

Wohnungsmärkte im Spannungsfeld regionaler Heterogenität und politischer Steuerung

Dissertation

zur Erlangung des Grades eines Doktors der Wirtschaftswissenschaft

eingereicht an der
Fakultät für Wirtschaftswissenschaften
der Universität Regensburg

vorgelegt von:

Lars Jagemann

Berichterstatter:

Prof. Dr. Steffen Sebastian

Prof. Dr. Tobias Just

Tag der Disputation: 30. April 2026

Inhaltsverzeichnis

Abkürzungsverzeichnis	ii
Symbolverzeichnis	iii
Abbildungsverzeichnis	iv
Tabellenverzeichnis	vi
Vorwort	vii
A Regulierungsinstrumente und ihre Marktauswirkungen:	
Empirische Analysen deutscher Mietwohnungsmärkte	1
A.1 Mietpreisdynamiken im Wechselspiel von Markt und Regulierung - Ein Vergleich deutscher Angebots- und Mietspiegelmieten als Indikator regionaler Segregationstendenzen	4
A.1.1 Einleitung	4
A.1.2 Rechtliche Grundlagen	7
A.1.3 Daten und Methodik	10
A.1.4 Ergebnisse	16
A.1.5 Fazit	27
A.2 Fehlallokationen deutscher Mietpreisregulierung? Ein dynamisches Modell zur Evaluation alternativer Regulierungsformen	30
A.2.1 Einleitung	30
A.2.2 Literaturübersicht	31
A.2.3 Daten und Methodik	33
A.2.4 Mikroökonomische Fundierung	43
A.2.5 Ergebnisse	45
A.2.6 Limitationen der Studie	60
A.2.7 Fazit	64
B Subtile Markteinflüsse: Politische Unsicherheit	66
B.1 The Price of Politics: A County-Level Analysis of Political Uncertainty and German House Prices	67
B.1.1 Introduction	67
B.1.2 Uncertainty in Real Estate	69
B.1.3 Data	72
B.1.4 Empirical Analysis	79
B.1.5 Conclusion	97
C Synthese	98
Literaturverzeichnis	102
Anhang	111

Abkürzungsverzeichnis

BB	Brandenburg
BBSR	Bundesinstitut für Bau-, Stadt- und Raumforschung
BE	Berlin
BW	Baden-Württemberg
BY	Bayern
EPU	Economic Policy Uncertainty Index
FE	Fixed Effects (Feste Effekte)
GAM	Generalized Additive Model
HB	Bremen (Freie Hansestadt Bremen)
HC	Heteroskedasticity-consistent (Heteroskedastie-robust)
HE	Hessen
HH	Hamburg (Freie und Hansestadt Hamburg)
IPO	Initial Public Offering
KdU	Kosten der Unterkunft
km	Kilometer
MPB	Mietpreisbremse
Mrd.	Milliarden
MV	Mecklenburg-Vorpommern
MZ	Mikrozensus
NI	Niedersachsen
NW	Nordrhein-Westfalen
NVM	Neuvertragsmiete
Q1	Quintil 1 (Kap. A.2) / Quartal 1 (analog Q2, Q3, und Q4) (Kap. B.1)
RE	Random Effects (Zufallseffekte)
REIT	Real Estate Investment Trust
RP	Rheinland-Pfalz
SARAR	Spatial Autoregressive with Autoregressive error term
SE	Standard Error (Standardfehler)
SH	Schleswig-Holstein
SL	Saarland
SN	Sachsen
ST	Sachsen-Anhalt
TH	Thüringen
UK	United Kingdom (Vereinigtes Königreich)
UPI	Uncertainty Perception Index
US	United States of America (Vereinigte Staaten von Amerika)
Vgl.	Vergleiche
VIF	Variance Inflation Factor (Varianzinflationsfaktor)

Symbolverzeichnis

α	Präferenzparameter für Wohnen
β	Regressionskoeffizient
γ	Koeffizient für feste Zeiteffekte (Kap. A.1); Koeffizient (Kap. A.2)
δ	Koeffizient (Kap. A.2); Koeffizient für feste Zeiteffekte (Kap. B.1)
ε / ϵ	Fehlerterm in Regressionsmodellen
λ	Räumlicher Lag-Parameter (Kap. A.1); Angebotsreaktion/Elastizität (Kap. A.2)
μ	Koeffizient für feste Stadt-/Kreiseffekte (Kap. A.1, B.1)
ρ	Räumlicher Fehlerparameter (Kap. A.1); Räumlicher Lag-Parameter (Kap. B.1)
τ	Effektiver Steuersatz (Kap. A.2)
χ^2	Chi-Quadrat-Verteilung (in statistischen Tests)
c	Nicht-Wohnungskonsum (Kap. A.2)
D	Dummy-Variable (Kap. A.1)
d	Geographische Distanz (Kap. A.1)
e	Fehlerterm-Vektor (Kap. A.1)
EV	Äquivalente Variation (Kap. A.2)
h	Wohnfläche (Kap. A.2)
i, j, t	Indizes für Regionen (i, j) oder Zeit (t)
L	Log-Likelihood-Funktion (Kap. A.1)
$\log$ / $\ln$	Natürlicher Logarithmus
p	p-Wert (Statistik); Miete/Preis (Kap. A.2)
R^2	Bestimmtheitsmaß
$te(\dots)$	Tensor-Produkt-Interaktion (in GAMs)
U	Nutzenfunktion (Kap. A.2)
W, w	Räumliche Gewichtungsmatrix / Gewicht (Kap. A.1, B.1)
X	Matrix der erklärenden Variablen (Kap. A.1)
y	Abhängige Variable; Relative Mietdifferenz (Kap. A.1); Haushaltsnettoeinkommen (Kap. A.2)
$\otimes$	Kronecker-Produkt (Kap. A.1)
%	Prozent
€	Euro (Währungseinheit)

Abbildungsverzeichnis

A.1	Flussdiagramm: Deutsche Mietpreisregulierung und ihre Ausnahmen	9
A.2	Absolute Differenzen im Zeitverlauf nach Stadtkategorie (€/m ²)	17
A.3	Relative Differenzen im Zeitverlauf nach Stadtkategorie	17
A.4	Verteilung relativer Differenzen nach Stadtkategorie (2020), Inseratsebene .	18
A.5	Relative Differenzen nach Baujahr (Durchschnitt 2014-2022), GAM-gewichtete Städte-Ebene	20
A.6	Relative Differenzen nach Baujahr und Städtektegorie (Durchschnitt 2014-2022), Inseratsebene der Angebotsdaten	20
A.7	Datengrundlage und Filterung	34
A.8	Validierung der Gewichtungsfaktoren und Repräsentativität	35
A.9	Verteilung des Gesamtregelbedarfs der Haushalte	37
A.10	Bedarfslücke und Transferberechtigung	38
A.11	Verteilung der Haushaltsgrößen	46
A.12	Wohnflächenverteilung und Pro-Kopf-Fläche	46
A.13	Einkommensverteilung der Miethaushalte	46
A.14	Vergleich: Status Quo vs. Neuvertragsmieten	49
A.15	Verfügbares Einkommen: Detailanalyse	50
A.16	Mietbelastungsquote im Vergleich	51
A.17	Gleichgewichtskonvergenz - Medianwerte	52
A.18	Gesamte Mietausgaben nach Szenario	53
A.19	Mietbelastung: Detailanalyse nach Gruppen	54
A.20	Mietbelastung nach Einkommen	55
A.21	Empfängerhaushalte von Transferleistungen	56
A.22	Jährliche Transferausgaben	57
A.23	Fiskalische Nettobilanz	57
A.24	Wohlfahrtsanalyse: Äquivalente Variation der Miethaushalte	58
B.1	Development of UPI German Politics Index 2013-2022	74
B.2	Average House Prices 2013-2022 (in €)	75
B.3	Average Apartment Prices 2013-2022 (in €)	76
B.4	Average House Prices in the State of Bavaria 2013-2022 (in €)	80
B.5	Average Apartment Prices in the State of Baden-Wuerttemberg 2013-2022 (in €)	81
B.6	Average Unemployment Rate 2013-2022 (in Percentage)	86
B.7	Spatial Regions of Germany	92

An.1	Verteilung der Angebotsmietdaten der Stadtkategorien im Zeitverlauf . . .	119
An.2	Angebotsmietdaten Städte innerhalb der Stadtkategorien im Zeitverlauf . .	119
An.3	GAM-Funktionen am Beispiel Berlin	120
An.4	Residuen vs. Angepasste Werte und Skalierungs-Lokations-Diagramm . . .	128
An.5	Q-Q-Diagramm (links) und Histogramm der Residuen (rechts)	129
An.6	Methodik Zuweisung der Mietstufen mit Beispiel	135
An.7	Kennzahlen der Mietstufen-Zuordnung	139
An.8	Stabilitätsmetriken	140
An.9	KdU-Berechnung: Methodik und Beispiele	141
An.10	Struktur des Gesamtregelbedarfs nach Haushaltsgröße	142
An.11	Tensorprodukt-Interaktionsoberfläche	143
An.12	Diagnostische Analyse des Basis-GAM	144
An.13	Heteroskedastizität-Stabilisierung durch Tensorprodukt und HC-Standardfehler	146
An.14	Tensorprodukt-Dekomposition und partielle Effekte	147
An.15	Multikollinearität-Diagnostik	149
An.16	Heteroskedastizität-Tests	150
An.17	Normalitäts-Tests	151
An.18	Residuen-Diagnostik	152
An.19	Haushaltseinkommen nach Haushaltsgröße	153
An.20	Pro-Kopf-Einkommen nach Haushaltsgröße	154
An.21	Einkommensverteilung nach Bundesland	154
An.22	Durchschnittliche Wohnfläche nach Bundesland	155
An.23	Gleichgewichtskonvergenz - Durchschnittswerte	156
An.24	Verteilung der Wohnflächenanpassung	157
An.25	Regionale Mietentwicklung nach Mietstufe	158
An.26	Transferleistungsintensität nach Mietstufe	159
An.27	Transferleistungen nach Bundesland	160
An.28	Verteilung der monatlichen Transferbeträge	161
An.29	Q-Q Plot Model 2 – House Prices	165
An.30	Q-Q Plot Model 8 – Apartment Prices	166
An.31	Residual Distribution Model 2 – House Prices	167
An.32	Residual Distribution Model 8 – Apartment Prices	168
An.33	Residual vs. Fitted Values Model 2 – House Prices	169
An.34	Residual vs. Fitted Values Model 8 – Apartment Prices	170
An.35	Autocorrelation Function Model 2 – House Prices	171
An.36	Autocorrelation Function Model 8 – Apartment Prices	172

