale Effekt eines Schocks auf eine Variable verfolgt durch ein System, bei dem eine Komponente von u_t auf eins gesetzt wird und alle anderen Komponenten auf null gesetzt werden. Dann werden die Antworten der Komponenten in X_t über den Zeitverlauf ausgewertet. Die Impulsantworten sind die Elemente der Matrix Θ_i . Oft werden die u_t

3. Theoretische Grundlagen und Methoden

Prognosefehler der Impulse Antwort genannt, da die u_t der Prognosefehler eines Prognoseschritts in die Zukunft sind.

Die Orthogonalisierung der ursprünglichen Schockvariablen u_t löst das Problem der simultanen Korrelation der Schockvariablen. Allerdings entsteht eine neue Herausforderung mit der Orthogonalisierung, da sich die Koeffizientenmatrix mit der Reihenfolge der u_t -Variablen ändert. Bei der Festlegung der Anordnung der Variablen in X_t sollten daher wirtschaftstheoretische Überlegung zur Wirkungsbeziehungen der abhängigen Variablen hinterfragt werden[Rinne, 2004].

Impulse Antworten in Bezug auf linearen VAR Modellen haben die Eigenschaft zeitinvariant zu sein. Die Form ist invariant zur Größe und Richtung des Impulses. Diese Eigenschaften machen es einfach, die Reaktionen der Variable graphisch darzustellen. In der Praxis gelten diese linearen Ansätze oft als unrealistisch, da positive Schocks andere Effekte als negative Schocks auf das System auslösen können. Zudem kann der Effekt des Schocks auch abhängig vom Zustand des Systems und vom Zeitpunkt, an dem der Schock ausgelöst wird, sein. In diesen Fällen erweisen sich nichtlineare Modelle als nützliche Lösungsansätze. Modelle, die dynamischen Effekte von Schocks unterscheiden können, werden im nächsten Unterkapitel vorgestellt.

3.5. Quantil-Vektor Autoregressive Methoden

Das VAR Modell beschreibt die durchschnittliche Interaktion zwischen den betrachteten Variablen im System. Zur Untersuchung von dynamischen Effekten auf bestimmte Quantile der Variablen lässt sich das VAR Modell mithilfe der Theorie aus Abschnitt 3.3 zu den sogenannten Quantil Vektor Autoregressive (Q-VAR) Modellen erweitern. Gleichermaßen lässt sich das Konzept der IAF aus Abschnitt 3.4.5 übertragen.

Es können sowohl Langzeitrisiken beobachtet als auch Stress-Szenarien simuliert werden. Gleichzeitig wird damit die Erweiterung von VAR Modellen auf Quantile realisiert mit der Möglichkeit nicht nur Beziehungen von Variablen im Zentrum, sondern auch entlang der gesamten bedingten Verteilung der abhängigen Variablen zu erforschen. Das dynamische Modell kann damit entlang der

3.5. Quantil-Vektor Autoregressive Methoden

Quantile variieren. Dies ist vor allem bei Stresstests relevant, dessen Ziel es ist Tail-Abhängigkeiten der Wirtschaft bei einem großen negativen Finanz- oder Realwirtschaftlichen Schock zu simulieren. Da aber Instabilität im Finanzsystem vor allem auf Tail-Abhängigkeiten beruht, bieten sich zur Analyse folgende Modelle an, um den Einfluss von Tail Schocks zu modellieren und Feedbackeffekte genauer zu untersuchen.

Nun verbinden wir die Theorie der bedingten Quantilfunktionen aus Abschnitt 3.3 mit derjenigen der VAR Modellen aus Abschnitt 3.4.4. Dazu betrachten wir das bivariate VAR(1) Modell:

$$\begin{aligned}X_{1,t} &= \phi_{10} + \Phi_{11}X_{1,t-1} + \Phi_{12}X_{2,t-1} + u_{1,t}, \\X_{2,t} &= \phi_{20} + \Phi_{21}X_{1,t-1} + \Phi_{22}X_{2,t-1} + u_{2,t}.\end{aligned}$$

Durch Nutzung der Erwartungswertfunktion werden hier die Parameter geschätzt

$$E_t(X_t) = E(X_t|\Omega_{t-1}),$$

wobei Ω_{t-1} die Informationsmenge aller zum Zeitpunkt $t - 1$ bekannten Variablenwerte beinhaltet. Da $E_t(u_t) = 0$, folgt

$$\begin{aligned}E_t(X_{1t}) &= \phi_{10} + \Phi_{11}X_{1,t-1} + \Phi_{12}X_{2,t-1} \\E_t(X_{2t}) &= \phi_{20} + \Phi_{21}X_{1,t-1} + \Phi_{22}X_{2,t-1}.\end{aligned}$$

Zur Herleitung des Q-VAR(1) Modells wenden wir nun die bedingte Quantilfunktion auf das Vektorautoregressive Model an und nutzen Quantilsregression zur Schätzung der Parameter. Damit können Dynamiken auf ein beliebiges Quantil eingefangen und Risiko-Szenarien abgeleitet werden.

$$\begin{aligned}q_{\tau t}(X_{1t}) &= \phi_{10}(\tau) + \Phi_{11}(\tau)X_{1,t-1} + \Phi_{12}(\tau)X_{2,t-1}, \\q_{\tau t}(X_{2t}) &= \phi_{20}(\tau) + \Phi_{21}(\tau)X_{1,t-1} + \Phi_{22}(\tau)X_{2,t-1}.\end{aligned}$$

Für ein beliebig großen, k-dimensionalen Vektor gilt dann

3. Theoretische Grundlagen und Methoden

$$\underbrace{q_\tau(X_t | \Omega_t)}_{k \times 1} = \underbrace{\phi(\tau)}_{k \times 1} + \underbrace{\Phi_1(\tau)}_{k \times k} \underbrace{X_{t-1}}_{k \times 1}.$$

Da ebenfalls kontemporäre Effekte auftreten können, bietet sich das Q-VAR Modell in Strukturform an, welches restriktivere Modellannahmen und Einschränkungen in der Varianz-Kovarianzmatrix der Fehlerterme voraussetzt. Betrachte das Vektorautoregressive Modell in Strukturform

$$X_{t+1} = \phi + \Phi_0 X_{t+1} + \Phi_1 X_t + \epsilon_{t+1}, \quad \epsilon_{t+1} \sim \text{i.i.d. } (0, \Sigma)$$

mit Koeffizientenmatrizen Φ_0 und Φ_1 . Diese haben besondere Eigenschaften im Vergleich zum Standard VAR Modell, da die Fehlerterme Zeitreihenabhängigkeiten aufweisen, die man in dem Modell bereinigen möchte. Diese Modellrepräsentation ist vor allem für die Prognose notwendig und kann nicht über die Standardform abgeleitet werden, im Gegensatz zum VAR Modell [Chavleishvili and Manganelli, 2019, S.13]. Damit die Varianz-Kovarianzmatrix der Residuen eine Diagonalmatrix ist, müssen bestimmte Regressionskoeffizienten eingeschränkt werden.

Sei $\mathbf{X}_t = (X_{1t}, \dots, X_{kt})'$ eine multivariate Zeitreihe mit k -Zeitreihen im System unter Betrachtung des Zeitpunkts t . Dann gilt

$$\underbrace{q_\tau(\mathbf{X}_{t+1} | \Omega_t)}_{k \times 1} = \underbrace{\omega(\tau)}_{k \times 1} + \underbrace{A_0(\tau)}_{k \times k} \underbrace{\mathbf{X}_{t+1}}_{k \times 1} + \underbrace{A_1(\tau)}_{k \times k} \underbrace{\mathbf{X}_{tt}}_{k \times 1}$$

mit der Regressionsgleichung

$$X_t = \omega(\tau) + A_0(\tau)X_t + A_1(\tau)X_{t-1} + \epsilon_{t+1}(\tau)$$

mit $P(\epsilon_{i,t+1}(\tau_j) < 0 | \Omega_{it}) = \tau_j$ und $i = 1, \dots, k, \quad j = 1, \dots, p$.

Für den zweidimensionalen Fall erhalten wir damit

$$\begin{aligned} X_{1,t+1} &= \omega_1(\tau_1) + a_{11}(\tau_1)X_{1,t} + a_{12}(\tau_1)X_{2,t} + \epsilon_{1t}(\tau_1), \\ X_{2,t+1} &= \omega_2(\tau_2) + a_{021}(\tau_2)X_{1,t+1} + a_{21}(\tau_2)X_{1,t} + a_{22}(\tau_2)X_{2,t} + \epsilon_{2t}(\tau_2). \end{aligned}$$

Hier wird erkenntlich, dass die erste Komponente im System einen direkten Einfluss auf die zweite Komponente im System hat. Das bedeutet, dass die zweite

3.5. Quantil-Vektor Autoregressive Methoden

Komponente kontemporär auf die erste reagiert. Damit hat ein Schock in der ersten Variable einen direkten Einfluss auf die zweite Variable. Dies wird durch den Parameter a_{021} ($\tau_2 \neq 0$) ermöglicht. Durch $a_{12}(\tau_1)$ und $a_{21}\tau_2 \neq 0$ sind Feedbackbeziehungen möglich. Das heißt in dem Fall, dass die Variablen sich verzögert um ein Lag beeinflussen. Die gewählten Quantile τ_1 und τ_2 können je nach dem welche Wechselbeziehung von Interesse ist gleich oder verschieden sein. Die Modellierung des Q-VAR Modells lässt sich auf eine beliebig große Anzahl an Lags und gewählten Quantilen erweitern. Zur Veranschaulichung betrachten wir wieder ein bivariates Modell $k = 2$ mit $\tau_1 = \tau_2$. Bei der Betrachtung mehrerer Quantile gleichzeitig (z.B. $\tau = (0.5, 0.9)$) können diese in der Modellierung unabhängig voneinander dargestellt und in Matrixform aufeinander gestapelt werden über

$$\begin{aligned} \begin{bmatrix} X_{t+1} \\ X_{2,t+1} \\ X_{1,t+1} \\ X_{2,t+1} \end{bmatrix} &= \begin{bmatrix} \omega_1^5 \\ \omega_2^5 \\ \omega_1^9 \\ \omega_2^9 \end{bmatrix} + \begin{bmatrix} 0 & 0 & 0 & 0 \\ a_{021}^5 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & a_{021}^9 & 0 \end{bmatrix} \begin{bmatrix} X_{1,t+1} \\ X_{2,t+1} \\ X_{1,t+1} \\ X_{2,t+1} \end{bmatrix} \\ &+ \begin{bmatrix} a_{11}^5 & a_{12}^5 & 0 & 0 \\ a_{21}^5 & a_{22}^5 & 0 & 0 \\ 0 & 0 & a_{11}^9 & a_{12}^9 \\ 0 & 0 & a_{21}^9 & a_{22}^9 \end{bmatrix} \begin{bmatrix} X_{1,t} \\ X_{2,t} \\ X_{1,t} \\ X_{2,t} \end{bmatrix} + \begin{bmatrix} \epsilon_{1,t+1}^5 \\ \epsilon_{2,t+1}^5 \\ \epsilon_{1,t+1}^9 \\ \epsilon_{2,t+1}^9 \end{bmatrix}. \end{aligned} \quad (3.9)$$

Bei der Betrachtung von p verschiedenen Quantilen erhöht sich die Dimension der Matrix auf $k \cdot p$ Regressionen im System. Zur genaueren Herleitung des Vorhersagens und der spezifischen Quantils Impulse Antwort Funktion verweisen wir auf [Chavleishvili and Manganelli, 2019]. Die Schätzung der Parameter erfolgt wie im Abschnitt 3.3 beschrieben. Durch die Schätzung des VARs auf alle möglichen Quantile lässt sich die gesamte gemeinsame Verteilungsfunktion schätzen. Dies ist besonders von Vorteil, wenn extreme Realisierungen im Modell untersucht werden sollen. Mittels IAF lassen sich Stressszenarien simulieren und Kurzzeit- wie Langzeitauswirkungen für beliebige Quantile darstellen. Ein Schock im gestressten Modell beschreibt dabei die Entwicklung des Quantils durch einen Einheitsschock in einer festgelegten Variable [Chavleishvili and Manganelli, 2019].

4. Daten

Ziel dieser Arbeit ist es den Einfluss der Banken- und der Fondsaktivität auf Immobilienpreisentwicklungen in Deutschland zu quantifizieren und Risiken abzuleiten. In diesem Kapitel werden die für die Analyse ausgewählten Daten vorgestellt und beschrieben. Hierbei werden die Herkunft der Daten, die Datenfrequenz, sowie die Verarbeitung und Aufbereitung der Daten erläutert. Es wird darauf eingegangen, welche spezifischen Anforderungen an die Daten gestellt wurden und wie diese erfüllt wurden. Zudem wird eine Übersicht über die verwendeten Variablen und deren Bedeutung gegeben. Abschließend werden erste Visualisierungen der Zeitreihen präsentiert, welche die Grundlage für die Modellierung bilden.