Tabellenverzeichnis

A.1	SARAR-Modell: Determinanten der relativen Differenzen	22
A.2	Temporale Effekte innerhalb des robusten SARAR	25
A.3	Gesamtwohlfahrtseffekt im Gleichgewichtszustand	59
B.1	Descriptive Statistics	77
B.2	Pairwise Correlations	78
B.3	Political Uncertainty and Transaction Prices	84
B.4	Spatial Impacts for Political Uncertainty and Transaction Prices	85
B.5	Spatial Heterogeneous Effects of Political Uncertainty on Transaction Prices	87
B.6	Robustness Checks for Political Uncertainty and Economic Policy Uncertainty	90
B.7	Robustness Checks for Spatial Regions	93
B.8	Robustness Checks for Urbanity	95
B.9	Robustness Checks for COVID-19	96
An.1	Übersicht der Städte, Stadtkategorien und Mietspiegel	112
An.2	Variablenliste Angebotsmietdaten	118
An.3	Bevölkerungsgewichtete Angebotsmietentwicklung 2014-2022; Datengrundlage: Regressionsanalyse mit 73 Städten	120
An.4	Filterkriterien für die Datenauswahl	121
An.5	Harmonisierungsmaßnahmen und verbleibende Unsicherheiten	122
An.6	Übersicht der Kontrollvariablen, ihrer Repräsentation und Datenquellen	124
An.7	Deskriptive Statistik der SARAR-Modellvariablen	125
An.8	Umfassende Validitätstests für das SARAR-Modell	126
An.9	Zusätzliche Validitätstests: Stationarität und Serielle Korrelation	126
An.10	Variance Inflation Factors (VIF) - Multikollinearitätstest	127
An.11	Charakteristika der Modellresiduen	127
An.12	Effekt-Dekomposition am Beispiel der Mietpreisbremse	133
An.13	Vergleich SARAR mit alternativen Spezifikationen	134
An.14	Verteilung der Mietstufen in Deutschland nach Bundesland und Gemeindegrößenklasse	136
An.15	Validitätsprobleme des Basis-GAMs	145
An.16	Einkommensabhängige Flächenelastizitäten	147
An.17	Modellvergleich: Additiv vs. Tensorprodukt	148
An.18	Ökonometrische Validitätsübersicht	148
An.19	UPI German Politics: Dictionary Example for 2021Q1	163
An.20	Moran's I Test Statistics for Transaction Prices	164

Vorwort

„The curious task of economics is to demonstrate to men how little they really know about what they imagine they can design.“ (Hayek, 1991)

Wohnen ist mehr als ein Dach über dem Kopf – es ist Grundbedürfnis und Ausdruck gesellschaftlicher Teilhabe zugleich. Die Frage des bezahlbaren Wohnens steht daher im Zentrum gesellschaftlicher Debatten in Deutschland, das mit einer Wohneigentumsquote von lediglich 43,7 % den höchsten Mieteranteil in der Europäischen Union aufweist (Statistisches Bundesamt, 2024a; Eurostat, 2024). Als wichtigste Vermögenskomponente privater Haushalte vereinen Wohnimmobilien soziale und ökonomische Dimensionen in einzigartiger Weise (Deutsche Bundesbank, 2025).

Wohnungsmärkte weisen jedoch charakteristische Imperfektionen auf, die regulierende Eingriffe legitimieren: ein kurzfristig unelastisches Angebot, hohe Such- und Umzugskosten, ausgeprägte Heterogenität sowie positive Externalitäten bezahlbaren Wohnens. Rein markt-basierte Lösungen können daher ebenso problematisch sein wie eine politische Steuerung, die ihre Wirkungsmechanismen nicht durchdringt. Doch während die wissenschaftliche Literatur diese Mechanismen mit zunehmender Präzision beschreibt, finden sie in der öffentlichen Debatte zu wenig Beachtung. Politische Entscheidungen orientieren sich häufig an normativen Zielsetzungen, ohne die ökonomischen Folgewirkungen ihrer Instrumente vorab abzuwägen – ein Ausdruck dessen, was Hayek als fundamentales Problem wirtschaftspolitischen Handelns identifizierte.

Diese Diskrepanz zwischen politischer Praxis und analytischer Fundierung motiviert meine Forschung. Die vorliegende Dissertation prüft drei aufeinander bezogene Hypothesen. Erstens: Die in Deutschland gewachsene asymmetrische Regulierung von Bestands- und Neuvertragsmieten erzeugt eine systematische Segmentierung der Wohnungsmärkte, deren Ausmaß und Treiber empirisch messbar sind. Zweitens: Eine Reform dieser Asymmetrie hätte spürbare Wohlfahrts- und Verteilungswirkungen, die sich mikroökonomisch fundiert simulieren und nicht allein politisch postulieren lassen. Drittens: Auch die wahrgenommene politische Unsicherheit selbst formt die Preisbildung deutscher Wohnimmobilien jenseits direkter Regulierung – eine indirekte Wirkungsebene, die in der deutschsprachigen Forschung bislang weitgehend unbeleuchtet geblieben ist.

Diesen Hypothesen folgt die Arbeit in drei Beiträgen. Eine räumlich-ökonometrische Analyse quantifiziert zunächst die wachsende Divergenz zwischen Bestands- und Neuvertragsmieten in 107 deutschen Städten und identifiziert ihre Determinanten. Darauf aufbauend bewertet eine mikrofundierte Simulation einen alternativen Reformpfad nach seinen Wohlfahrts- und Verteilungseffekten. Eine räumliche Panelanalyse auf Kreisebene erweitert den Blick schließlich vom Mietmarkt zu den Preisen für Wohnimmobilien und prüft, wie politische Unsicherheit auch jenseits konkreter Regulierung deren Bildung prägt. Eine zusammenführende Synthese diskutiert die Implikationen für eine evidenzbasierte Wohnungspolitik.

Ich möchte allen Menschen danken, die es mir ermöglicht haben, durch meine Forschung einen wissenschaftlichen Beitrag zu diesen Themen zu leisten: Mein Dank gilt Professor Sebastian für seine Beiträge und inspirierende Betreuung, Professor Just für viele wertvolle Hinweise, meinen Kolleginnen und Kollegen für die wertvolle Zusammenarbeit sowie meiner Familie und meiner Partnerin für ihre unermüdliche Unterstützung.

Teil A

Regulierungsinstrumente und ihre Marktauswirkungen: Empirische Analysen deutscher Mietwohnungsmärkte

Die ökonomische Forschung zu Auswirkungen von Mietpreisregulierungen auf Wohnungsmärkte zeigt typischerweise Zielkonflikte auf. Während Regulierungen wie Mietpreisbindungen oder -bremsen kurzfristig die Bezahlbarkeit für Bestandsmieter sichern können, deuten theoretische Modelle und empirische Studien auf potenzielle negative Langzeiteffekte hin. Dazu zählen eine Reduzierung des Angebots an Mietwohnungen, geringere Investitionen in Instandhaltung, eine ineffiziente Allokation von Wohnraum sowie mögliche Anreize für Umgehungsstrategien (Arnott, 1995; Arnott, 2003; Kholodilin, 2024). Internationale Evidenz, etwa aus San Francisco (Diamond et al., 2019) oder nach der Abschaffung der Mietpreisbindung im US-Bundesstaat Massachusetts (Autor et al., 2014; Sims, 2007), dokumentiert diese negativen Effekte in der Praxis und zeigt die komplexen, teils adversen Auswirkungen von staatlichen Eingriffen auf das Marktgeschehen. Trotzdem können Imperfektionen auf den Wohnungsmärkten staatliche Eingriffe in den Mietwohnungsmarkt legitimieren: Anders als auf idealtypischen Wettbewerbsmärkten ist das Angebot an Wohnraum kurzfristig unelastisch, da die Produktion neuen Wohnraums langen Planungs- und Bauphasen unterliegt und durch Baulandverfügbarkeit sowie regulatorische Hürden limitiert wird (DiPasquale und Wheaton, 1996). Auf der Nachfrageseite führen erhebliche Such- und Umzugskosten zu eingeschränkter Mobilität der Mieter. Die ausgeprägte Heterogenität, Unteilbarkeit von Wohnraum und hohe Transaktionskosten erschweren zudem effiziente Marktmechanismen. Hinzu kommen Informationsasymmetrien zwischen Mietern und Vermietern sowie lokale Marktmachtkonstellationen, die zu suboptimalen Marktergebnissen führen können (Glaeser und Luttmer, 2003; Wheaton, 1990).