4.1. Datengrundlage

Zur Untersuchung des deutschen Wohnimmobilienmarktes verwendet diese Arbeit den Hauspreisindex von *National Sources, BIS Residential Property Price database*. Dieser ist auch über die Seite der Federal Reserve Economic Data (FRED) von der Federal Reserve Bank of St. Louis zugänglich (QDER628BIS) und liegt in Quartalsfrequenz vor. Der Index mit der Einheit (2010 = 100) umfasst alle Arten von Eigentümer genutzten neuen und bestehenden Wohnimmobilien in Deutschland. Die Zeitreihe wurde mit dem Consumer Price Index (CPI) deflationiert. Weiterhin werden aus *National Sources, BIS Residential Property Price database* noch weitere Hauspreisindizes herangezogen, die für Mehrfamilienimmobilien und Mietimmobilien genutzt werden und sowohl als Vergleich als auch zur Unterstützung von Robustheitschecks dienen. Die Nutzung von monatlichen Immobilienpreisen, welche aus Angebotsdaten der gängigen Immobilienportale wie ImmobilienScout24 basierten, mussten aufgrund der geringer Stichprobengröße von nur 5 Jahren

zurückgestellt und nicht weiter aufgeführt. Als Indikator für die Investmentfondsaktivität im Immobilienmarkt wurde das Fondsvermögen von offenen Immobilienfonds verwendet. Das Fondsvermögen, von Publikums und Spezialfonds, beinhaltet das gesammelte Vermögen des eingesammelten Kapitals der Anleger zur Investition in den Erwerb, den Bau oder die Finanzierung von Immobilien. Die Daten stammen aus der Investmentfondsstatistik der deutschen Bundesbank und liegen in monatlicher Frequenz in Dimension Millionen vor [Bundesbank, 0]. (BBSF2.M.1.T.00000.IMM01.I.F.NAV.Z5.00000.000000.Z01.00) Als Indikator für die Bankaktivität wurden verschiedene Indikatoren untersucht. Das Kreditvolumen deutscher Banken für inländische Unternehmen und Privatpersonen (BBK01.PQA350) und das Wohnungsbaukreditvolumen deutscher Banken für inländische Unternehmen und Privatpersonen (BBK01.PQ3151) liegen in [Bundesbank, 0] in quartalsweiser Frequenz (Dimension Millionen) vor. Weitere Bankentyp-spezifische Indikatoren (Sparkassen, Kreditbanken, Regionalbanken) wurden untersucht, jedoch für die Analysen zurückgestellt. Weiterhin wurde das Neugeschäftsvolumen der Banken an Wohnungsbaukrediten für private Haushalte (BBK01.SUD231) herangezogen. Diese Daten stehen in der Zeitreihen-Datenbank der [Bundesbank, 0] in monatlicher Frequenz mit Dimension in Millionen zur Verfügung. Der gemittelte Effektivzins der Kredite an Privatpersonen (BBK01.SUD131Z) ist auch auf der MFI-Zinsstatistik der deutschen Bundesbank [Bundesbank, 0] in monatlicher Frequenz verfügbar. All die eben aufgelisteten Zeitreihen bilden die Grundlage der Analyse. Zusätzlich wurde aus der Datenbank [Nomics,] weitere Indikatorvariablen der Bank für die Quantilsregressions-Analysen ausgewählt. Dazu zählt das Verhältnis der Zinszahlungen privater Haushalte zu Einkommen ZINS:EINKOMMEN, das Verhältnis des Wohnimmobilienpreis zur Miete PRICE/RENT (BUBA/BBDY1/Q.B10.N.G200.P0420.A), das Verhältnis des Wohnbaukreditvolumens zum BIP (BUBA-BBDY1-Q.B20.N.G400.F0210.A), Änderungen in den Kreditstandards und den Margen der Bank für Wohnbaukredite (BUBA/BBDY1/Q.B20.N.G500.F0600.A), das prozentuale Verhältnis zwischen Zinszahlungen für Wohnbaukredite als Anteil des verfügbaren Einkommens (BUBA-BBDY1-Q.B20.N.G550.F0800.A) und das Wohnbaukreditvolumen an einheimische private Haushalte (BUBA-BBDY1-Q.B20.Y.G350.F0020.A). Für zusätzliche

4. Daten

Einflussfaktoren des Marktes untersuchte diese Arbeit das deutsche BIP und kurzfristige Zinssätze (Euribor) und die Anzahl an Bauaufträgen. Die Daten stehen in der Datenbank [Bundesbank, 0] und werden kostenfrei zur Verfügung gestellt. Diese Zeitreihen liegen alle in quartalsweiser Frequenz vor. Alle Zeitreihen werden vom 1. Quartal 2003 bis zum 2. Quartal 2022 berücksichtigt. Dieser Zeitrahmen bedingt an die Datenverfügbarkeit der Zeitreihen. Die Zeitreihen der Bundesbankstatistik erheben aggregierte Volumenbestände in Euro zum Stand der Bücher am jeweiligen Monats- bzw. Quartalsultimo. Alle verwendeten Zeitreihen sind frei verfügbar und werden regelmäßig aktualisiert.

4.2. Datenvorverarbeitung

Zur erfolgreichen Anwendung der Daten auf die kürzlich vorgestellten Modelle bedarf es mehrere notwendige Vorverarbeitungsschritte. Aufgrund der unterschiedlichen Frequenz der Daten werden zunächst die Zeitreihen allesamt auf die Frequenz der abhängigen Variable (der Immobilienpreisindex) umgewandelt. Somit werden die unabhängigen Variablen mit monatlicher Frequenz durch Durchschnittsbildung zur quartalsweisen Frequenz aggregiert. Aufgrund des exponentiellen Verlaufs in den Zeitreihen, welche Volumina oder Preis bzw. Indexentwicklungen einschließen, werden diese Zeitreihen durch Logarithmieren linearisiert. Das Logarithmieren dient zur Linearisierung des exponentiellen Wachstum, zur Stabilisierung der Varianz und zur gleichen Skalierung der Daten. Der nächste Vorverarbeitungsschritt widmet sich dem Umgang mit Trends in den Zeitreihen und erweist sich als entscheidend für die Modellergebnisse und ihrer Güte, da sie die Gefahr von sogenannten Scheinregressionen unterbindet [Wooldridge, 2009, S.366]. Zur Bereinigung des deterministischen Trends bieten sich hierbei zwei Möglichkeiten an: das Auffangen des Trends mit einer Trendkomponente in dem jeweiligen Regressionsmodell oder das individuelle Entfernen des Trends in den jeweiligen Zeitreihen. Im letzten Fall kann der Trend entweder durch individuelle Regression auf die Zeit oder durch Differenzieren der Zeitreihen bereinigt werden. Es ist hervorzuheben, dass unabhängige Variablen die allesamt einen linearen Trend aufweisen stark voneinander abhängig sein können. Die dabei entstehende

Multikollinearität äußert sich durch einen hohen Variance Inflation Factor (VIF) [Wooldridge, 2009, S.98]. Die Trendbereinigung ist somit auch entscheidend für die Reduzierung der VIFs und damit auch für die Anwendungen in den Regressionsmodellen. Beim Auftreten von stochastischen Trends kann die Bereinigung ausschließlich durch Differenzenbildung ausgeführt werden, was eine Reduzierung des Datensatzes um einen Datenpunkt zur Folge hat. Da dieser Schritt erstmals spezifische Zeitreihenanalysen bedarf und sich der Umgang von Zeittrends in Abhängigkeit des Untersuchungskontextes von Modell zu Modell unterscheidet, wird diese Herangehensweise erst im Kapitel 5 beschrieben und diskutiert. Abschließend werden alle Zeitreihen standardisiert, um die unterschiedlich verteilten Zeitreihen miteinander vergleichen zu können. Dieser Schritt ist entscheidend um die Vergleichbarkeit des Einflusses der unabhängigen Variablen des Bank- und des Kapitalmarktes auf die Immobilienpreiszeitreihe zu gewährleisten. Die Ab-

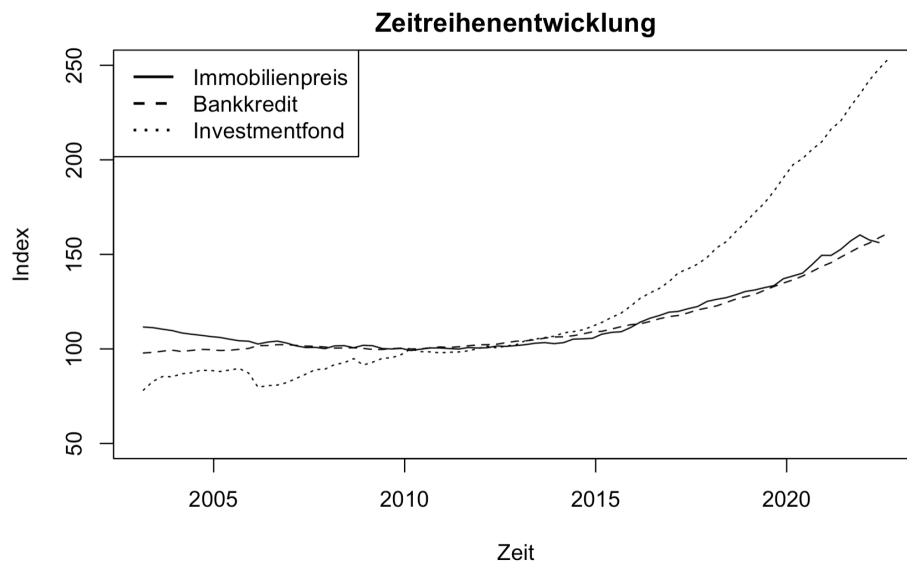


Abbildung 4.1.: Indizierte Zeitreihen des Immobilien-, Bank- und Kapitalmarktes

Abbildung 4.1 visualisiert die Zeitreihen des Bankkreditvolumens für Unternehmen und Privatpersonen, das Fondvermögen von offenen Immobilienfonds und den Immobilienpreis indiziert auf die Basis 2010. Die Zeitreihe lässt sich in drei Phasen unterteilen:

4. Daten

1. (2003-2010): stabile, leicht schwankende Immobilienpreise, niedriges Fondsvermögen und leicht abfallende Bankkreditvolumen
2. (2010-2014): zunächst stabile, dann leicht steigende Tendenz aller Zeitreihen
3. (2014-2022): stark steigende Zeitreihen insbesondere Fondsvermögen in Relation zu Immobilienpreisen und Bankkreditvolumen

Das Fondsvermögen von Immobilienfonds ist von 2010 zu 2022 zu 150% gestiegen während Immobilienpreise und das Wohnbaukreditvolumen im gleichen Zeitraum zu 60% steigt. Der extreme Anstieg in Immobilienfonds lässt die Vermutung zu, dass besonders die Immobilienpreise durch die Aktivität der Investmentfonds gestiegen ist.

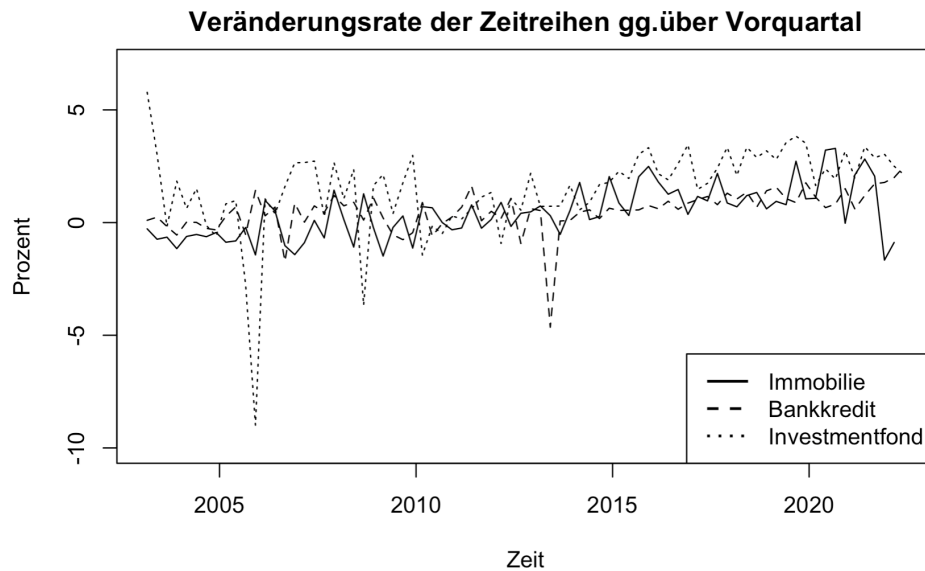



Abbildung 4.2.: Veränderungsrate der Zeitreihen des Immobilien-, Bank- und Kapitalmarktes


5. Ergebnisse und Diskussion

Zeitreihenanalysen Zur Analyse der zeitlichen Strukturen des Wohnimmobilienpreisindex IP wurde die Zeitreihe mithilfe von ACF und PACF Diagrammen auf Autokorrelationen untersucht. Das ACF Diagramm weist auf starke und abklingende Korrelationen zwischen den Lags und daher auf einen zeitlichen Trend hin. Der PACF Plot bricht nach einem Lag ab und zeigt eine Modellierbarkeit der Zeitreihe über ein AR(1) Modell.