Wohnen ist darüber hinaus kein gewöhnliches Wirtschaftsgut, sondern aus sozialpolitischer Perspektive ein zentrales Politikum. Qualitativ hochwertiger und bezahlbarer Wohnraum generiert positive Externalitäten durch erhöhte Arbeitsmarktmobilität, verbesserte Gesundheit und Bildungserfolge (Favilukis et al., 2023) – gesellschaftliche Erträge, die private Marktteilnehmer nicht internalisieren. Diese Diskrepanz zwischen privatem und sozialem Grenznutzen kann wohlfahrtsökonomisch Markteingriffe wie Subventionen begründen.

Deutschland eignet sich besonders gut für die Analyse von Mietwohnungsregulierungen. Mit einer Wohneigentumsquote von 43,7% im Jahr 2023 weist Deutschland den höchsten Mieteranteil in der Europäischen Union auf (Statistisches Bundesamt, 2024a; Eurostat, 2024). Diese Besonderheit verleiht der staatlichen Mietwohnungsregulierung eine große gesellschaftliche Bedeutung. So ist der deutsche Mietwohnungsmarkt durch ein Regulierungssystem geprägt, das bezahlbaren Wohnraum sichern und Mieter vor übermäßigen Mietsteigerungen schützen soll. Die ortsübliche Vergleichsmiete bildet dabei die zentrale Referenzgröße: Sie wird aus den üblichen Entgelten gebildet, die in den letzten sechs Jahren für vergleichbaren Wohnraum in Art, Größe, Ausstattung, Beschaffenheit und Lage vereinbart oder geändert wurden (§ 558 Abs. 2 BGB). Diese Vergleichsmiete wird häufig in Mietspiegeln dokumentiert. Zu den wichtigsten Regulierungsinstrumenten gehören die Mietpreisbremse und die Kappungsgrenze, die beide Mieterhöhungen begrenzen, jedoch unterschiedliche Anwendungsbereiche aufweisen: Die Mietpreisbremse greift bei Neuvermietungen in angespannten Wohnungsmärkten und limitiert die Anfangsmiete auf maximal 110% der ortsüblichen Vergleichsmiete – ausgenommen sind etwa modernisierte oder nach 2014 errichtete Wohnungen. Die Kappungsgrenze hingegen wirkt als dynamische Begrenzung in bestehenden Mietverhältnissen: Sie beschränkt Mieterhöhungen auf maximal 20% innerhalb von drei Jahren, wobei die Bundesländer diese in angespannten Märkten auf 15% reduzieren können (§ 558 Abs. 3 BGB). Dabei gilt die ortsübliche Vergleichsmiete bei regulären Mietverhältnissen stets als Obergrenze für Mieterhöhungen im Bestand (§ 558 Abs. 1 BGB), selbst wenn die Kappungsgrenze eine höhere Erhöhung erlauben würde. Eine von der Bundesregierung zwischenzeitlich erwogene Absenkung der Kappungsgrenze auf 11 % in angespannten Wohnungsmärkten ist im laufenden Mietrechtsnovellierungsverfahren nicht umgesetzt worden; die Mietpreisbremse selbst wurde mit Wirkung vom 23. Juli 2025 bis zum 31. Dezember 2029 verlängert (Deutscher Bundestag, 2025).

Die empirische Evidenz differenziert zwischen intendierten Primäreffekten und nicht-intendierten Sekundäreffekten dieser Regulierungen. Studien zur Mietpreisbremse bestätigen teils die angestrebten moderaten preisdämpfenden Effekte, insbesondere kurz nach Einführung (Breidenbach et al., 2022; Deschermeier et al., 2016), weisen aber zugleich auf kompensatorische Marktreaktionen wie Angebotsverknappung im regulierten Segment oder Verlagerungen in unregulierte Wohnsegmente hin (Autor et al., 2014; Diamond et al., 2019; Mense et al., 2023). Baye und Dinger (2024) untersuchen die Auswirkungen der deutschen Mietpreisbremse auf Investitionsanreize und Gentrifizierung. In der Studie reduziert die Mietpreisbremse Renditen im preisregulierten Segment und verlagert folglich Investitionen hin zu nicht regulierten Objekten mit höheren Renditen. Diese Verschiebung kann Gentrifizierungstendenzen verstärken, da Investoren bevorzugt in profitableren Wohnraum investieren. Die Forschung zur Kappungsgrenze ist weniger umfangreich, doch deuten Analysen darauf hin, dass auch

sie das Mietniveau beeinflusst und zur Segmentierung des Marktes beitragen kann, indem sie die Anpassung von Bestandsmieten an das Marktniveau verlangsamt (Kholodilin, 2024).

Obwohl Mietpreisbremse und Kappungsgrenze in 85% der regulierten deutschen Kommunen gleichzeitig gelten (BBSR, 2025), ist die Interaktion zwischen Kappungsgrenze und Mietpreisbremse sowie deren gemeinsame Wirkung auf die zunehmende Divergenz von Bestands- und Neuvertragsmieten kaum erforscht. Während Preissteigerungen im Bestand erfolgreich im Rahmen allgemeiner Preissteigerungen eingedämmt werden konnten, legten Neuvertragsmieten seit dem Jahr 2015 um rund 70% zu (Bundesbank, 2023). Die zunehmende Polarisierung der Wohnungsmärkte konstituiert sich als zentrale sozioökonomische Herausforderung. Baldenius et al. (2020) dokumentieren die Rückkehr der “Wohnungsfrage” als gesellschaftliches Verteilungsproblem. Die Divergenz zwischen Bestands- und Neuvertragsmieten zeigt sich besonders in deutschen Metropolregionen durch eine institutionelle Segmentierung des Mietwohnungsmarktes: Der starke Bestandsmieterschutz kontrastiert mit der durch Ausnahmen abgeschwächten Mietpreisbremse bei Neuverträgen führt zu einer Asymmetrie, die zusammen mit der Angebotsknappheit zu hohen Neuvertragsmieten führt und mobile Haushalte wie Berufseinsteiger und junge Familien vor hohe Zugangsbarrieren stellt. Vor diesem Hintergrund adressiert Teil A dieser Dissertationsschrift zwei zentrale Forschungsfragen:

- (i) Welche Faktoren treiben die zunehmende Segmentierung zwischen Bestands- und Neuvertragsmieten, und inwieweit tragen zentrale Regulierungsinstrumente wie die Mietpreisbremse in ihren intendierten Funktionen dazu bei, diese Divergenzen zu begrenzen?
- (ii) Welche Wohlfahrts- und Verteilungseffekte entstünden durch eine Reform der dualen Regulierung, und wie wären verschiedene gesellschaftliche Gruppen davon betroffen?

Zur Beantwortung dieser Fragen präsentiert Kapitel A.1 eine empirische Analyse der Mieten-segregation in 107 deutschen Städten und identifiziert mittels räumlicher Panel-Regression die ökonomischen, demographischen und räumlichen Determinanten der wachsenden Divergenz zwischen Bestands- und Neuvertragsmieten. Kapitel A.2 entwickelt ein dynamisches, auf Mikrodaten fundierendes Mietwohnungsmarktmodell, das durch die Simulation der Anpassung von Bestands- und Neuvertragsmietniveau zur wohlfahrtstheoretischen Analyse alternativer Regulierungsmaßnahmen beiträgt.

A.1 Mietpreisdynamiken im Wechselspiel von Markt und Regulierung - Ein Vergleich deutscher Angebots- und Mietspiegelmieten als Indikator regionaler Segregationstendenzen*

Autoren: Lars Jagemann und Steffen Sebastian

Zusammenfassung: Mieterhöhungen in bestehenden regulären Mietverhältnissen sind grundsätzlich auf die ortsübliche Vergleichsmiete begrenzt. In angespannten Wohnungsmärkten gilt bei Neuvermietungen zudem eine Obergrenze von 110% der ortsüblichen Vergleichsmiete. Dennoch wächst die Divergenz zwischen Bestands- und Neuvertragsmieten. Diese Studie analysiert die Differenz zwischen der ortsüblichen Vergleichsmiete, die durch Mietspiegelwerte die Bestandsmieten repräsentiert, und den Angebotsmieten, welche die Neuvertragsmieten abbilden, in 107 deutschen Städten. Ziel ist es, das Ausmaß dieser Mietsegmentierung in den Jahren 2014 bis 2022 zu quantifizieren und ihre Determinanten zu identifizieren. Die empirische Analyse dokumentiert eine ausgeprägte Segmentierung deutscher Wohnungsmärkte mit relativen Differenzen zwischen Neuvertrags- und Bestandsmieten von durchschnittlich 20 bis 25%, die in Metropolen auf bis zu 50% ansteigen. Die räumliche Regressionsanalyse identifiziert marktstrukturelle Faktoren als Treiber dieser Divergenz: Wirtschaftliche Prosperität und demografischer Druck dominieren, während höhere Anteile nicht-gewinnorientierter Vermieter dämpfend wirken. Räumliche Abhängigkeiten zwischen den Städten im Panel verstärken regionale Disparitäten. Die Mietpreisbremse zeigt keine unmittelbare Wirkung; erst mit zweijähriger Verzögerung manifestiert sich ein moderat dämpfender Effekt, der angesichts der Marktdynamik irrelevant erscheint. Die dokumentierten Asymmetrien generieren Ineffizienzen durch Immobilisierung des Bestandsmarktes, während das knappe und teurere Neuvertragssegment Anpassung an veränderte Lebensumstände und räumliche Arbeitsmobilität einschränkt. Die Befunde implizieren einen Lock-in-Effekt, der ohne Reform der Regulierungsarchitektur – entweder durch effektivere Durchsetzung im Neuvertragssegment oder symmetrische Deregulierung – in Form ineffizienter Marktallokationen persistieren wird.

A.1.1 Einleitung

Mietregulierungen stehen in einem grundsätzlichen Spannungsfeld: Dem sozialpolitisch legitimen Ziel, bezahlbares Wohnen zu sichern und Mieter vor disruptiven Preissprüngen zu schützen, stehen ökonomische Folgewirkungen gegenüber. Eine breite theoretische und empirische Literatur dokumentiert, dass rigide Preisregulierungen langfristig unbeabsichtigte Effekte entfalten können: Investitionen in den Bestand und den Neubau sinken, das Angebot verknappt sich, und es entstehen Ineffizienzen in der Allokation von Wohnraum (Arnott,

*Die Autoren danken der FUB IGES Wohnen+Immobilien+Umwelt GmbH für die Bereitstellung der Datengrundlage sowie Oliver Strege und Thorsten Hühn für den hilfreichen fachlichen Austausch.

1995; Arnott, 2003; Autor et al., 2014; Diamond et al., 2019; Glaeser und Luttmer, 2003; Kholodilin, 2024; Wheaton, 1990). Wie im allgemeinen Teil A dieser Dissertation ausführlich dargestellt, verweisen einige dieser Arbeiten zugleich auf grundlegende Marktunvollkommenheiten, die staatliche Eingriffe theoretisch begründen.

Eine charakteristische Verzerrung tritt dort auf, wo Bestands- und Neuvertragsmieten dauerhaft divergieren, etwa infolge unterschiedlicher Regulierungsintensität in den beiden Segmenten: Bestandsmieter halten an günstigen und gesetzlich gesicherten Altverträgen fest und vermeiden den Wechsel in das teurere Neuvertragssegment, selbst wenn ihre Wohnsituation nicht mehr ihren Lebensumständen entspricht – der sogenannte Lock-in-Effekt. Wohnungen verbleiben so dort, wo sie historisch belegt wurden, statt dorthin zu wandern, wo aktueller Bedarf besteht (Glaeser und Luttmer, 2003); das Angebot für mobile Haushalte wie junge Familien oder Berufseinsteiger schrumpft entsprechend, sodass diese ihren Wohnraumbedarf nur erschwert decken können. Empirische Evidenz für diesen Effekt findet sich bei Mense et al. (2023) für den deutschen Markt: Sie dokumentieren, dass Mietregulierung die Ummobilität messbar reduziert, was sie als Zeichen regulierungsbedingter Misallokation werten. Im Zentrum der vorliegenden Studie steht die dem Lock-in-Effekt zugrundeliegende Preissegmentierung: ihre Quantifizierung, ihre Determinanten und mögliche Reformpfade.

Der deutsche Wohnungsmarkt bietet für diese Untersuchung einen besonders geeigneten Rahmen. Mit einer Wohneigentumsquote von lediglich 43,7% im Jahr 2023 weist Deutschland den höchsten Mieteranteil in der Europäischen Union auf (Statistisches Bundesamt, 2024a; Eurostat, 2024). So kommt der Mietregulierung in Deutschland eine bedeutende gesellschaftliche und ökonomische Bedeutung zu. Mieten in Deutschland sind dabei nicht einheitlich, sondern differenziert nach dem Status des Mietverhältnisses reguliert: In bestehenden regulären Mietverhältnissen werden Mieterhöhungen durch die Kappungsgrenze auf maximal 20%¹ innerhalb von drei Jahren begrenzt, wobei die ortsübliche Vergleichsmiete bei regulären Mietverhältnissen als Obergrenze für Mieterhöhungen fungiert. Bei Neuvermietungen begrenzt die Mietpreisbremse die Anfangsmieten in angespannten Märkten auf 110% der ortsüblichen Vergleichsmiete – ausgenommen sind etwa umfassend modernisierte oder nach 2014 errichtete Wohnungen.²

Gleichzeitig lässt sich empirisch eine zunehmende Polarisierung der Mietpreisentwicklung beobachten. Im letzten Jahrzehnt legten Neuvertragsmieten um rund 70% zu, während Preissteigerungen im Bestand im Rahmen allgemeiner Preissteigerungen verliefen (Bundesbank,

¹Bundesländer können diese in angespannten Märkten auf 15% reduzieren.

²Nach Abschluss der Datenanalyse dieser Arbeit hat der Gesetzgeber die Mietpreisbremse mit Wirkung vom 23. Juli 2025 bis zum 31. Dezember 2029 verlängert (BT-Drs. 21/322); die parallel diskutierte Verschärfung des Mietwucher-Tatbestands nach § 5 Wirtschaftsstrafgesetz wurde vom Bundestag am 6. November 2025 abgelehnt.

2023). Diese Divergenz nährt den Verdacht eines „geteilten Marktes“, der sich in zwei Gruppen aufspaltet: „Insider“, die von regulierungsbedingt stabilen und günstigen Bestandsverträgen profitieren, und „Outsider“, die als Wohnungssuchende mit den vollen, gestiegenen Marktpreisen im Neuvertragssegment konfrontiert sind. Eine derartige Kluft verstärkt den eingangs skizzierten Lock-in-Effekt: Sie verlangsamt die Marktflektuation und engt das Angebot für mobile Gruppen wie junge Familien oder Berufseinsteiger ein.

Trotz intensiver Debatten über die Wirksamkeit der Mietpreisregulierung fehlt bislang eine systematische, quantitative Analyse des tatsächlichen Ausmaßes, der regionalen Heterogenität und der ökonomischen Treiber dieser postulierten Segregation auf Städteebene. Diese Lücke ist für eine evidenzbasierte Politik kritisch: Ohne ein klares Bild dieser Divergenz können die realen Konsequenzen der Regulierung, etwa das Ausmaß der Lock-in-Effekte und die faktische Wirksamkeit der Mietpreisbremse im Verhältnis zum Bestandsmietenschutz, nicht bewertet werden. Es ist unklar, ob diese Kluft ein universelles Phänomen oder ein Problem spezifischer Metropolregionen darstellt und welche marktstrukturellen Faktoren sie abseits der Mietregulierung verstärken oder dämpfen. Genau hier setzt diese Studie an und leistet zwei Beiträge: Erstens quantifizieren wir das Ausmaß der Segregation. Hierfür analysieren wir die relativen Differenzen zwischen der ortsüblichen Vergleichsmiete, die durch Mietpiegelwerte die Bestandsmieten repräsentiert, und den Angebotsmieten, welche die Neuvertragsmieten als Näherungswert abbilden.³ Diese Untersuchung erfolgt für 107 deutsche Städte im Zeitraum der Jahre 2014 bis 2022. Zweitens identifizieren wir mithilfe einer räumlichen Panelregression die Determinanten dieser Divergenz. Methodisch quantifiziert unsere abhängige Variable – die relative Differenz – dabei implizit Auswirkungen der differenzierten Regulierung, indem sie die Wirkung der Neuvertragsregulierung ins Verhältnis zur Dämpfung der Bestandsmieten setzt. Die methodischen Herausforderungen dieser Operationalisierung adressieren wir durch ein mehrstufiges Harmonisierungsverfahren, das die Heterogenität der Datenrepräsentation für Bestands- und Neuvertragsmieten sowie die Beschränkung der Mietpiegel auf eine Musterwohnung berücksichtigt.

Der Rest der Studie ist wie folgt gegliedert. Abschnitt 2 stellt die rechtlichen Grundlagen der asymmetrischen Mietregulierung in Deutschland dar. Abschnitt 3 beschreibt die Datengrundlage und die Methodik, einschließlich der Harmonisierungsschritte und der Spezifikation des räumlichen Regressionsmodells. Abschnitt 4 präsentiert die Ergebnisse der deskriptiven Da-

³Die Annahme basiert auf geringer Verhandlungsmacht der Mieter in angespannten Marktumfeldern. Angebotspreisdaten zeigen laut Kholodilin et al. (2016) verlässliche Mietpreistrends; größere Abweichungen zu Transaktionspreisen in Märkten mit Nachfrageüberhang sind unwahrscheinlich: Empirische Evidenz aus Eigentumsmärkten bestätigt, dass in engen Märkten der Abstand zwischen Angebots- und Transaktionspreisen schrumpft (Anenberg und Bayer, 2013). Trotzdem überschätzen Angebotsmieten die abgeschlossenen Neuvertragsmieten tendenziell. Auch scheinen Unterschiede je nach Viermietertyp möglich. Da die öffentlich zugänglichen Portale hauptsächlich Anzeigen gewinnorientierter Vermieter zeigen, berücksichtigen wir den Anteil nicht rein gewinnorientierter Vermieter im Wohnungsbestand (vgl. Anhang A.1 II).

tenanalyse und der ökonometrischen Schätzung. Abschnitt 5 fasst die Ergebnisse zusammen, interpretiert sie im Kontext der herrschenden Mietpreisregulierung und zieht ein Fazit.