Zur genauen Untersuchung von zeitlichen Strukturen wurde die Zeitreihe differenziert und Renditen gebildet auf denen Autokorrelationen untersucht wurden. Der ACF Plot klingt ab und der PACF Plot bricht ab. Die Renditen lassen sich durch ein AR(1) oder AR(3) Modell beschreiben. Zudem waren keine saisonalen Effekte zu erkennen.



(a) ACF Diagramm



(b) PACF Diagramm

Abbildung 5.1.: Autokorrelationen der Wohnimmobilienpreise

5. Ergebnisse und Diskussion




Abbildung 5.2.: Autokorrelation der Renditen

5.1. Finanzierungseinflüsse auf Immobilienpreisentwicklungen

5.1.1. Ergebnisse der Multiplen Linearen Regression

Investmentfonds vs. Neugeschäft von Wohnbaukrediten für Privatpersonen Mit dem Ziel den Finanzierungseinfluss der Banken und Fonds auf den Wohnimmobilienpreis zu quantifizieren, wurde zunächst eine multiple lineare Regression durchgeführt. Als abhängige Variable wurde der Wohnimmobilienpreisindex (IP) und als unabhängige Variablen der Zeittrend (ZEIT), das Fondsvermögen von offenen Immobilienfonds (OIF) und das Wohnbaukreditvolumen im Neugeschäft für Privatpersonen (WBK.P) ausgewählt. Da der lineare Trend der abhängigen Variable mit den erklärenden Variablen korrelierte, wurde nach der Empfehlung von [Wooldridge, 2009, S. 366] die Variable *Zeit* in das Modell aufgenommen und somit der Einfluss des linearen Trends miteinbezogen. Folglich bestand damit keine Gefahr mehr für Scheinregressionen, weder vonseiten OIF noch vonseiten WBK.P. Obwohl laut [Wooldridge, 2009, S. 366] im Umkehrschluss das Detrenden der anderen Variablen nicht mehr notwendig ist, wurde aufgrund des hohen VIFs sowohl OIF als auch WBK.P um den zeitlichen Trend bereinigt um damit einen VIF unter fünf zu gewährleisten der die Gefahr von Multikollinearität ausschließt.

5.1. Finanzierungseinflüsse auf Immobilienpreisentwicklungen

Die Regressionsgleichung lautet

$$\hat{IP}_t = -0.03 + 0.59 OIF_{t-1} + 0.045 WBK.p.t_{t-1} + 0.15 t \quad \text{Adj.}R^2 = 0.95$$

(0.177)
(0.042)
(0.019)
(0.008)

und zeigt signifikante Koeffizientenschätzer mit Varianzaufklärung der abhängigen Variable bei 95.9%.

Zur Bestimmung des Einflusses auf die Erklärbarkeit von IP wurden univariate trendbereinigte Modelle herangezogen [Wooldridge, 2009, S. 369] und in 5.1 durch das Modell (2) und (3) ausgedrückt.

Der zeitliche Trend leistet einen Beitrag von 59.8%, die Immobilienfonds von

Tabelle 5.1.: Multiple Lineare Regression: Einflussstärke des Fonds- und Bankkreditvolumens auf Wohnimmobilienpreise

<i>Abhängige Variable:</i>				
Immobilienpreis				
	(1)	(2)	(3)	(4)
OIF	0.592*** (0.020)	0.526*** (0.117) (0.117)		
WBK	0.045* (0.024)		0.307** (0.120)	
Zeit	0.151*** (0.005)			0.137*** (0.015)
Observations	77	77	77	78
Adjusted R ²	0.959	0.242	0.074	0.598
RSE	0.203 (df=73)	0.876 (df=75)	0.968 (df=75)	0.634 (df=76)

*p<0.1; **p<0.05; ***p<0.01

Anmerkung: HAC Standardfehler in Klammern, standardisierte Variablen auf dem logarithmierten Level und mit bereinigtem linearen Trend

25.3% und das Kreditvolumen von 7.4%. Die p-Werte und das Verhältnis zwischen Koeffizientenschätzer und Standardfehler sind alle signifikant und damit auch Koeffizientenschätzer. Es wird ersichtlich, dass Immobilienfonds und Wohnbaukredite einen positiven Einfluss auf Immobilienpreise haben. Der Einfluss der

5. Ergebnisse und Diskussion

Immobilienfonds mit 0.59 zeigt sich im Vergleich zu Wohnbaukredite mit 0.04 als wesentlich stärker.

5.2. Wechselbeziehung zwischen Banken, Fonds und Immobilienpreisen

Um der Leitfrage „*Heute bewegt sich das Finanzierungsvolumen der Bank bzw. des Immobilienfonds um eine Standardabweichung nach oben bzw. unten, welche Konsequenz hat dies für Immobilienpreise insbesondere Immobilienrenditen?*“ nachzugehen, wurde das VAR Modell angewendet. Das VAR Modell wird zum einen genutzt, um Preisentwicklungen zu erklären und zum anderen, um Stressszenarien zu untersuchen. Durch die Beobachtung von kurzen Zeitabständen ließen sich zum Beispiel Rückschlüsse auf langfristige Entwicklung für die nächsten Jahre erkennen, bei einem Impuls in einer Variable. Als Werkzeug wurde hierbei die IAF aus dem Unterkapitel 3.4.5 herangezogen, welches es ermöglicht die Auswirkung bzw. Antwort dieses Impulses, oft auch als Schock bezeichnet, einer festgelegten Variable über die Zeit auf andere endogene Variablen im System zu verfolgen und zu quantifizieren. Das VAR Modell bietet für jede endogene Variable ein regressives Modell, das im folgenden nacheinander genauer beschrieben wird.

5.2.1. Ergebnisse des VAR Modells

Dadurch ließen sich Wechselwirkungen zwischen den Finanzierungsmärkten mit dem Immobilienmarkt messen und deuten. Hierzu wurde aus jedem Markt ein Indikator entnommen und in den Vektor aller endogener Variablen für das VAR Modell eingesetzt. Als Variable für den Bankmarkt diente das Wohnbaukreditvolumen für Privatpersonen in Deutschlands (WBK.P). Auch wurden andere Indikatoren untersucht wie zum Beispiel das Wohnbaukreditvolumen aller Banken für Privatpersonen, Wohnbaukreditvolumen aller Banken für Unternehmen, das Neugeschäft der Wohnbaukreditvolumen aller Banken für Privatpersonen, das Gesamtkreditvolumen aller Banken für Unternehmen und Privatpersonen und die jeweiligen standardisierten Formen, daher deren Verhältnis zum Bruttoinlands-

5.2. Wechselbeziehung zwischen Banken, Fonds und Immobilienpreisen

produkt (BIP). Auch wurden die Kreditvolumen von Regionalbanken, Kreditbanken, Großbanken und weiteren Banken analysiert, jedoch auf Grund von hoher Korrelation zu anderen Variablen und instabilen Ergebnissen von dem Modell ausgeschlossen. Als Indikator für die Investmentfonds wurde das logarithmierte Fondsvermögen von offenen Immobilienfonds (OIF) verwendet. Auch hier wurden verschiedene Indikatoren ausprobiert, wie das Fondsvermögen von geschlossenen Immobilienfonds, das Gesamtvermögen von REITs, der Mittelzufluss von offenen Immobilienfonds oder das Gesamtvolumen von Investmentfonds in Europa. Da deren Datenverfügbarkeit aber noch begrenzter war, wurden diese Daten für die Modellierung ausgeschlossen. Für die Immobilienpreisentwicklung in Deutschland wurde der deflationäre Index für Wohnimmobilienpreise in Deutschland (IP) angewendet.

Ergebnisse des VAR Modells Zur Nutzung des VAR Modells wurden zunächst alle Zeitreihen im System mit Hilfe des ADF-Tests auf Stationarität bzw. auf Trends überprüft. Mit einem p-Wert größer als 0.05 belegten alle Ergebnisse einen statistisch signifikanten zeitlichen Trend in allen Zeitreihen, der das Differenzieren der Zeitreihen begründet. Siehe auch Abbildung 5.2 Nach Differenzieren

Tabelle 5.2.: ADF-Test auf dem Level der Zeitreihen

	Zeitreihe	Statistik	p-Wert	Diff.stationär
1	IP	-1.31	0.86	0
2	OIF	-0.88	0.95	0
3	WBK.p	-2.41	0.40	0

aller Variablen zeigte sich kein Trend mehr in den Variablen und die Nullhypothese, dass Einheitswurzeln in der der Zeitreihe enthalten sind, wird verworfen. Siehe auch Abbildung 5.3. Die stationären Zeitreihen bildeten dann den Zeitreihenvektor

$$\Delta \mathbf{X}_t = [R_t, \Delta WBK.p_t, \Delta OIF_t].$$

Zur Bestimmung des VAR(p) Modells mittels AIC Kriterium zeigte sich (unter maximaler Betrachtung von 8 Perioden in die Vergangenheit) das Modell bei $p = 1$ mit dem kleinsten AIC Wert. Daher wurde das VAR(1)Modell gebildet, welches

5. Ergebnisse und Diskussion

Tabelle 5.3.: ADF-Test auf den differenzierten Zeitreihen

	Zeitreihe	Statistik	p-Wert	Diff.stationär
1	R	-4.16	0.01	1
2	Δ OIF	-4.09	0.01	1
3	Δ WBK.p	-5.228	0.01	1

bis zu einem Lag in die Vergangenheit betrachtet. Dabei wurde das Modell auf signifikante Einflussvariablen eingeschränkt und demnach ein restriktives VAR Modell erzeugt. Um mögliche Autokorrelationen in den Residuen zu erkennen, wurde mit Hilfe des Portemonteau Test die Modellannahmen auf unabhängigen Residuen getestet. Dieser Schritt der Modelldiagnostik ist essenziell, um die Validität des Modells zu testen. Sind noch Autokorrelationen in den Residuen enthalten, so müssen in der Modellierung noch weitere Lags berücksichtigt werden. Der Test ergab einen p-Wert von 0.09 und damit kann die Nullhypothese nicht verworfen werden, dass die Residuen nicht autokorreliert sind. Auch die ACF und PACF Plots der Residuen wiesen keine signifikanten Lags mehr auf. Damit sind alle Modellannahmen erfüllt.

Die Schätzung des VAR Modells ist durch folgende Modellgleichungen definiert:

$$R_t = \underset{(0.11)}{0.25} R_{t-1} + \underset{(0.011)}{0.029} \Delta WBK.p_{t-1} + \underset{(0.01)}{0.05} \Delta OIF_{t-1} \quad \text{Adj.}R^2 = 0.38$$

$$\Delta WBK.p_t = \underset{(0.09)}{0.63} \Delta WBK.p_{t-1} \quad \text{Adj.}R^2 = 0.39$$

$$\Delta OIF_t = \underset{(0.005)}{0.01} + \underset{(0.42)}{1.42} R_{t-1} + \underset{(0.09)}{0.57} \Delta OIF_{t-1} \quad \text{Adj.}R^2 = 0.72$$

Die Immobilienrenditen bedingen sowohl auf vergangenen Immobilienrenditen als auch vergangenen Änderungsraten von Wohnbaukredit- und Immobilienfonds-Volumen. Insgesamt konnte durch das Modell 38% der Varianz in den Renditen erklärt werden. Ebenfalls wird deutlich, dass der direkte Einfluss der Immobilienfonds mit 0.05 stärker ist als die Kredite mit 0.029. Die Wohnbaukredit-Volumenveränderung wird dabei von vergangenen Veränderungen im Volumen

5.2. Wechselbeziehung zwischen Banken, Fonds und Immobilienpreisen




Abbildung 5.3.: Antwort der Wohnimmobilienpreise auf einen Einheitschock der Bankkredite bzw. des Fondsvolumen

getrieben (darstellbar durch ein AR(1) Modell). Die Änderung des Fondsvolumens lässt sich durch vergangene Renditen erklären. Hier wird der „Renditeappetit“ der Fondsanleger deutlich, die darauf spekulieren, bei steigenden Immobilienpreisen Profite zu erzielen. Die Varianzaufklärung lag hierbei insgesamt bei knapp 72%.

Die Impuls-Antwort Reaktion ist in Abbildung 5.3 dargestellt und zeigt, dass eine Veränderung im Fondsvolumen der Immobilienfonds die Immobilienrenditen signifikant erhöht. Dieser Einfluss zeigt sich innerhalb von einem Quartal und klingt nach fünf Quartalen ab.

Weiterhin wird demonstriert wie sich ein Schock in der Veränderung in Wohnbaukreditvolumen für Privatpersonen signifikant positiv auf Immobilienrenditen auswirkt. Dabei scheint die Wirkung des Schocks der Bank zunächst stärker als derer der Fonds zu sein. Das 90% Konfidenzband in 5.3 (rot gestichelte Linien) verdeutlicht mit seiner Breite eine große Unsicherheit in Bezug auf des genauen Einflusses. Bei Überprüfung der Ergebnisse mit anderen Hauspreisindizes wird deutlich, dass die Modelle unterschiedliche Resultate zeigen und teilweise eine höhere Lag-Anzahl als das optimale Modell wählen. In den Modellen werden sowohl Einflüsse von Banken als auch von Investmentfonds eingebunden. Letztlich sind weder alle Modellannahmen erfüllt noch die Impulse Antwort Funktionen signifikant und daher auch nicht weiter aufgeführt. Die Ergebnisse hierzu findet man im Anhang unter weitere VAR Modelle.

5.3. Untersuchung von Risikofaktoren, Übertragungseffekten und Stress-Szenarien

In diesem Abschnitt wird der Einfluss von Bank- und Investmentfonds auf verschiedene Quantile von Immobilienpreisschwankungen untersucht und anschließend werden Risikofaktoren abgeleitet. Hierbei wurde der logarithmierte Wohnimmobilienpreisindex um ein Lag differenziert und somit zu Renditen umgewandelt, die die prozentualen Preisschwankungen von Quartal zu Quartal darstellen. Die Renditeverteilung beschreibt daher das Risiko von Immobilienpreisschwankungen.

5.3.1. Ergebnisse der univariaten Quantilsregressionsmodelle

Als Voruntersuchung wurden verschiedene Einflussfaktoren in einem univariaten Quantilsregressionsmodell modelliert, um deren Auswirkung auf die Immobilienpreisentwicklung sowohl in Boom- als auch in Krisenzeiten zu untersuchen. Dabei wurde die Modellierung in Abhängigkeit der Datenverfügbarkeit jeweils von 2003-2022 oder von 2010-2022 (mit ' markiert) durchgeführt. Die Modellierungen zeigten, dass die Einflüsse entlang der Quantile variieren und es unterschiedliche Wirkungen auf Immobilienrenditen gibt. Dies gilt sowohl für das Verlustrisiko (VaR) in Krisenzeiten als auch auf die Chancen während eines Booms und motivierte die folgenden multiplen Quantilsregressionsanalysen.

5.3. Untersuchung von Risikofaktoren, Übertragungseffekten und Stress-Szenarien

Tabelle 5.4.: Univariate Quantilsregression auf Wohnimmobilienrenditen

<i>Abhängige Variable: Wohnimmobilienrenditen</i>			
	Quantile		
<i>Einflussvariablen</i>	(0.1)	(0.5)	(0.9)
Bankkreditzins	−0.005**	−0.005**	−0.005**
Zinszahlung/Einkommen	−0.008**	−0.0098**	−0.008
Wohnbaukredit.Privat	0.02**	0.03**	0.02**
Wohnbaukredit.Gesamt	0.07**	0.07**	0.05**
Immobilienfonds	0.0087	0.01685***	−0.0168**
Kreditstandards	−0.00102	−0.00102	0.003*
Preis/Miete	0.03	0.11**	0.08*
Geschlossene Immobilienfonds'	−0.0035	0.0191*	0.012
REITS'	0.00675*	0.01256**	0.02017**

*p<0.1; **p<0.05; ***p<0.01

5.3.2. Ergebnisse der multiplen Quantilsregressionsmodelle

Zur Gegenüberstellung der Intensität der Risiken vonseiten der Banken und der Fonds wurde ein multiples Quantilregressionsmodell auf Wohnimmobilienrenditen (R) angewendet und entlang der Quantile untersucht. Als unabhängige Variablen wurden hierbei Bankkredite durch das Volumen für Wohnbaukredite an Privatpersonen ($WBK.P$) und Immobilienfonds durch das Fondsvermögen für offene Immobilienfonds (OIF) ausgedrückt und zudem der Zeittrend $ZEIT$ und die Konstante (engl. Intercept) geschätzt.

Die Abbildung 5.4 zeigt die Koeffizientenschätzer der unabhängigen Variablen für die Quantilsregression von Immobilienrenditen und vergleicht die Schätzung mittels QR in blau mit der linearen Regression in rot. Während bei der linearen Regression per Definition die Schätzung für alle Quantile gleich ist, wird bei der QR für jedes Quantil der Immobilien-Preisrenditen der Einfluss der unabhängigen Variablen geschätzt. Die blauen Punkte verdeutlichen die Parameterschätzer für das 5% bis zum 95% Quantil. Das 95% Konfidenzband für die QR-Schätzung ist in hellblau hinterlegt, während das Konfidenzband der linearen Regression mit rot-gestrichelten Linien dargestellt wird.

Hierbei ist ein asymmetrisches Verhalten der Schätzungen in allen Variablen zu erkennen, welcher zur monotonen Eigenschaft von Quantilen passt. Sowohl Immobilienfonds als auch Bankkredite zeigten in Krisenzeiten einen verstärkenden Einfluss, da eine Erhöhung der Finanzierung um eine Einheit zu erhöhtem VaR führt. In Boomzeiten verstärkten beide die Renditen, jedoch wird deutlich, dass Immobilienfonds stärker dazu beitragen. Da jedoch das Konfidenzband sehr breit ist, ist es schwer, sichere Aussagen abzuleiten. Dennoch wird in ?? eindeutig erkenntlich, dass die QR sinnvoll ist um entlang der Quantile Einflussfaktoren auf das Risiko zu analysieren und betont sowohl die asymmetrische Wirkungsbeziehungen der Banken und Fonds auf Immobilienrenditen. Die QR wurden deshalb um die Betrachtung von weiteren bank- und fondsbasierten Risikofaktoren erweitert. Dabei wurden die Quantile $\tau = \{0.05, 0.1, 0.25, 0.5, 0.75, 0.9, 0.95\}$ der Renditeverteilungsfunktion mittels QR genauer auf Risikofaktoren untersucht. Die Untersuchung von extremen Quantilen wie $\tau = 0.01$ und $\tau = 0.99$ konnte

5.3. Untersuchung von Risikofaktoren, Übertragungseffekten und Stress-Szenarien

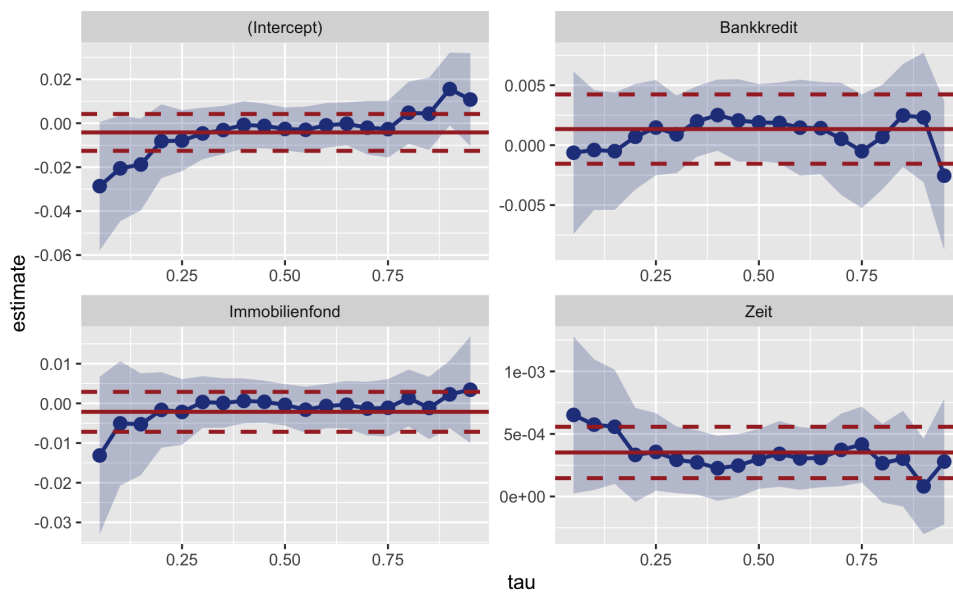


Abbildung 5.4.: Koeffizientenschätzer für die Quantilsregression von Immobilienrenditen

wegen der niedrigen Stichprobenzahl mit $T = 77$ rechnerisch nicht ausgeführt werden. Daher wurde für das Verlustrisiko bzw. für die Chance jeweils die äußeren zwei gewählten Quantile des Quantilsvektors verwendet. Die Modellierung des QR-Modells

$$R_t = \mathbf{X}_t \beta^T + \varepsilon_t$$

wurde mit den Einflussfaktoren

$$X_t = [\text{KREDITZINS}, \text{FOND}, \text{BANK}, \text{ZINS:EINKOMMEN}, \text{BIP}, \text{EURIBOR}, \text{BAU}]$$

durchgeführt. Zur robusten Schätzung werden HAC Standardfehler¹genutzt, die im Fall von autokorrelierten Fehlertermen inflationäre T-Statistiken in den Ergebnissen aufdecken. Autokorrelierte Fehlerterme entstehen dann, wenn signifikante Einflüsse auf den Renditen nicht durch das Modell beschrieben wurde und damit in den Residuen auftreten. Die nicht aufgefangenen Informationen in den Residu-

¹Mit Hilfe des R-Pakets von Koenker *quantreg* lassen sich die Fehlerterme mit der Einstellung 'nid' zu HAC Standardfehlern korrigieren und auf die Ergebnisse übertragen [Koenker, 2022]

5. Ergebnisse und Diskussion

en können dann zu autokorrelierten Residuen führen, die dann korrigiert werden müssen. Zum Vergleich wurden auch Standardfehler mit Hilfe von Bootstrap² gebildet und die signifikanten Risikofaktoren verglichen. Zusätzlich zu den Bank- und Investmentfondsvariablen, welche deren Volumen und Zinsen einschließen, wurde noch der BIP als Indikator für Konsum, ein Index für den Wohnungsbau in Wohnimmobilien als Angebotsvariable und das Verhältnis von Kreditzinszahlungen zum Einkommen gewählt. In der QR-Analyse wurde dabei zunächst eine univariate Voranalyse auf dem logarithmierten Level der Variablen durchgeführt. Da wirtschaftliche Zeitreihen eine gemeinsame, zugrundeliegende und wachsende bzw. fallende Tendenz über die Zeit haben, sind diese hochkorreliert. Sie teilen einen zeitlichen Trend, der sich vor allem durch hohe VIFs bemerkbar machte. Dies führte zu inkonsistenten, aufgeblasenen und schein-signifikanten Koeffizientenschätzern, die eine konsistente und durchführbare Modellierung im multivariaten Fall nicht ermöglichte. Als Lösungsansatz wurde daher ein zeitlicher Trend als Einflussvariable hinzugefügt. Dabei wurde zunächst in der Modellierung noch eine Trendvariable mitaufgenommen, anstatt den linearen Trend der Einflussvariablen einzeln zu eliminieren. Besonders die Variablen des Bankkredit- und des Investmentfondsvolumen zeigten hohe Korrelationen von über 0.80 auf. Diese konnte entweder mittels Detrenden auf 0.45 oder mittels Differenzieren der Variablen auf 0.04 reduziert werden. Daher wurde die finale Modellierung durch das Differenzieren der Einflussvariablen durchgeführt, was dazu führte, dass alle VIFs der Variablen ca. einen Wert von 1 – 2 hatten. Hierdurch wurden die Voraussetzung für die Modellierung erfüllt, um multivariate Regressionsmodelle umzusetzen. Die Risikofaktoren beschreiben folglich eine prozentuale Veränderung des jeweiligen Risikofaktors auf die Renditen. Die Ergebnisse sind in Tabelle 5.5 aufgelistet.

Risikofaktoren auf Immobilienpreisrenditen Kreditzinsen der Banken haben über alle Quantile hinweg einen signifikanten negativen Einfluss. Bei einer Veränderung der Kreditzinsen um 1% verstärkt sich in Krisenzeiten das Verlustrisiko und reduzieren sich in Boomzeiten die Gewinnchancen. Im Median scheint

²Mit Hilfe des R-Pakets von Koenker *quantreg* lassen sich die Fehlerterme mit der Einstellung 'boot' zu Standardfehlern nach dem Bootstrap-Verfahren korrigieren [Koenker, 2022]

5.3. Untersuchung von Risikofaktoren, Übertragungseffekten und Stress-Szenarien

Tabelle 5.5.: Quantilsregression: Risikofaktoren auf Wohnimmobilienrenditen

	tau= 0.10	tau= 0.25	tau= 0.50	tau= 0.75	tau= 0.90
(Intercept)	-0.013***	-0.013**	-0.008	-0.0002**	0.010**
Kreditzins	-0.026**	-0.020*	-0.013	-0.024*	-0.014
Fond	0.139**	0.182**	0.206**	-0.033	0.018
Bank.PU	0.266	0.162	0.346	0.779***	0.877**
Zins:Einkommen	-0.061	-0.334*	-0.231**	-0.309	-0.109
BIP	-0.476	-0.116	0.166	-0.016	-0.088
Euribor	0.017*	0.010	0.004	0.011	0.016
Bau	0.050*	0.051*	0.023	0.014	-0.006

Anmerkung: * $p < 0.1$; ** $p < 0.05$; *** $p < 0.01$, differenzierte und logarithmierte Einflussfaktoren auf Hauspreisrenditen unter Nutzung von HAC Standardfehlern mit Zeithorizont 2003-2022

es jedoch keinen signifikanten Einfluss zu haben. Das Bankkreditvolumen hat in Krisenzeiten einen stabilisierenden Einfluss auf das Risiko, während es in Boomzeiten einen verstärkenden Einfluss auf die Gewinnchancen hat. Eine positive Veränderung im Gesamtkreditvolumen hat über alle Quantile hinweg einen positiven Einfluss und verdeutlicht die gestiegene Nachfrage in Immobilieninvestitionen von Seiten der Privatpersonen und Unternehmen.