A.1.2 Rechtliche Grundlagen

Mietspiegel

Ein Mietspiegel, unabhängig ob einfach oder qualifiziert, ist eine Übersicht über die ortsübliche Vergleichsmiete für Wohnraum. Die Festlegung der ortsüblichen Vergleichsmiete wird im § 558 BGB Abs. 2 geregelt: „Die ortsübliche Vergleichsmiete wird gebildet aus den üblichen Entgelten, die (...) für Wohnraum vergleichbarer Art, Größe, Beschaffenheit und Lage einschließlich der energetischen Ausstattung und Beschaffenheit in den letzten sechs Jahren vereinbart oder geändert worden sind“. Neben den in § 558 BGB Abs. 2 genannten fünf Wohnwertmerkmalen ist insbesondere die Einschränkung der in den Mietspiegel einbezogenen Mieten entscheidend. Der Gesetzgeber hat hier eine Normierung der ortsüblichen Vergleichsmiete auf die Mieten, die in den letzten sechs Jahren neu vereinbart oder geändert worden sind, vorgenommen.

Gemäß § 558 BGB Abs. 1 sind qualifizierte Mietspiegel auf Basis anerkannter wissenschaftlicher Grundsätze zu erstellen. So muss die Auswertung auf Basis einer repräsentativen Datenerhebung erfolgen. Darüber hinaus muss ein qualifizierter Mietspiegel nach zwei Jahren fortgeschrieben und nach vier Jahren neu erstellt werden. Ein qualifizierter Mietspiegel kann sowohl durch die Kommune als auch durch die dazu berechtigten Vertreter der Interessenverbände der Mieter und Vermieter anerkannt werden. Erfüllt ein Mietspiegel diese Anforderungen nicht, gilt er als einfacher Mietspiegel. Ein einfacher Mietspiegel dient als Begründungsmittel für ein Mieterhöhungsverlangen, da hier keine besonderen Anforderungen gestellt werden. Seine Beweisfunktion vor Gericht ist allerdings eingeschränkt, da nur ein qualifizierter Mietspiegel die Vermutungswirkung besitzt (§ 558 d Abs. 3. BGB).

Mietpreisbegrenzung im Bestand

Die rechtliche Grundlage für Mieterhöhungsbegehren in laufenden Mietverhältnissen bilden §§ 557 bis 561 BGB. Mieterhöhungen sind zulässig als Anpassung an die ortsübliche Vergleichsmiete, nach Modernisierungsmaßnahmen und im Falle eines Staffel- oder Indexmietvertrags. Eine Mieterhöhung darf dabei nicht in beliebiger Häufigkeit oder in beliebiger Höhe erfolgen. Nach Mietvertragsabschluss ist eine Mieterhöhung frühestens nach Ablauf von zwölf Monaten durch den Vermieter anzukündigen. Die Frist bis zur tatsächlichen Mieterhöhung beläuft sich auf drei Monate, sodass frühestens 15 Monate nach Vertragsabschluss der Mietpreis angepasst werden kann. Ein erneutes Begehren zur Mietanpassung kann wiederum erst nach Ablauf weiterer zwölf Monate nach der letzten Mieterhöhung angekündigt werden. Weiterhin ist die Kappungsgrenze bei Mieterhöhungen einzuhalten. Durch § 558 Abs. 3 BGB

haben die Bundesländer die Möglichkeit erhalten, durch Rechtsverordnung die Kappungsgrenze bei der Anpassung von bestehenden Mietverträgen an die ortsübliche Vergleichsmiete auf 15% anstatt 20% innerhalb von drei Jahren zu begrenzen.⁴ Staffel- und Indexmietverträgen sind von den Kappungsgrenzen ausgenommen. Es ist lediglich vorgesehen, dass zwischen zwei Mieterhöhungen mindestens zwölf Monate liegen müssen.


Mietpreisbegrenzung bei Neuverträgen

Durch das Mietrechtsnovellierungsgesetz (§ 556d Abs. 2 BGB) erhielten die Bundesländer im Jahr 2015 die Möglichkeit, in Gebieten, in denen die ausreichende Versorgung der Bevölkerung mit Mietwohnungen zu angemessenen Bedingungen besonders gefährdet ist, die Miethöhe zu Beginn des Mietverhältnisses auf die ortsübliche Vergleichsmiete gemäß § 558 Abs. 2 BGB zuzüglich 10% zu begrenzen. Hier wird das Instrument Mietspiegel auf neu zu vereinbarende Mietverhältnisse angewendet. Mietpreisüberhöhungen bestehen, sofern die Miethöhe die ortsüblichen Vergleichsmiete um mehr als 20% überschreitet. Beträgt die Abweichung mehr als 50% liegt Mietwucher vor.

Die Regelung der Mietpreisbegrenzungsverordnung (§ 556 d BGB) wird durch Ausnahmetatbestände (§ 556 e, f. BGB) ergänzt. Diese umfassen die Höhe der Vormiete, Modernisierungen, umfassende Modernisierungen und Neubau: Lag die Höhe der Miete des Vermieters bereits vor Inkrafttreten der Mietpreisbegrenzungsverordnung mehr als 10% über der ortsüblichen Vergleichsmiete, gilt ein sogenannter Bestandsschutz. Nach § 556 e Abs. 1 BGB darf die Miete auch nach Einführung der Verordnung bei dem Wert der Vormiete belassen, nicht jedoch weiter angehoben werden. Wurde eine Bestandswohnung innerhalb der letzten drei Jahre vor Beginn des Mietverhältnisses im Sinne des § 555 b BGB modernisiert, so darf die Miete nach Einführung der Mietpreisbegrenzungsverordnung bis 10% oberhalb der ortsüblichen Vergleichsmiete liegen plus zusätzlich 8% der Modernisierungskosten. Hat ein Vermieter eine umfassende Modernisierung durchgeführt, gilt eine Mietpreisbegrenzungsverordnung gemäß § 556 f BGB für die Erstvermietung nicht. Bei Neuvermietungen wird die Verordnung jedoch angewendet: Die Mietpreisbegrenzungsverordnung nach § 556 d BGB ist ebenfalls nicht anzuwenden auf Neubau-Wohnungen, die nach dem 01.10.2014 erstmals genutzt oder vermietet werden.

⁴In der Praxis verlaufen die Gebietskulissen der abgesenkten Kappungsgrenze und der Mietpreisbremse weitgehend deckungsgleich. Eine aktuelle Zusammenstellung auf Basis der BBSR-Kartierung weist für 610 Gemeinden mit entsprechenden Verordnungen aus, davon 522 Gemeinden, in denen beide Instrumente gleichzeitig gelten (BBSR, [2025](#)).

Abbildung A.1: Flussdiagramm: Deutsche Mietpreisregulierung und ihre Ausnahmen



Eigene Darstellung. VGM bezeichnet die ortsübliche Vergleichsmiete.

Erkenntnisse für empirische Auswertungen

Zusammenfassend zeigt sich, dass Mietspiegel durch die beschriebene Regularien Bestands- und Neuvertragsmieten zu unterschiedlich Niveaus begrenzen. Die Schwellenwerte von 10%, 20% und 50% oberhalb von Mietspiegeln bilden bei Neuvertragsmieten relevante Schwellenwerte für unsere Analyse. Das Kapitel hat zudem einige Ausnahmen insbesondere bei der Begrenzung von Neuvertragsmieten aufgezeigt. Im folgenden Methodik-Abschnitt werden diese berücksichtigt, etwa werden nur Wohnungen mit Baujahr vor dem Jahr 2014 in der Regressionsanalyse berücksichtigt. Zudem wird im Methodik-Abschnitt aufgezeigt, dass unsere Analysedaten keine Kontrolle über Ausnahmen hinsichtlich Modernisierungen und Vormiete bei der Mietpreisbremse erlauben und lediglich über robuste Methodiken Ausreißer vermieden werden können. Trotz der Limitationen soll diese Arbeit wesentliche Entwicklungen hinsichtlich der Segmentation von Bestands- und Neuvertragsmieten aufzeigen, ohne ein exaktes Ausmaß in Bezug auf Mietpreisüberhöhungen oder -wucher treffen zu können.

A.1.3 Daten und Methodik

Angebots- und Mietspiegelmietdaten

Die Analyse basiert auf zwei Paneeldatensätzen, die Angebots- und Mietspiegelmieten für 107 Städte im Zeitraum der Jahre 2014 bis 2022 in Deutschland umfassen. Ziel der deskriptiven Datenanalyse ist die Berechnung einer repräsentativen und vergleichbaren Angebotsmiete für jede Stadt und jedes Jahr, um darauf aufbauend Differenzen zwischen Angebots- und Mietspiegelmieten zu bestimmen, die als Grundlage weiterer Analysen dienen.