Das Vermögen von offenen Immobilienfonds zeigt bis auf dem 0.75 Quantil ebenfalls einen positiven Einfluss auf die Immobilienrenditen, der aber wesentlich geringer ausfällt als der der Banken. Das Verhältnis zwischen Zinszahlungen von Privatpersonen zum Einkommen zeigt durchweg einen negativen Einfluss auf die Renditen. Die Ergebnisse des Bruttoinlandprodukts (BIP) sind nicht signifikant und weisen daher keine ableitbaren Erkenntnisse auf. Sie sollten jedoch intuitiv keinen negativen Einfluss auf Immobilienrenditen haben. Schließlich zeigen sich Bauinvestitionen im Wohnimmobilienbereich in Krisenzeiten als ein stabilisierender Einflussfaktor auf das Verlustrisiko. Kurzfristige Zinsen als Proxy für Investmentfondszinsen (EURIBOR) scheinen einen positiven jedoch nicht signifikanten Einfluss zu haben. Der Zins für Bankkredite hat einen negativen Effekt auf die Immobilienentwicklung. Steigt der Zins, so sinken die Immobilienpreise. Dies be-

5. Ergebnisse und Diskussion

einflusst den VaR als auch die Immobilienpreisentwicklung im Allgemeinen. Steigende Bankkreditvolumen haben über alle betrachteten Quantile hinweg einen positiven Einfluss auf die Immobilienentwicklung: In Krisenzeiten mildern sie den VaR und in Boomzeiten verstärken sie dessen Auftrieb. Die Variable (VERÄNDERUNG DER KREDITSTANDARDS) beschreibt das Verhältnis zwischen risikoreichen und konservativen Kreditvergaben, die sich aus der Berichterstattung der Banken ergeben und Aufschluss über die Strenge der Kreditstandards geben. Dabei wurden die Anteile von Salden von verschärften, verengten und gelockerten Kreditmargen laut Befragungen abgewogen. Bei positivem Verlauf sind die Margen breiter und die Kreditstandards strenger, so dass höhere Kreditrisiken toleriert werden. Bei negativem Verlauf ist die Kreditvergabe gelockert und die Margen eines durchschnittlichen und eines risikobereiten Wohnkredits enger. Die Erhöhung der Variable um eine Einheit führt daher zu strengeren Kreditbedingungen und hat einen leicht positiven Effekt in Boomzeiten. Dies könnte darauf hindeuten, dass verschärfte Kreditstandards das Immobilienpreiswachstum nicht aufhalten und eher von risikobereiteren Wohnkreditnehmern genutzt werden. Das Verhältnis von Bankzinszahlungen zum Einkommen für Privatpersonen hat einen negativen Einfluss was bedeutet, dass durch ein geringeres Verhältnis von Zinszahlungen im Vergleich zum Lohn die Immobilienpreise steigen. Dies lässt sich auch so interpretieren, dass Kreditstandards einen starken Einfluss haben und gekoppelt mit dem Einkommen zu der Entwicklung von Immobilienpreisen beitragen. Der Anteil von Wohnbaukrediten im Verhältnis zum GDP hat in Krisenzeiten einen verstärkenden und in Boomzeiten einen leicht positiven Einfluss auf den VaR. Mit Hilfe der QR wird ersichtlich, dass Einflüsse auf Immobilienrenditen stark entlang der Quantile variieren. Während in Krisenzeiten eher Investmentfondvariablen einen signifikanten Einfluss auf das Risiko haben, scheinen Bankvariablen besonders in Boomzeiten signifikante Wirkungen zu zeigen.

5.3.3. Ergebnisse der Q-VAR Modelle zur Untersuchung dynamischer Risikoübertragungen

Weiterhin wurden in dieser Arbeit Stress-Szenarien simuliert, um mögliche Langzeitrisiken aus beiden Variablen (Bankkredit- und Fondsvermögen) zu untersu-

5.3. Untersuchung von Risikofaktoren, Übertragungseffekten und Stress-Szenarien

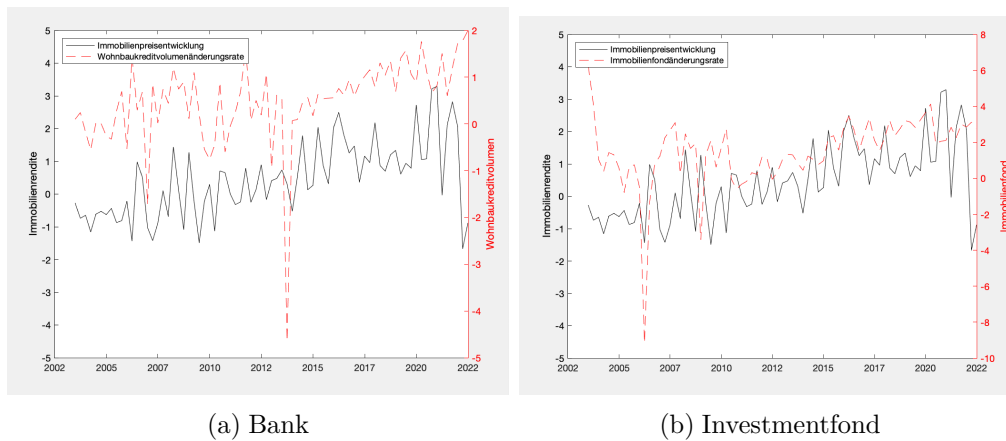


Abbildung 5.5.: Zeitreihenentwicklung im Vergleich

chen. Hierzu wurde das Q-VAR(1) Modell nach [Chavleishvili and Manganelli, 2019] verwendet, welche es ermöglicht den Einfluss bzw. die Übertragung von Marktschocks auf verschiedene Quantile von Immobilienrenditen zu quantifizieren. Als unabhängige Variable wurde hier das Fondvermögen offener Immobilienfonds (OIF) und für Wohnbaukreditvolumen für Privatpersonen verwendet. Zur Bereinigung des zeitlichen Trends wurden beide Variablen jeweils mit Grad eins differenziert. Weiter wurden zwei bivariate Q-VAR(1) Modelle angepasst, deren Quantilplots für die Parameterschätzungen mitsamt deren Interpretationen im Anhang wiedergegeben sind. Abbildung 5.6 verdeutlicht die asymmetrische Wirkung von Immobilienfonds auf Immobilienrenditen. Bei der Simulierung von verschiedenen Quantilschocks reagieren Immobilienrenditen unterschiedlich. Besonders auffällig ist die negative Entwicklung bei einem 80%-Quantilschock, was sich so interpretieren lässt, dass Immobilienfonds die Volatilität von Immobilienrenditen und damit die Volatilität der Immobilienpreise verstärken, und wiederum für mehr Unsicherheit im Immobilienmarkt sorgt. Bankkreditentwicklungen scheinen hingegen einen dämpfenden Einfluss auf Immobilienrenditen zu haben und in bieten in Krisenzeiten einen stabilisierenden Effekt.

Aus dem Q-VAR Modell lässt sich zudem ableiten, dass Immobilienfonds einen alternierenden Einfluss auf Immobilienrenditen haben, die sich gegenseitig aus-

5. Ergebnisse und Diskussion

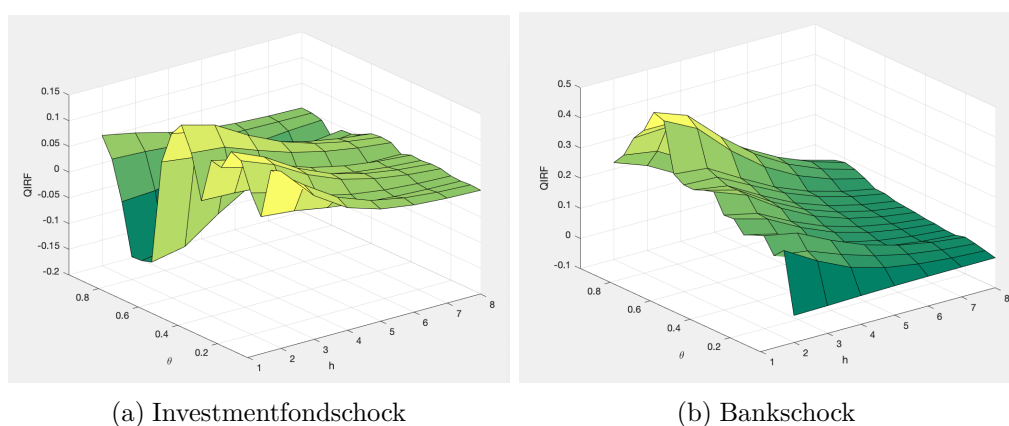


Abbildung 5.6.: Impulse Antwort auf verschiedene Quantile von Immobilienrenditen

gleichem. Einige VAR Modelle mit einem dynamischen Zeitraum von bis zu 4 Jahren bestärken diese Vermutung. Da diese Modelle jedoch den diagnostischen Test nicht bestanden haben und weiterhin Korrelationen in den Residuen aufweisen, wurden sie nicht weiter für Inferenzen herangezogen. Die Quantil-Impulse-Antwort-Funktion verdeutlicht den asymmetrischen Einfluss von Immobilienfonds entlang der Quantile von Immobilienrenditen. Da das VAR Modell nur auf stationären Zeitreihen stabil ist, wurden Differenzen der Finanzierungsvariablen gebildet. Das Problem der Differenzbildung ist, dass enthaltene Informationen über langfristige Zusammenhänge verloren gehen, wenn die Daten kointegriert sind. Als Erweiterung der Untersuchung, beispielsweise um Langzeiteffekte zu identifizieren, könnte man das VAR Modell für nicht-stationäre bzw. kointegrierte Modelle anwenden. Wegen dem begrenzten Zeitrahmen dieser Arbeit konnten diese Anwendungen nicht mehr realisiert werden. Da sich zeigte, dass die Zeitreihen kointegriert sind, könnte dies zu einer erkenntnisreichen Untersuchung führen. Weiterhin können die QVAR Modelle auf höher periodische Modelle ($k > 1$) erweitert werden.

6. Fazit

6.1. Zusammenfassung

Zusammenfassend zeigen die empirischen Ergebnisse, dass sowohl Banken als auch Immobilienfonds die Immobilienpreisentwicklung in Deutschland beeinflussen. Mit Hilfe der Quantilsregression ließen sich insbesondere Verlustrisiken identifizieren, die mithilfe einfacher linearer Regression nicht identifiziert werden konnten. Dies bestärkt die methodischen Überlegungen und ihre Umsetzung zur Beantwortung der Forschungsfragen. Die LR zeigt, dass Immobilienfonds mit 24% einen großen Beitrag zur Erklärbarkeit von deutschen Wohnimmobilienpreisen leisten und dieser wesentlich größer ausfällt, als derjenige der Banken unter Betrachtung Wohnbaukrediten im Neugeschäft an Privatpersonen (7%). Unter Berücksichtigung anderer Bankenvariablen bezogen auf das Wohnbaukreditvolumens traten hohe Korrelationen zwischen Investmentfonds- und Bankvariable auf. Die QR erweitert das Verständnis der Zielvariablenverteilung und ermöglichte es Einflüsse auf die gesamte Renditeverteilung zu untersuchen, was insbesondere für das Erklären von Einflussfaktoren extremer Ereignisse einen großen Nutzen bot. Hier wird deutlich, dass sowohl Bankvariablen als auch Investmentfondsfaktoren das Risiko in Wohnimmobilienpreisschwankungen und damit in den Renditen an verschiedenen Stellen in der Renditeverteilung beeinflussen. Signifikante Einflüsse für das VaR zeigten sowohl Bank- als auch Investmentfondsvariablen. Die VAR Modelle zeigen, dass ein Schock in den Änderungen von sowohl des Wohnbaukreditvolumen der Bank als auch im Fondsvermögen eine signifikante positiven Antwort auf Immobilienrenditen und damit Immobilienpreisen auslöst, welcher nach ca. einem Jahr abklingt. Die Q-VAR Modelle verdeutlichen die asymmetrische Beziehungen zwischen den Investmentfonds bzw. Bankkreditvolumens und

6. Fazit

den Renditen und illustriert mit Hilfe des Quantils-IAF Plots die asymptotische Verteilung der Renditeverteilung und damit letztendlich des Risikos. Gleichzeitig wurde deutlich, dass eine Änderung des betrachteten Fonds bzw. Wohnbaukreditvolumens, verschieden starke und gerichtete Wirkungen auf das Risiko hat. Zu betonen ist, dass durch alle Modelle ein vollständigeres Datenverständnis geschaffen werden konnte. Insgesamt bewährten sich die methodischen Überlegungen als gut und könnten auch auf Problemstellungen anderer Fachbereiche mit einem anderen Praxisbezug angewendet werden.

6.2. Schlussfolgerung und Einordnung in den Forschungsstand

Wer finanziert den Immobilienboom - Banken oder Investmentfonds?

Die Analysen zeigten, dass sowohl die Banken als auch Investmentfonds den Immobilienboom finanzieren und den Anstieg in den Preisen mit beeinflussen. Die betrachtete Zeitperiode von 2003 bis 2022 lässt mit den gefundenen Modellen die Interpretation zu, dass Banken insgesamt einen stärkeren positiven Einfluss auf die Immobilienpreisentwicklung haben. Besonders interessant bei den Banken ist hierbei, dass sie über verschiedene Kanäle Einfluss auf die Aktivität im Immobilienmarkt ausüben können. Wie beispielsweise über den Zins, die Lockerung der Kreditkonditionen als auch die Finanzierung von Privatpersonen und Unternehmen.

Wie wirkt sich ein Schock bei den Banken bzw. den Investmentfonds auf die Immobilienpreisrenditen aus?

Ein Schock in der prozentualen Veränderung des Wohnbaukreditvolumens führt zu einem Anstieg der Immobilienrenditen nach einem Quartal um 24 BP. Dieser Effekt klingt nach einem Jahr aus. Ein Schock in der prozentualen Veränderung des Fondvermögens führt zu einem Anstieg der Immobilienrenditen nach einem Quartal bei 20 BP. Dieser Effekt klingt nach einem Jahr aus. Zu betonen ist, dass aufgrund des breiten Konfidenzbands beider Impuls-Antwort Funktionen, die Aussage mit einer gewissen Unsicherheit verbunden ist. Beide Impulse sind jedoch signifikant positiv und

klingen nach 1 bis 2 Jahren wieder auf Null ab.

Wie beeinflussen Banken und Investmentfonds die Immobilienpreise und welche Chancen bieten bzw. Risikofaktoren bergen diese?

Es zeigt sich, dass vor allem Investmentfonds zu Risiken in Immobilienpreisen beitragen und verstärken den VaR bzw. den House-Price-at-Risk. Das bivariate Q-VAR Modell der Investmentfonds verdeutlicht, dass deren Wirkung entlang der Quantile verschiedene Richtungen annehmen können. Die Ergebnisse der Quantilsregression zeigten, dass sowohl Banken als auch Investmentfonds zum Marktrisiko von Immobilien beitragen. Bei der Untersuchung des Verlusts bei fallenden Hauspreisen, zeigte sich, ein besonders verstärkendes Down-Side-Risk durch Immobilienfonds. Dieser ist wesentlich stärker als der der Banken. Die Nutzung der erweiterten Form, Q-VAR Modelle, zeigt, dass Immobilienfonds unterschiedlich starke und unterschiedlich gerichtete Einflüsse entlang des Quantils von Immobilienrenditen aufzeigen. Dies lässt darauf schließen, dass Investmentfonds auch die Immobilienrenditen beeinflussen, indem sie Risiken verstärken. Es führt zu mehr Schwankungen in der Entwicklung von Immobilienrenditen und damit verstärkt die Aktivität von Investmentfonds die Volatilität der Wohnimmobilienpreise. Die weiteren, sich im Anhang befindenden Untersuchungen zeigen, dass es zu anderen und weiteren Interpretationen kommen kann. Dies schließt darauf, dass weitere Analysen mit anderen Modellen und Modellannahmen als auch höherfrequente und größere Zeitreihenstichproben robustere Antworten bieten könnten. Auch wird ersichtlich, dass ein besonderes Augenmerk auf den Umgang mit Trends gelegt werden sollte.

6.3. Ausblick weiterführende Forschung

Die Erkenntnisse der Q-VAR(1) Modelle mitsamt der Quantils-IAF Diagrammen könnte die These von [Muñoz, 2020] befürworten, dass der Investmentmarktsektor die Volatilität im Immobilienmarkt verstärkt. Dafür müssten jedoch, die Modelle auf die genauen Untersuchung der Volatilität angepasst werden. Unter Berücksichtigung verschiedener Immobilienpreisindizes zeigten sich verschiedene Resultate in den VAR Modellen. Als Erweiterung könnten daher Mixed-Frequency VAR

6. Fazit

Modelle herangezogen werden, die in einem gemischten Modell mit verschiedener Frequenzen (z.B von Quartalsdaten als auch Monatsdaten) Effekte identifizieren. Da die Betrachtung von $VAR(p)$ mit $p > 10$ aufgrund der niedrigen Stichprobengröße nicht durchführbar war, wäre es sinnvoll sowohl höher frequentierte Zeitreihen zu untersuchen als auch weitere Einschränkungen auf die Beziehungen und Wahrscheinlichkeitsverteilung der Bank, Fonds und Immobilienpreisvariable anhand von finanztheoretischen Annahmen festzulegen und das Modell dementsprechend einzuschränken. Die Erweiterung der VAR Modelle zu Bayesian VAR Modelle könnte dazu von Nutzen sein und weitere Ergebnissen zur Langzeitbeziehung der Variablen bieten [Hanck and Prüser, 2020]. Zusätzlich könnten die Q-VAR Modelle noch weitere Lags in die Vergangenheit betrachtet werden, um Langzeitrisiken und Übertragungen zu verfolgen.

A. Anhang

A.1. Weitere VAR Modelle

A.1.1. Kreditvolumen zu BIP Verhältnis vs. Fondsvermögen

Als Zeitreihenvektor wurde

$$\mathbf{X}_t = [R_t, \Delta WBK : BIP_t, \Delta OIF_t].$$

verwendet.

Zunächst wurde mit Hilfe des AIC Kriteriums bei maximaler Betrachtung von 3 Jahre (12 Lags) das optimale Lag bei $p = 2$ identifiziert. Dabei wurde das Modell auf signifikanten Einflussvariablen eingeschränkt und damit ein restriktives VAR Modell erzeugt. Mit Hilfe des Portemonteau Test wurden die Modellannahmen von unabhängigen Residuen getestet, um mögliche Autokorrelationen zu erkennen. Dieser Schritt der Modelldiagnostik ist essenziell, um die Validität des Modells zu testen. Sind noch Residuen enthalten, so müssen weitere Lags berücksichtigt werden. Der Test ergibt ein p-Wert von 0.12 und damit kann die Nullhypothese nicht verworfen werden, dass die Residuen nicht autokorreliert sind. Auch die ACF und PACF Plots der Residuen weisen keine signifikanten Lags mehr auf. Damit sind die Modellannahmen erfüllt.

Die Schätzung des VAR Modells ergeben folgende Modellgleichungen:

A. Anhang




Abbildung A.1.: Antwort der Wohnimmobilienpreise auf einen Einheitschock der Bankkredite zu BIP Verhältnis bzw. des Fondsvolumen

$$IR_t = \underset{(0.09)}{0.41} IR_{t-1} + \underset{(0.06)}{0.24} \Delta WBK / BIP_{t-12} + \underset{(0.001)}{0.002} \quad \text{Adj. } R^2 = 0.4038$$

$$WBK : BIP_t = \underset{(0.15)}{0.32} IR_{t-2} \quad \text{Adj. } R^2 = 0.04$$

$$OIF_t = \underset{(0.17)}{0.51} IR_{t-1} + \underset{(0.10)}{0.28} OIF_{t-1} + \underset{(0.002)}{0.007} \quad \text{Adj. } R^2 = 0.4942$$

Die Immobilienrenditen bedingen auf vergangenen Immobilienrenditen und Veränderungen im Verhältnis zwischen Bankkreditvolumen zum BIP, was 40% der Varianz in den Renditen erklärt.

Die Änderung des Fondsvolumens lässt sich durch steigende Immobilienpreise bzw. vergangene Renditen erklären. Hier wird der „Renditeappetit“ der Anleger in Immobilienfonds deutlich, die darauf spekulieren, bei steigenden Immobilienpreisen Profite zu erzielen. Die Varianzaufklärung lag hierbei bei knapp 50%.

Die Abbildung ?? zeigt, dass eine Veränderung im Fondsvolumen der Immobilienfonds die Immobilienrenditen erhöht. Dieser Einfluss zeigt sich innerhalb von 2 Quartalen und klingt nach 5 Quartalen ab.

A.1.2. Wohnbaukredite an Privatpersonen im Neugeschäft vs. Immobilienfonds

Die endogenen Variablen bestehen aus dem Kreditvolumen für Privatpersonen im Neugeschäft WBK, das Fondvermögen für Immobilienfonds OIF und den Immobilienpreisen für Neubauwohnungen in Deutschland HP.




Abbildung A.2.: Zeitreihen für das VAR(2) Modell

Als Zeitreihenvektor wurde

$$\mathbf{X}_t = [HP_t, WBK_t, OIF_t]$$

verwendet.

Zusätzlich zu dem Zeitreihenvektor wurde ein Trend und eine Konstante in die VAR Modellierung mitaufgenommen. Zunächst wurde mit Hilfe des AIC Kriteriums unter Betrachtung von maximal vier Perioden in die Vergangenheit das optimale Lag bei $p = 2$ identifiziert. Dabei wurde das Modell auf signifikante Einflussvariablen eingeschränkt und damit ein restriktives VAR Modell erzeugt. Mit Hilfe des Portmanteau-Tests wurden die Modellannahme von unabhängigen Residuen getestet, um mögliche Autokorrelationen zu erkennen. Dieser Schritt der Modelldiagnostik ist essenziell, um die Validität des Modells zu testen.

A. Anhang

$$HP_t = 0.6HP_{t-1} + 0.09OIF_{t-2} + 0.03WBK_{t-1} + 0.24HP_{t-2} + 0.27HP_{t-2} \quad R^2 = 1$$

$$WBK_t = 0.55HP_{t-1} + 0.33WBK_{t-1} + 0.38 \quad R^2 = 0.99$$

$$OIF_t = 0.37HP_{t-1} + 1.19OIF_{t-1} - 0.32HP_{t-2} - 0.21OIF_{t-2} \quad R^2 = 0.99$$

Die Regression der Immobilienpreise zeichnet einen starken Einfluss des Preises der Vorperiode ab. Dies verdeutlicht eine starke Persistenz der Zeitreihe und veranschaulicht die Trägheit des Immobilienmarktes. Der log Preis des Vorquartals und auch die Preise vor einem halben Jahr haben einen starken Einfluss auf den Preis von heute. Das R^2 ist sehr hoch, was für eine hohe Erklärungskraft der Preisvariable spricht. Dies wird durch die trägen Immobilienmarktpreise verdeutlicht, bei denen sich Schwankungen im Preis erst langsam bemerkbar machen. Auch das Fondsvolumen vor zwei Perioden hat einen signifikanten Einfluss auf den Preis, der jedoch im Verhältnis zum vergangenen Preis eher schwach ist. Die Trendvariable wird nicht signifikant, was vermuten lässt, dass die Wohnpreiszeitreihe bereits trendbereinigt ist und damit auf kointegrierte Zeitreihen hindeutet.

Da die Trendvariable nicht signifikant wurde und die Zeitreihe sehr persistent ist, lässt sich vermuten, dass Immobilienpreise und das Fondsvolumen sich den gleichen Trend teilen und dieser sich in der Regression aufhebt. Das R^2 liegt bei 1, was eine starke Varianzerklärung beschreibt. Der Standardfehler lag bei 0.01184, womit ein niedriger Prognosefehler bestätigt ist.

Um mögliche Autokorrelationen in den Residuen zu erkennen, wurde mit Hilfe des Portemonteau Test die Modellannahmen auf unabhängigen Residuen getestet. Dieser Schritt der Modelldiagnostik ist essenziell, um die Validität des Modells zu testen. Sind noch Autokorrelationen in den Residuen enthalten, so müssen in der Modellierung noch weitere Lags berücksichtigt werden. Der Test ergab einen p-Wert von 0.12 und damit kann die Nullhypothese nicht verworfen werden, dass die Residuen nicht autokorreliert sind. Auch die ACF und PACF Plots der Residuen

wiesen keine signifikanten Lags mehr auf. Damit sind alle Modellannahmen erfüllt.

Das Modell weist einen positiven Einfluss auf den Immobilienpreis auf nach einem halben Jahr auf den Immobilienpreis eine Auswirkung zeigt. Aus der Elastizität der Modellvariablen ergibt sich, dass bei einem Zuwachs des Fondsvolumens um 1% sich der Immobilienpreis in zwei Quartalen um 0.09% erhöht. Bei einem Zuwachs der Wohnbaukrediten um 1% steigt der Immobilienpreis um 0.03% . Es wird deutlich, dass es 6 Monate braucht, bis sich der vollständige Einfluss von Immobilienfonds in Immobilienpreisen beobachten lässt. Die Regression von Wohnbaukreditvolumen zeigt hier zusätzlich, dass Wohnbaukredite stark von den Immobilienpreisen der Vorperioden abhängen. Hierbei ist ein signifikanter positiver Effekt auf das Wohnbau-Kreditvolumen vorzufinden. Steigt der Immobilienpreis um 1%, so steigt auch das Kreditvolumen. Dieser Effekt kann auf zwei verschiedene Weisen interpretiert werden: Wenn die Immobilienpreise heute steigen, dann sollte sich das Bankvolumen erhöhen, da die Sicherheiten von Krediten an Wert gewinnen und generell ein höheres Kreditvolumen ausgegeben wird. Da Bankkredite meist über Sicherheiten vergeben werden und Immobilien häufig als Sicherheit fungieren, könnte durch die Wertsteigerung der Sicherheiten auch das Vermögen des Kreditnehmers an Wert steigen und damit die Bereitschaft in die Investition von Immobilienkrediten verstärken. Zudem kann die Preissteigerung dazu führen, dass, wenn die Immobilienpreise steigen sich auch die Erwartungen vergrößern, dass die Nutzung von Immobilieninvestments als gewinnbringende Anlage an Wichtigkeit gewinnt und in Zukunft sogar weiter steigen wird. Da es auch negative Effekte von vergangenen Wohnbaukreditvolumen gibt ist zu deuten, dass hier keine unidirektionale Beziehung besteht und dass auch Feedbackeffekte zwischen Immobilienpreis und Wohnbaukrediten auftreten können.