Der Mietspiegeldatensatz umfasst ortsübliche Vergleichsmieten aller Städte mit veröffentlichtem Mietspiegel. Die Mietspiegeldaten basieren dabei immer auf derselben standardisierte 65-m²-Referenzwohnung mit mittlerer Ausstattung und Lage. Die Beschränkung auf eine einzige Musterwohnung pro Stadt folgt der Mietspiegel-Systematik: Erst die Standardisierung auf die Referenzwohnung erlaubt einen über die Heterogenität des realen Bestands hinweg vergleichbaren Wert und ist damit zwingende Voraussetzung für die Vergleichbarkeit von Mietspiegel- und Angebotsmietdaten. Für diese Musterwohnung wird die durchschnittliche ortsübliche Nettokaltmiete pro m² für folgende diskrete Baualtersklassen erhoben: 1905, 1925, 1955, 1965, 1975, 1985, 1995, 2005 und 2015 (vgl. Anhang A.1 [III](#)). Im Rahmen der Datenaufbereitung wird in Jahren ohne gültigen Mietspiegel vorrangig ein alter Wert anhand des Verbraucherpreisindex fortgeschrieben oder retropoliert. Eine Fortschreibung oder Retropolation findet dabei für maximal vier Jahre statt. Städte, die in mehr als vier aufeinanderfolgenden Jahren keinen gültigen Mietspiegel aufweisen, werden nicht betrachtet. Nach Bereinigung verbleiben 107 Städte, deren Mietspiegel ausgewertet wurden (vgl. Anhang A.1 [I](#)).

Die Daten der Angebotsmieten enthalten Inserate aus 687 verschiedenen Quellen. Der Großteil entstammt aus den überregionalen Anzeigenportalen “ImmoScout24”, “Immonet” und “Immo-Welt” (vgl. Anhang A.1 IV). Die Wohnungsinserate basieren auf Angaben von gewerblichen und privaten Vermietern beziehungsweise beauftragter Makler oder Immobilienverwaltungen. Der Datensatz umfasst die wesentlichen Stammdaten der inserierten Wohnung, etwaige Objektbeschreibung in Freitext sind nicht enthalten (vgl. Anhang A.1 IV). Der Datensatz wurde bereits durch FUB IGES GmbH aufbereitet. So wurden beispielsweise Duplikate auf mehreren Plattformen entfernt.

Beide Datenquellen unterscheiden sich systematisch: Mietspiegelmieten entstehen in einem politisch-administrativen Verfahren auf Basis der beschriebenen 65-m²-Referenzwohnung, Angebotsmieten dagegen auf heterogenen Online-Inseraten, die das Neuvertragssegment tendenziell überzeichnen. Wir adressieren diese Verzerrungen durch ein vierstufiges Harmonisierungsverfahren: (i) Filterung der Angebotsmieten auf strukturell vergleichbare Wohnungen, (ii) GAM-basierte Kontrolle nichtlinearer Effekte von Wohnfläche und Baujahr, (iii) identische Baujahresgewichtung über beide Datenquellen sowie (iv) relative Differenzbildung, die zeitkonstante stadtspezifische Niveauunterschiede eliminiert. Die folgenden Abschnitte detaillieren diese Schritte.

(i) Filterung der Angebotsmieten Aufbauend auf dem Konzept der Musterwohnung im Mietspiegeldatensatz wird der Angebotsdatensatz eingeschränkt. So werden Inserate, die betreutes oder gefördertes Wohnen, Erbpacht, Baujahre vor 1880 und nach 2022⁵ oder Wohnflächen unter 45 m² und über 85 m² beinhalten, nicht betrachtet. Um unplausible Miethöhen auszuschließen, werden Beobachtungen mit Mieten unter 2€ pro m² und über 40€ pro m² entfernt. Die Georeferenzierung geschieht anhand des amtlichen Gemeindeschlüssels, welcher die Zuordnung des Inserats in die Gemeinden sowie gemeindefreien Einzugsgebiete der betrachteten 107 Städte des Mietspiegeldatensatzes ermöglicht. So können Angebotsmieten pro m² analog zu den 65 m² großen Musterwohnungen der Mietspiegeldaten bestimmt werden.

(ii) GAM-basierte Bestimmung einer Angebotsmiete Konkret wurden zwei Methodiken zur Bestimmung der Angebotsmiete innerhalb einer Stadt-Jahr-Baujahresklasse angewendet. Im Median-Ansatz wird die mittlere Angebotsmiete pro m² der verbliebenen Inserate einer Stadt-Jahr-Baujahresklasse-Kombination gewählt. Im Regression-Ansatz wird für jede Stadt ein generalisiertes additives Modell (GAM) geschätzt, das die Angebotsmiete pro m² für die 65-m²-Musterwohnung über die neun Baujahresklassen modelliert und nichtlineare Zusammenhänge zwischen Wohnfläche, Baujahr und Mietpreis berücksichtigt. GAM sind seit Hastie und Tibshirani (1990) der Standard zur Modellierung nichtlinearer Beziehungen;

⁵Die deskriptive Analyse berücksichtigt Baujahre bis 2022, während in der Regressionsanalyse Baujahre nach 2014 ausgeschlossen werden, da Wohnungen mit Baujahr nach 2014 von der Mietpreisbremse ausgenommen sind, wir jedoch Mietpreisbremse als Prädiktor in der Regression nutzen.

wir verwenden penalisierte Spline-Glättung mit REML im `mgcv`-Framework (Wood, 2011). Eine strukturell vergleichbare Anwendung in der deutschsprachigen Mietpreis-Hedonik liefern Brunauer et al. (2010) mit additiven P-Spline-Modellen für Wiener Mietwohnungen, in denen Wohnfläche und Baujahr ebenfalls als Smooth-Funktionen modelliert werden. Die Validierung erfolgt über Residuendiagnostik und Inspektion der Glättungsfunktionen (vgl. Anhang A.1 VI). Um standortspezifische Zusammenhänge erklären zu können, wurde für jede Stadt ein eigenständiges GAM-Modell geschätzt. Das Modell wurde wie folgt spezifiziert:

$$y_{i,t} = \beta_0 + f_1(x_{1,i}) + f_1(x_{2,i}) + \sum_{t=2}^T \beta_{i1} D_t + \epsilon_{it} \quad (\text{A.1})$$

$y_{i,t}$ entspricht der Nettokaltmiete pro m² für die Stadt i und das Jahr t , $f_1(x_{1,i})$ und $f_1(x_{2,i})$ symbolisieren die glatten Funktionen des Baujahrs und der Wohnfläche. Die den Dummy-Variablen D_t zugehörigen Koeffizienten β_{i1} erfassen die standortspezifische allgemeine Mietsteigerung im Vergleich zum Basisjahr 2014. $\epsilon_{i,t}$ stellt die unabhängig und identisch verteilten Fehlerterme dar (vgl. Anhang A.1 VI). Die in den folgenden Abschnitten dargestellten Ergebnisse basieren auf dem GAM-Ansatz, jedoch sind hinsichtlich der Ergebnisse keine erheblichen Unterschiede zum Median-Ansatz erkennbar.

(iii) Gewichtung der Baujahresklassen

Um sowohl mietspiegel- als auch angebotsseitig aus den verschiedenen Nettokaltmieten der Musterwohnungen verschiedener Baujahresklassen jeweils eine Nettokaltmiete für jede Stadt-Jahr-Kombination zu bilden, wird ein gewichteter Durchschnitt anhand des Baujahresverteilung im Wohnungsbestand gebildet. Die Aggregation über Baualtersklassen erfolgt mit Bestandsgewichten aus der Gebäude- und Wohnungszählung (GWZ) des Zensus der Jahre 2011 und 2022. Da die Mieten im Zeitverlauf von 2014 bis 2022 betrachtet werden, wird die Häufigkeitsverteilung für jedes Jahr durch lineare Interpolation der Werte des Zensus 2011 und 2022 bestimmt.⁶

(iv) Relative Differenzen

Auf Basis der nun für jede Stadt und jedes Jahr vorliegenden Mietspiegel- und Angebotsmiete pro m² einer 65 m² Musterwohnung mit durchschnittlicher Ausstattung, Lage und Baujahr, wird nun die Entwicklung der Mietspiegelmieten als Proxy für Bestandsmieten und die Angebotsmieten als Proxy für Neuvertragsmieten verglichen. Konkret wird die Differenz dieser

⁶Die lineare Interpolation zwischen Zensus 2011/2022 Daten glättet zwar jährliche Neubau- und Abgangsschwankungen, ist aber aus folgenden Gründen vertretbar: (1) Baujahresstrukturen ändern sich nur träge, (2) jährliche Fertigstellungsstatistiken sind nicht für alle Städte konsistent verfügbar, (3) beide Mietspiegel- und Angebotsmietdaten werden identisch gewichtet, wodurch etwaige Interpolationsfehler die relative Differenz nicht systematisch verzerren und (4) für die Forschungsfrage ist die strukturelle Vergleichbarkeit wichtiger als die jährliche Präzision der Baujahresverteilung.

Mieten analysiert. Als Maß der Diskrepanz zwischen Angebots- und Mietspiegelmieten, welches einen Vergleich zwischen den jeweiligen Städten erlaubt, werden relative Differenzen wie folgt definiert:

$$RelativeDifferenz_{i,t} = \frac{AngMiete_{i,t} - MietspMiete_{i,t}}{MietspMiete_{i,t}} \quad (A.2)$$

Dieses Maß dient als Grundlage für die deskriptiven Datenanalyse sowie der Regressionsanalyse.⁷ Entsprechend der bereits diskutierten Mietwohnungsregulierung sollten die Angebotsmieten als Repräsentation für Neuvertragsmieten die Mietspiegelmieten im Mittel nicht deutlich über 10% übertreffen.

Eine asymmetrische Restverzerrung bleibt: Unser Bestandsmieten-Proxy überzeichnet das tatsächlich gezahlte Niveau leicht, da Kappungsgrenzen Anpassungen an die Vergleichsmiete verzögern; Angebotsmieten überschätzen die realisierten Neuvertragsmieten geringfügig (vgl. Anhang A.1 II), insbesondere in weniger angespannten Märkten (Boeing et al., 2020; Anenberg und Bayer, 2013). Beide Verzerrungen wirken gleichgerichtet im Zähler wie im Nenner, wodurch die berechneten relativen Differenzen ein belastbares Maß der Marktdivergenz darstellen.