Die Regression von Wohnbaukreditvolumen zeigt hier zusätzlich, dass Wohnbaukredite stark von den Immobilienpreisen der Vorperioden abhängen. Hierbei ist ein signifikanter positiver Effekt auf das Wohnbau-Kreditvolumen vorzufinden. Steigt der Immobilienpreis um 1%, so steigt auch das Kreditvolumen um 0.55%. Dieser Effekt könnte auf zwei verschiedene Weisen interpretiert werden: Wenn die Immobilienpreise heute steigen, dann sollte sich das Bankvolumen erhöhen, da die Sicherheiten von Krediten an Wert gewinnen und generell ein höheres Kreditvolu-

A. Anhang

men ausgegeben wird. Da Bankkredite meist über Sicherheiten vergeben werden und Immobilien häufig als Sicherheit fungieren, könnte durch die Wertsteigerung der Sicherheiten auch das Vermögen des Kreditnehmers an Wert steigen und damit die Bereitschaft in die Investition von Immobilienkrediten verstärken. Zudem könnte die Preissteigerung dazu führen, dass, wenn die Immobilienpreise steigen sich auch die Erwartungen vergrößern, dass die Nutzung von Immobilieninvestments als gewinnbringende Anlage an Wichtigkeit gewinnt und in Zukunft sogar weiter steigen wird. Da es auch negative Effekte von vergangenen Wohnbaukreditvolumen gibt ist zu vermuten, dass hier keine unidirektionale Beziehung besteht und dass auch Feedbackeffekte zwischen Immobilienpreis und Wohnbaukrediten auftreten können.

Die Regression des Fondsvermögens weist einen positiven Einfluss vergangener Immobilienpreise auf. Dies lässt die Interpretation zu, dass bei Preissteigerungen der Renditeappetit der Anleger eher steigt. Vergangene Fondseinlagen haben hier ebenfalls einen starken Einfluss und auch hier ist ein starke persistente Zeitreihe zu erkennen. Beides führt zu einem Boom in Immobilien. Sowohl das Fondsvermögen von vor einem halben Jahr hat einen starken positiven Einfluss wie die Preise einen negativen Einfluss auf das Fondsvermögen haben. Diese Preiseinflüsse heben sich damit gegenseitig auf und schwankende bzw. alternierende Verhalten sind zu deuten. Hierbei lässt sich interpretieren, dass Immobilienfonds vor allem auf die Volatilität von Immobilienpreisen Einfluss hat.

Mit Hilfe der IAF untersuchten wir noch die Langzeitbeziehungen zwischen den Variablen. Dabei wird untersucht, wie ein Einheitsschock in einer endogenen Variable sich zeitlich auf die andere Variable auswirkt. Hierzu wurde untersucht, wie sich der Anstieg im Fondsvolumen bzw. Kreditvolumen auf Immobilienpreise auswirkt.

Die Abbildung A.3 demonstriert, wie das Fondsvolumen einen positiven Effekt auf den Immobilienpreis äußert. Ein einmaliger Schock im Immobilienfondsvolumen führt zu einer Preissteigerung von 2%. Da jedoch das Konfidenzband die Null enthält ist diese Aussage mit Unsicherheit verbunden und hat keine signifikante Aussagekraft. Ein Schock in Wohnbaukrediten führt zu einer Preissteigerung von 0.4% innerhalb eines halben Jahres und klingt nach eineinhalb

A.2. Parameterschätzer der Q-VAR(1) Modelle





Abbildung A.3.: Antwort des Immobilienpreises bei einem Impuls von

Jahre wieder ab. Sowohl die Banken als auch Investmentfonds finanzialisieren die Immobilienpreise, wobei der Einfluss der Investmentfonds stärker ist.

A.2. Parameterschätzer der Q-VAR(1) Modelle

Die Abbildungen in A.4 visualisieren die Parameterschätzer für den Koeffizienten a_{021} und stellen damit die kontemporären Effekte von Immobilienpreisen auf die Finanzierungsvariablen dar. Ins Auge stechend ist hierbei die gegensätzliche Wirkung entlang der Quantile im Vergleich beider bivariaten Modelle. Hier wird deutlich, dass Bankkredite besonders in Krisenzeiten einen starken kontemporären Effekt der Immobilienpreise auf die Kreditaufnahmeaktivität haben. Dieser ist beim VaR bei 10. Entlang des Quantils nimmt dieser Effekt ab und hat zwischen dem 50%-Quantils und dem 80%-Quantil eine nur sehr schwache Wirkung, die in Boomzeiten bei 90% an Stärke gewinnt. Diese asymmetrische Struktur kann zum einen verdeutlichen, dass zum einen in Krisenzeiten die Preise die Nachfrage an Krediten bestimmen, als auch in Boomzeiten wieder fördern. Im bivariaten Modell der Banken ist dieser Effekt stets positiv entlang der Quantile. Bei den Immobilienfonds entstehen sowohl positive Effekte als auch negative Effekte. In Boomzeiten haben Immobilienrenditen einen leicht positiven Effekt, während in Krisenzeiten der Effekt auf Immobilienfonds negativ wird. Das Ergebnis verstärkt die Annahme, dass Immobilienfonds in Abhängigkeit von der Entwicklung der Preise starke Veränderungen und Schwankungen im Fondsvermögen erleben.

A. Anhang




(a) kontemp. Effekt von IP auf Fonds

(b) kontemp. Effekte von IP auf Banken


Abbildung A.4.: Parameterschätzer im Vergleich beider bivariaten Q-VAR(1) Modelle

Abbildung A.5 (a) verdeutlicht die Wirkung der steigenden Renditen von heute auf Renditen von morgen, der besonders in Boomzeiten im 80% seine maximale Wirkung mit 0.8 erreicht. In Krisenzeiten hingegen ist der Einfluss der Renditen gering jedoch stets positiv. Abbildung A.5 (b) zeigt auf, dass besonders in Boomzeiten(80%-Quantil), die Wohnbaukreditaktivität einen negativen Effekt auf die Renditen und unter Betrachtung aller anderen Quantile einen stets positiven Einfluss auf zukünftige Immobilienrenditen ausübt. Die Wirkung in (c) entspricht dem kontemporären Effekt. Zuletzt zeigt sich in Abbildung A.5 (d) einen stets positiven autoregressiven Effekt von Wohnbaukreditvolumen, dessen Intensität aber entlang der Quantile variiert. Allesamt zeigen die Ergebnisse Feedbackbeziehungen zwischen Immobilienrenditen und Wohnbaukrediten.


A.2. Parameterschätzer der Q-VAR(1) Modelle




(a) R->R



(b) WBK->R




(c) R->WBK




(d) WBK->WBK

Abbildung A.5.: Parameterschätzer des bivariaten Q-VAR(1) Modells für Immobilienfonds


A. Anhang




(a) R->R



(b) OIF->R



(c) R->OIF



(d) OIF->OIF

Abbildung A.6.: Parameterschätzer des bivariaten Q-VAR(1) Modells für Wohnbaukredite an Privatpersonen

Abbildung A.6 (b) verdeutlicht den steigenden Einfluss der Immobilienfonds auf die Renditen entlang der Quantile. Im Boom ist dieser bei knapp 0.03 am stärksten. Abbildung A.6 (c) weist auf, dass Renditen besonders in Krisenzeiten einen positiven Einfluss auf die Fonds haben, während dieser Einfluss zum Boom hin sogar stark negative Effekte ausübt. Schließlich zeigt (c) einen stets positiven Effekt entlang der Quantile, der im Boom eine Stärke von bis zu 0.7 erreicht. Auch hier verdeutlichen die Plots Feedback-effekte und asymmetrische Effekte zwischen Immobilienfonds und Renditen. Besonders starke Effekte treten hierbei vor allem im Einfluss der Renditen auf die Fonds auf (Siehe A.6 (c)) .

Literaturverzeichnis

- [Aalbers, 2008] Aalbers, M. (2008). The Financialization of Home and the Mortgage Market Crisis. *the journal of global business and political economy*, 12:148–166.
- [Adams et al., 2021] Adams, P. A., Adrian, T., Boyarchenko, N., and Giannone, D. (2021). Forecasting macroeconomic risks. *International Journal of Forecasting*, 37(3):1173–1191.
- [Adelino et al., 2012] Adelino, M., Schoar, A., and Severino, F. (2012). Credit Supply and House Prices: Evidence from Mortgage Market Segmentation. *SSRN Electronic Journal*.
- [Adrian et al., 2019] Adrian, T., Boyarchenko, N., and Giannone, D. (2019). Vulnerable Growth. *American Economic Review*, 109(4):1263–89.
- [Agnello and Schuknecht, 2009] Agnello, L. and Schuknecht, L. (2009). Booms and busts in housing markets: determinants and implications. Working Paper Series 1071, European Central Bank.
- [Ando et al., 2018] Ando, T., Greenwood-Nimmo, M., and Shin, Y. (2018). Quantile Connectedness: Modelling Tail Behaviour in the Topology of Financial Networks. *SSRN Electronic Journal*.
- [André et al., 2017] André, C., Antonakakis, N., Gupta, R., and Zerihun, M. F. (2017). Asymmetric Behavior in Nominal and Real Housing Prices: Evidence from Emerging and Advanced Economies. *Journal of Real Estate Literature*, 25(2):409–425.

Literaturverzeichnis

- [Anundsen and Jansen, 2013] Anundsen, A. and Jansen, E. (2013). Self-Reinforcing Effects between Housing Prices and Credit. *Journal of Housing Economics*.
- [Arnold et al., 2017] Arnold, D., Rottke, N., and Winter, R. (2017). *Wohnimmobilien: Lebenszyklus, Strategie, Transaktion*.
- [Baffoe-Bonnie, 1998] Baffoe-Bonnie, J. (1998). The Dynamic Impact of Macroeconomic Aggregates on Housing Prices and Stock of Houses: A National and Regional Analysis. *The Journal of Real Estate Finance and Economics*, 17:179–197.
- [Banti and Phylaktis, 2022] Banti, C. and Phylaktis, K. (2022). Financialization of Housing Markets: Can REITs be the Culprit of Rising House Prices? page 51.
- [Belej and Kulesza, 2014] Belej, M. and Kulesza, S. (2014). The Influence Of Financing On The Dynamics Of Housing Prices. *Folia Oeconomica Stetinensia*, 14.
- [BIS, 2022a] BIS (2022a). Financial Stability Review. page 20. Zugegriffen am: 2022-12-22.
- [BIS, 2022b] BIS (2022b). Real Residential Property Prices for Germany. https://www.bis.org/statistics/pp_detailed.htm. Zuletzt zugegriffen am: 2022-12-22.
- [Brissimis and Vlassopoulos, 2009] Brissimis, S. and Vlassopoulos, T. (2009). The Interaction between Mortgage Financing and Housing Prices in Greece. *The Journal of Real Estate Finance and Economics*, 39(2):146–164.
- [Bundesbank, 0] Bundesbank (0). Zeitreihen-Datenbanken.
- [Carlier et al., 2016] Carlier, G., Chernozhukov, V., and Galichon, A. (2016). Vector Quantile Regression: An Optimal Transport Approach. Sciences po publications, Sciences Po.
- [Cecchetti and Li, 2008] Cecchetti, S. G. and Li, H. (2008). Measuring the Impact of Asset Price Booms Using Quantile Vector Autoregressions.

- [Cerutti et al., 2017] Cerutti, E., Dagher, J., and Dell'ariccia, G. (2017). Housing finance and real-estate booms: A cross-country perspective. *Journal of Housing Economics*, 38(C):1–13.
- [Chatfield, 2004] Chatfield, C. (2004). *The analysis of time series: an introduction*. CRC Press, 6th edition.
- [Chavleishvili and Manganelli, 2019] Chavleishvili, S. and Manganelli, S. (2019). Forecasting and Stress Testing with Quantile Vector Autoregression. *ERN: Outlooks & Forecasting (Topic)*.
- [Chowdhury et al., 2022] Chowdhury, M. S. R., Damianov, D. S., and Elsayed, A. H. (2022). Bubbles and crashes in cryptocurrencies: Interdependence, contagion, or asset rotation? *Finance Research Letters*, 46(PB):102494.
- [Cochrane, 2001] Cochrane, J. H. (2001). *Asset pricing*. Princeton Univ. Press, Princeton [u.a.].
- [Cunha and Lobão, 2021] Cunha, A. and Lobão, J. (2021). The determinants of real estate prices in a European context: a four-level analysis. *Journal of European Real Estate Research*, ahead-of-print.
- [Cvijanovic et al., 2021] Cvijanovic, D., Milcheva, S., and Van de Minne, A. (2021). Impact of Institutional Investors on Real Estate Risk. page 32.
- [Dahl and Goralczyk, 2017] Dahl, J. and Goralczyk, M. (2017). Recent supply and demand developments in the german housing market. European Economy - Economic Briefs 025, Directorate General Economic and Financial Affairs (DG ECFIN), European Commission.
- [Eller, 2010] Eller, R. (2010). *Kompaktwissen Risikomanagement : Nachschlagen, verstehen und erfolgreich umsetzen*. Wiesbaden : Gabler Verlag / Springer Fachmedien Wiesbaden GmbH, Wiesbaden.
- [Epstein, 2005] Epstein, G. A., editor (2005). *Financialization and the World Economy*. Edward Elgar Publishing.