Trotz der dargestellten Harmonisierung können einzelne mietrechtlich relevante Parameter – Vormiete, Modernisierungszustand und exakte Mikrolage – mit den verfügbaren Daten nicht kontrolliert werden.⁸ Diese Analyse erhebt daher keinen Anspruch auf mietrechtliche Bewertung möglicher Verstöße; sie zielt auf die Identifikation robuster Markttendenzen ab, wobei persistente hohe Differenzen (>20%) strukturelle Divergenzen zwischen Neuvertrags- und Bestandssegment indizieren, die über zufällige Schwankungen oder Datenunschärfen hinausgehen.

⁷Wie in Abschnitt A.1.2 erläutert, bilden Mietspiegelmieten in regulären Mietverhältnissen die rechtlich zulässige Obergrenze im Bestand (§ 558 Abs. 1–3 BGB). Da Kappungsgrenzen die Anpassung an diese Obergrenze in der Praxis verzögern, liegen die tatsächlich gezahlten Mieten faktisch darunter.

⁸Diese Limitationen sind in der Verwendung öffentlich verfügbarer Daten begründet. Eine vollständige Kontrolle würde Zugang zu individuellen Mietverträgen inklusive Vormietinformationen und detaillierten Modernisierungshistorien erfordern, was für ein Panel von 107 Städten über neun Jahre nicht realisierbar ist.

Regressionsanalyse

In einem zweiten Schritt wird untersucht, welche Faktoren relative Differenzen determinieren. Ein Fokus liegt auf dem möglichen Erklärungsgehalt der Mietpreisbremse (MPB), die als Dummy-Variable kodiert wird. Diese Variable nimmt den Wert 1 an, wenn in der jeweiligen Stadt zum jeweiligen Zeitpunkt eine gültige Mietpreisbremsenverordnung in Kraft war, andernfalls 0.⁹ Die Wahl einer MPB-Dummy-Variable statt einer Kappungsgrenzen-Dummy-Variable folgt der identifikationsrelevanten Zeitvariation: In unserer städtisch geprägten Stichprobe zeigt allein die Mietpreisbremse geringfügige zeitliche und räumliche Änderungen, während die Kappungsgrenze bei regulären Mietverhältnissen flächendeckend gilt. Die empirisch relevante Variation der Kappungsgrenze beschränkt sich de facto auf die Unterscheidung zwischen regulärer (20%) und abgesenkter Grenze (15%), was in einem Zwei-Wege-Fixed-Effects-Modell mit Stadt- und Jahr-Effekten sowie in räumlichen Spezifikationen wegen starker Kollinearität mit dem MPB-Status keinen zusätzlichen Identifikationsgewinn ermöglicht (BBSR, 2025).¹⁰

Da angenommen wird, dass sich benachbarte Städte gegenseitig beeinflussen und eine mangelnde Modellierung räumlicher Abhängigkeiten Resultate verzerren könnte, werden räumliche Regressionsmodelle aufgestellt. Die Basis dieser Modelle bildet die Nachbarschaftsmatrix W in den Dimensionen $N \times N$. Das Nachbarschaftsgewicht basiert dabei auf inversen geographischen Distanzen der Stadtzentren:

$$w_{ij} = \begin{cases} \frac{1/d_{ij}}{\sum_{k \neq i} 1/d_{ik}} & \text{für } i \neq j \\ 0 & \text{für } i = j \end{cases} \quad (\text{A.3})$$

So ist das Element $w_{i,j}$ der Matrix W der paarweise, räumliche Gewichtungsfaktor zwischen Stadt i und Stadt j . Dabei sind alle Elemente $w_{i,j} \geq 0$. Diese Spezifikation gewichtet nähere Städte stärker als entfernte und erfasst damit die abnehmende Intensität räumlicher Interaktionen mit zunehmender Distanz.

⁹Die Kodierung erfolgt jahrgenau basierend auf den tatsächlichen Inkrafttretens- und Auslaufdaten der jeweiligen Landesverordnungen. Verschärfungen der Regulierung (etwa die Auskunftspflicht im Jahre 2019) werden nicht separat modelliert, da sie bundesweit einheitlich erfolgten und somit durch die Zeiteffekte γ_t erfasst werden. Ankündigungseffekte würden zu einer Unterschätzung des tatsächlichen Mietpreisbremsen-Effekts führen, da Vorzieheffekte die Differenzen vor Inkrafttreten erhöhen würden. Daher analysieren wir temporale Effekte der Mietpreisbremse ebenfalls.

¹⁰Für Kausal- und Wirkungstests wird Variation im Zeit-Querschnitt unserer Stichprobe benötigt. Die MPB liefert gestaffelte Einführungen, Verlängerungen und punktuelle Änderungen; demgegenüber ist die abgesenkte Kappungsgrenze in den betrachteten Räumen meist im Gleichlauf mit der MPB ausgewiesen. Wo Kappungsgrenzen-Variation existiert, beschränkt sie sich auf 15% statt 20% (§ 558 Abs. 3 BGB). Wegen paralleler Ausweisungen und starker Überlappung kollinear zu MPB-Status (BBSR, 2025) und Fixed-Effects in unsere Modell ermöglicht eine Kappungsgrenze-Dummy-Variable keinen eigenständigen Inferenzgewinn. In unserer Zielgröße – der relativen Differenz von Neuvertrags- (Angebots-) zu Bestandsmieten (Mietspiegel) – ist die Mietpreisbremse außerdem der marginal relevante Eingriff (Neuvertragsseite), während die Kappungsgrenze die Vergleichsbasis (Bestand) strukturell dämpft und bereits träge in den Mietspiegel und daher implizit in unsere Analyse einsickert.

Als räumlicher Regressionsansatz wird hier ein SARAR-Modell (Spatial Autoregressive with Spatial Autoregressive Error) angewendet, welches räumliche Abhängigkeiten sowohl in der abhängigen Variable als auch im Fehlerterm berücksichtigt

$$y_{it} = \lambda \sum_{j=1}^N w_{ij} y_{jt} + X_{it} \beta + \mu_i + \gamma_t + u_{it}, \quad (\text{A.4})$$

wobei der Fehlerterm u_{it} selbst räumliche Autokorrelation aufweist:

$$u_{it} = \rho \sum_{j=1}^N w_{ij} u_{jt} + \varepsilon_{it} \quad (\text{A.5})$$

Dabei bezeichnet y_{it} die relative Differenz zwischen Angebots- und Mietspiegelmieten für Stadt i im Jahr t , X_{it} die Matrix der erklärenden Variablen, β den Vektor der zu schätzenden Koeffizienten, λ den räumlichen Autokorrelationsparameter der abhängigen Variable, ρ den räumlichen Autokorrelationsparameter des Fehlerterms, $W = [w_{ij}]$ die räumliche Gewichtungsmatrix, μ_i stadtspezifische fixe Effekte, γ_t zeitspezifische fixe Effekte und ε_{it} den idiosynkratischen Fehlerterm. Neben der Dummy-Variable “Mietpreisbremse” werden in X_{it} eine Reihe standortspezifischer Zeitreihen mit demographischen und wirtschaftlichen Kennzahlen als Kontrollvariablen hinzugefügt (vgl. Anhang A.1 VIII für eine Auflistung der Variablen und Quellen). Die Schätzung erfolgt mittels Maximum-Likelihood nach Vornahme einer Within-Transformation zur Elimination der fixen Effekte. Die Log-Likelihood-Funktion lautet:

$$\ln L = -\frac{NT}{2} \ln(2\pi\sigma^2) + T \ln |I_N - \lambda W| + T \ln |I_N - \rho W| - \frac{1}{2\sigma^2} e' e \quad (\text{A.6})$$

mit $e = (I_T \otimes (I_N - \rho W)) [(I_T \otimes (I_N - \lambda W)) y - X\beta]$ und $\otimes$ als Kronecker-Produkt.

Das SARAR-Modell eignet sich, wenn sowohl direkte Spillover-Effekte über die abhängige Variable, als auch unspezifischere räumliche Autokorrelation, etwa über die Kontrollvariablen oder unbeobachtete räumliche Abhängigkeiten, zu vermuten sind. Im Kontext von Mietpreisdifferenzen sind beide räumliche Komponenten fundiert: Direkte Spillover-Effekte auf Mietwohnungsmärkten (λ) entstehen durch Migrationsströme und Verdrängungseffekte: Steigen die Neuvertragsmieten in einer Stadt überproportional, weichen Mieter vermehrt auf benachbarte Kommunen aus und verstärken dort die Mietdynamik (Mense et al., 2023). Die räumliche Fehlerkorrelation (ρ) erfasst unbeobachtete regionale Faktoren wie gemeinsame Arbeitsmarkregionen, ähnliche Wirtschaftsstrukturen oder koordinierte Investorenstrategien, die zu synchronen Marktentwicklungen führen ohne direkte Spillover (Elhorst, 2010; LeSage, 2014; Otto und Schmid, 2018). Diese Dualität räumlicher Abhängigkeiten erfordert die Modellierung beider Komponenten für eine unverzerrte Inferenz.