- [Ernst and Schurer, 2015] Ernst, D. and Schurer, M. (2015). *Portfolio Management : Theorie und Praxis mit Excel und Matlab*. Konstanz : UVK-Verl.-Ges. [u.a.].
- [Eurostat, 2022] Eurostat (2022). Wohneigentumsquote in ausgewählten europäischen Ländern im Jahr 2021 [Graph]. <https://de.statista.com/statistik/daten/studie/155734/umfrage/wohneigentumsquoten-in-europa>. Zuletzt zugegriffen am: 2023-01-16.
- [Faber, 2009] Faber, O. (2009). Porträt der Finanzinvestoren „The Blackstone Group“ und „Cerberus Capital Management“. page 17.
- [Farha, 2017] Farha, L. (2017). Report of the Special Rapporteur on Adequate Housing as a Component of the Right to an Adequate Standard of Living, and on the Right to Non-Discrimination in This Context.
- [Fitzenberger and Koenker, 2002] Fitzenberger, B. and Koenker, R. (2002). *Economic Applications of Quantile Regression*.
- [Forster and Sun, 2022] Forster, R. and Sun, X. (2022). Heterogeneous Effects of Mortgage Rates on Housing Returns: Evidence from an Interacted Panel VAR. *The Journal of Real Estate Finance and Economics*.
- [Gabor and Kohl, 2022] Gabor, D. and Kohl, S. (2022). my home is an asset class. <http://extranet.greens-efa-service.eu/public/media/file/1/7461>. Zugegriffen am: 2022-12-22.
- [Galvao JR. et al., 2013] Galvao JR., A. F., Montes-Rojas, G., and Park, S. Y. (2013). Quantile Autoregressive Distributed Lag Model with an Application to House Price Returns. *Oxford Bulletin of Economics and Statistics*, 75(2):307–321.
- [Gerlach and Peng, 2005] Gerlach, S. and Peng, W. (2005). Bank lending and property prices in Hong Kong. *Journal of Banking & Finance*, 29(2):461–481.
- [Ghysels et al., 2018] Ghysels, E., Iania, L., and Striaukas, J. (2018). Quantile-based Inflation Risk Models. Working Paper Research 349, National Bank of Belgium.

- [Gimeno and Martínez-Carrascal, 2010] Gimeno, R. and Martínez-Carrascal, C. (2010). The relationship between house prices and house purchase loans: The Spanish case. *Journal of Banking & Finance*, 34:1849–1855.
- [Giuliodori, 2005] Giuliodori, M. (2005). The Role Of House Prices In The Monetary Transmission Mechanism Across European Countries. *Scottish Journal of Political Economy*, 52(4):519–543.
- [Gromer, 2012] Gromer, C. (2012). *Die Bewertung Von Nachhaltigen Immobilien*. Springer.
- [Hanck and Prüser, 2020] Hanck, C. and Prüser, J. (2020). House prices and interest rates: Bayesian evidence from Germany. *Applied Economics*, 52(28):3073–3089.
- [Heeg, 2012] Heeg, S. (2012). Wohnen als Anlageform: Vom Gebrauchsgut zur Ware. https://www.uni-frankfurt.de/49205025/e_3_2_heeg.pdf. Zugegriffen am: 2022-12-22.
- [Holm, 2010] Holm, A. (2010). Institutionelle Anbieter auf deutschen Wohnungsmärkten – neue Strategien der Wohnungsbewirtschaftung. *Informationen zur Raumentwicklung*, (5):391–400.
- [Hu et al., 2022] Hu, W., Zhou, Y., and Liu, J. (2022). Evaluation of Hot Money Drivers in China: A Structural VAR Approach. *Complexity*, 2022.
- [Iacopini et al., 2022] Iacopini, M., Poon, A., Rossini, L., and Zhu, D. (2022). Bayesian Mixed-Frequency Quantile Vector Autoregression: Eliciting tail risks of Monthly US GDP.
- [Jacobs and Manzi, 2020] Jacobs, K. and Manzi, T. (2020). Conceptualising ‘financialisation’: governance, organisational behaviour and social interaction in UK housing. *International Journal of Housing Policy*, 20(2):184–202.
- [Jones and Trevillion, 2022] Jones, C. A. and Trevillion, E. (2022). *Real Estate Investment*. Springer.

Literaturverzeichnis

- [Jorda and Taylor, 2015] Jorda, Oscar and Schularick, M. and Taylor, A. (2015). Betting the house. *Journal of International Economics*, 96(S1):S2–S18.
- [Just, 2010] Just, T. (2010). German residential property: Back in fashion—with good reason? (491).
- [Koenker, 2005] Koenker, R. (2005). *Quantile Regression*. Econometric Society Monographs. Cambridge University Press.
- [Koenker, 2022] Koenker, R. (2022). R package ‘quantreg’.
- [Koenker and Hallock, 2001] Koenker, R. and Hallock, K. F. (2001). *Quantile Regression*, volume 15 of *Journal of Economic Perspectives*. Cambridge University Press, 4 edition.
- [Koenker and Xiao, 2004] Koenker, R. and Xiao, Z. (2004). Unit Root Quantile Autoregression Inference. *Journal of the American Statistical Association*, 99:775–787.
- [Koenker and Xiao, 2006] Koenker, R. and Xiao, Z. (2006). Quantile Autoregression. *Journal of the American Statistical Association*, 101:980–990.
- [Kohl, 2020] Kohl, S. (2020). Too much mortgage debt? The effect of housing financialization on housing supply and residential capital formation. *Socio-Economic Review*.
- [Korevaar, 2021] Korevaar, M. (2021). Reaching for Yield: How Investors Amplify Housing Booms and Busts. *Capital Markets: Asset Pricing & Valuation eJournal*.
- [Kreiß and Neuhaus, 2006] Kreiß, J.-P. and Neuhaus, G. (2006). *Einführung in die Zeitreihenanalyse*. Springer.
- [Krippner, 2005] Krippner, G. (2005). The Financialization of the American Economy. *Socio-Economic Review*, 3:173–208.
- [Lecat and Mésonnier, 2005] Lecat, R. and Mésonnier, J.-S. (2005). What role do financial factors play in house price dynamics? <https://doi.org/10.1016/j.sre.2005.08.001>

- //abc-economie.banque-france.fr/sites/default/files/media/2016/12/07/134etud1_0.pdf. Zugegriffen am: 2022-12-22.
- [Li and Gao, 2012] Li, W. and Gao, Z. (2012). Real Estate Investors and the Boom and Bust of the US Housing Market. *Behavioral & Experimental Finance eJournal*.
- [Liu, 2020] Liu, W. (2020). Are Gold and Government Bond Safe-Haven Assets? An Extremal Quantile Regression Analysis. *International Review of Finance*, 20(2):451–483.
- [Lütkepohl, 2005] Lütkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. Number 978-3-540-27752-1 in Springer Books. Springer.
- [Muñoz, 2020] Muñoz, M. A. (2020). Macroprudential policy and the role of institutional investors in housing markets. Working Paper Series 2454, European Central Bank.
- [Nomics,] Nomics, D. The world economic database. <https://db.nomics.world/>. Zuletzt zugegriffen am: 2022-12-22.
- [Pavlov and Wachter, 2011] Pavlov, A. and Wachter, S. (2011). Subprime Lending and Real Estate Prices. *Real Estate Economics*, 39(1):1–17.
- [Rettberg, 2007] Rettberg, U. (2007). Immobilien werden mobil. <https://www.handelsblatt.com/finanzen/immobilien/verpackung-in-handelbare-finanzprodukte-immobilien-werden-mobil/2826048.html>. Zuletzt zugegriffen am: 2023-01-16.
- [Rinne, 2004] Rinne, H. (2004). *Ökonometrie*. Verlag Vahlen.
- [Rottke and Voigtländer, 2017] Rottke, N. and Voigtländer, M. (2017). *Immobilienwirtschaftslehre - Ökonomie*. Springer Gabler.
- [Scharmanski, 2012] Scharmanski, A. (2012). Im Sog der Euroschuldenkrise. Auswirkungen der Euroschuldenkrise auf den deutschen Immobilienmarkt. *Quantum Fokus*.

- [Schneider and Wagner, 2015] Schneider, M. and Wagner, K. (2015). Housing Markets in Austria, Germany and Switzerland. *Monetary Policy & the Economy*, (1):42–58.
- [Shahzad et al., 2021] Shahzad, J., Bouri, E., Kristoufek, L., and Saeed, T. (2021). Impact of the COVID-19 outbreak on the US equity sectors: Evidence from quantile return spillovers. *Financial Innovation*, 7:1–23.
- [Shahzad et al., 2019] Shahzad, S. J. H., Hoang, T. H. V., and Arreola-Hernandez, J. (2019). Risk spillovers between large banks and the financial sector: Asymmetric evidence from Europe. *Finance Research Letters*, 28(C):153–159.
- [Shida, 2022] Shida, J. (2022). The Macroeconomic Determinants of House Prices and Rents. *Journal of Economics and Statistics (Jahrbuecher fuer Nationaloekonomie und Statistik)*, 242(1):39–86.
- [Shumway and Stoffer, 2000] Shumway, R. H. and Stoffer, D. S. (2000). *Time Series Analysis and Its Applications*. Springer.
- [Sousa and Machado, 2006] Sousa, J. and Machado, J. A. (2006). Identifying asset price booms and busts with quantile regressions. Working papers, Banco de Portugal, Economics and Research Department.
- [Taltavull de La Paz and White, 2012] Taltavull de La Paz, P. and White, M. (2012). Fundamental drivers of house price change: the role of money, mortgages, and migration in Spain and the United Kingdom. *Journal of Property Research*, 29(4):341–367.
- [Tsay, 2002] Tsay, R. S. (2002). *Analysis of financial time series*. Wiley series in probability and statistics. 3rd ed. edition.
- [Valckx et al., 2020] Valckx, N., Shahid, S., Katagiri, M., and Deghi, A. (2020). Predicting Downside Risks to House Prices and Macro-Financial Stability. IMF Working Papers 2020/011, International Monetary Fund.

- [van Loon and Aalbers, 2017] van Loon, J. and Aalbers, M. B. (2017). How real estate became ‘just another asset class’: the financialization of the investment strategies of Dutch institutional investors. *European Planning Studies*, 25(2):221–240.
- [Voigtländer, 2012] Voigtländer, M. (2012). The Stability of the German Housing Market. MPRA Paper 43315, University Library of Munich, Germany.
- [Vornholz, 2022] Vornholz, G. (2022). *Der Immobilien-Investmentmarkt*. Springer Gabler.
- [Waltersbacher, 2013] Waltersbacher, M. (2013). Internationalisierung der Wohnungs- und Immobilienwirtschaft – Märkte, Akteure, Strategien.
- [Wijburg and Aalbers, 2017] Wijburg, G. and Aalbers, M. B. (2017). The alternative financialization of the German housing market. *Housing Studies*, 32(7):968–989.
- [Wilhelmsson, 2020] Wilhelmsson, M. (2020). What Role Does the Housing Market Play for the Macroeconomic Transmission Mechanism? *Journal of Risk and Financial Management*, 13(6).
- [Wooldridge, 2009] Wooldridge, J. M. (2009). *Introductory Econometrics: A Modern Approach*. ISE - International Student Edition. South-Western.
- [Xiao, 2009] Xiao, Z. (2009). Quantile Cointegrating Regression. Boston College Working Papers in Economics 708, Boston College Department of Economics.
- [Xiao and Koenker, 2009] Xiao, Z. and Koenker, R. (2009). Conditional Quantile Estimation for GARCH Models. Boston College Working Papers in Economics 725, Boston College Department of Economics.
- [Xie, 2021] Xie, W. (2021). Risk spillover in financial markets based on support vector quantile regression. *Journal of Intelligent & Fuzzy Systems*, 40:2337–2347.
- [Xu et al., 2016] Xu, Q., Liu, X., Jiang, C., and Yu, K. (2016). Quantile auto-regression neural network model with applications to evaluating value at risk. *Applied Soft Computing*, 49.

Literaturverzeichnis

[Yang and Rehm, 2021] Yang, Y. and Rehm, M. (2021). Housing prices and speculation dynamics: a study of Auckland housing market. *Journal of Property Research*, 38(4):286–304.

[Zhang et al., 2019] Zhang, Y., Chen, F., Huang, J., and Shenoy, C. (2019). Hot money flows and production uncertainty: Evidence from China. *Pacific-Basin Finance Journal*, 57(C).