A.1.4 Ergebnisse

Differenzen zwischen Angebots- und Mietspiegelmieten


Bevor die Entwicklung der relativen Differenzen näher betrachtet wird, werden zunächst die absoluten Mietpreisentwicklungen analysiert. Bei der nach Einwohnern gewichteten Gesamtbetrachtung aller 107 Städte¹¹ zeigt sich, dass die Angebotsmiete in Deutschland von 7,90€ pro m² im Jahr 2014 um 3,10€ auf 11,00€ pro m² im Jahr 2022 steigen konnte. Im selben Zeitraum stieg die durchschnittliche Mietspiegelmiete bevölkerungsgewichtet von 6,50€ pro m² um nur 1,85€ auf 8,35€ pro m². Folglich stieg die absolute Diskrepanz zwischen Mietspiegel- und Angebotsmieten ($AngMiete_{i,t} - MietspMiete_{i,t}$) im betrachteten Zeitraum an. Wie in Abbildung A.2 zu erkennen, ist dieses Phänomen in den sechs bevölkerungsreichsten Städten (Top 6¹² deutlich ausgeprägter als in kleineren Groß- und Mittelstädten¹³ (vgl. Anhang A.1 I für Definitionen der Stadtkategorien und einer Auflistung aller Städte inklusive ihrer Zuordnung). Während die Kategorisierung in drei Gruppen eine strukturierte und übersichtliche Analyse der Mietpreisentwicklung ermöglicht und systematische Unterschiede zwischen den Städtetypen offenlegt, verbirgt sich dahinter dennoch Heterogenität innerhalb der jeweiligen Kategorien, wobei insbesondere die Großstädte mit einem Variationskoeffizienten von 0,21 die höchste interne Streuung aufweisen – für eine Darstellung der Verteilungen innerhalb der Städtekategorien siehe Anhang A.1 V.

¹¹Hier werden alle Baujahreskategorien inklusive 2015 betrachtet. Vgl. Anhang A.1 V für deskriptive Statistiken der Angebotsmieten-Datengrundlage der Regression, in der zusätzlich auf 73 Städte gefiltert wurde und alle Baujahre nach 2014 ausgeschlossen wurden.

¹²Düsseldorf wurde ausgeschlossen, da die dortigen Mietspiegelwerte aus technischen Gründen nicht vollständig in unser harmonisiertes Datenschema überführt werden konnten.


¹³Innerhalb der Stadtkategorien werden ebenfalls bevölkerungsgewichtete Durchschnitte gebildet.

Abbildung A.2: Absolute Differenzen im Zeitverlauf nach Stadtkategorie (€/m²)



Eigene Berechnung und Darstellung (basierend auf FUB-IGES Daten).

Abbildung A.3: Relative Differenzen im Zeitverlauf nach Stadtkategorie




Eigene Berechnung und Darstellung (basierend auf FUB-IGES Daten).

Die Unterschiede in den Stadtkategorien in Abbildung A.2 sind allerdings nur bedingt interpretierbar, schließlich könnten die absoluten Differenzen in teureren Großstädten strukturell größer sein, weil das absolute Mietpreinsniveau höher ausfällt. Daher wird nun das vergleichbare Maß der relativen Differenzen analysiert ($\frac{AngMiete_{i,t} - MietspMiete_{i,t}}{MietspMiete_{i,t}}$). Die in Abbildung A.3 dargestellten relativen Differenzen zeigen, dass die Abweichungen im Verhältnis zu den Mietspiegelmieten in den bevölkerungsreichsten Städten deutlich stärker ausfallen als in kleineren

Groß- und Mittelstädten. Während im Zeitraum von 2014 bis 2020 die relativen Mietpreisdifferenzen in allen Stadtkategorien noch steigen, stabilisiert sich der Trend ab 2020 auf hohem Niveau. Verantwortlich für den starken Anstieg sind die stark ansteigenden Angebotsmieten im Zeitraum der Jahre 2014 bis 2020 während gleichzeitig die Mietspiegelmieten mit einer Verzögerung von einigen Jahren steigen, da diese aus Mieten des 6-Jahres-Zeitraums davor gebildet werden und sich somit starke Entwicklungen erst zeitlich versetzt abbilden. Ab dem Jahr 2020 schlagen die Preissteigerungen der Jahre 2014-2020 verzögert auf die Mietspiegel durch, während sich das Wachstum der Angebotsmieten gleichzeitig abschwächt – ein temporärer Konvergenzeffekt, der die strukturelle Divergenz jedoch nicht aufhebt. Festzuhalten bleibt, dass die relativen Differenzen in den Top 6 mit durchgehend 30 bis 50% um 20 bis 40 Prozentpunkte über der durch die Mietwohnungsregulierung gesetzten Schwelle von 10% liegt, während die Differenzen in kleineren Groß- und Mittelstädten mit 10 bis 20% im Rahmen erscheinen. Wie bereits im Methodik-Teil erwähnt, können diese hohen relativen Differenzen tendenziell auf mögliche Missachtungen der Mietpreisbremse hindeuten, jedoch soll aufgrund der Limitationen der Methodik im Hinblick auf die Ausnahmetatbestände bei der Mietpreisbremse kein konkretes Ausmaß der Missachtung abgeleitet werden.

Um die Heterogenität innerhalb der städtischen Angebotsmärkte zu analysieren, wechselt Abbildung A.4 von der bisher verwendeten aggregierten Betrachtungsebene (ein GAM-geschätzter Wert pro Stadt-Jahr-Baujahresklasse) auf die Mikroebene einzelner Wohnungsinserate. Die Boxplots zeigen die Verteilung der relativen Differenzen zwischen individuellen Angebotsmietinseraten und der jeweiligen Mietspiegelmiete für vergleichbare Musterwohnungen im Jahr 2020 nach Stadtkategorien.

Abbildung A.4: Verteilung relativer Differenzen nach Stadtkategorie (2020), Inseratsebene




Eigene Berechnung und Darstellung (basierend auf FUB-IGES Daten).

Diese disaggregierte Analyse offenbart eine sichtbare Marktstreuung: In den sechs bevölkerungsreichsten Städten liegt bereits das 25%-Quantil bei etwa 25% über der Mietspiegelmiete. Diese persistente Überschreitung auch im unteren Quartil der Verteilung indiziert systematische Marktverzerrungen, da Qualitätsunterschiede allein diese breite Überschreitung kaum erklären können. Der Median relativer Differenzen von circa 40% und das 75%-Quantil bei über 55% unterstreichen die Entkopplung des Neuvertragssegments. In kleineren Städten zeigt sich mit einem Median um 20% und einem 25%-Quantil nahe null eine moderatere Diskrepanz. Die Streuung innerhalb der Städte mit Interquartilsabständen von 30-40 Prozentpunkten verdeutlicht die Heterogenität auf Inseratsebene im Angebotsmarkt.¹⁴

Durch die Erhebung der Angebots- und Mietspiegelmieten nach Baujahresklasse ist eine individuelle Betrachtung der relativen Differenzen nach Baujahresklasse möglich. Abbildung A.5 zeigt dabei die gesamtdeutsche (bevölkerungsgewichteten), relativen Differenzen nach Baujahr als Zeitdurchschnitt. Abbildung A.6 differenziert zusätzlich anhand der Städtekategorien. Bei Betrachtung des Medians der relativen Differenzen in Deutschland zwischen den Jahren 2014 und 2022 wird deutlich, dass frühere Baujahre und besonders junge Einheiten höhere Differenzen aufweisen. Das Baujahr 1995 hat dabei im Durchschnitt die geringsten relativen Differenzen, während das Baujahr 1905 die größten Differenzen aufweist. Die U-förmige Beziehung zwischen Baujahr und relativen Differenzen reflektiert mögliche Bewertungslücken: Altbauten profitieren von zentralen Lagen und Qualitätsmerkmalen, die Mietspiegel tendenziell untererfassen; bei Neubauten kumulieren Verzögerungen in der Mietspiegelanpassung mit der vollständigen Ausnahme von Baujahren nach 2014 aus der Mietpreisbremse. Dass Wohnungsbestände über den Lebenszyklus nichtlinear bewertet werden, wird durch die Alterseffekte in einem “Hierarchical Trend Model” von Francke und Vos (2004) gestützt, das U-förmigen Preisprofile modelliert. Die höhere Spreizung der Differenzen in regulierungsintensiven Segmenten, einschließlich jüngerer Baualter, zeigen zudem mögliche verzerrende Regulierungswirkungen (Kholodilin, 2024). Ein ähnliches Bild ergibt sich in Abbildung A.6: konsistent mit vorherigen Abbildungen fallen die relativen Differenzen in den sechs bevölkerungsreichsten Städten wie erwartet höher aus.


¹⁴Die Aggregation nach Stadtgrößenklassen folgt der in der Wohnungsmarktbeobachtung etablierten Konvention (vgl. zum Beispiel BBSR, 2021) und dient allein der Veranschaulichung; Boxplots und Anhang A.1 V zeigen die interne Streuung der Kategorien. Die Regressionsanalyse in Abschnitt 4.2 arbeitet auf Städte-Jahrebene ohne Kategorie-Mittelung, sodass die Heterogenität innerhalb der Stadtkategorien die Determinantenschätzungen nicht verzerrt.

Abbildung A.5: Relative Differenzen nach Baujahr (Durchschnitt 2014-2022), GAM-gewichtete Städte-Ebene



Eigene Berechnung und Darstellung (basierend auf FUB-IGES Daten).

Abbildung A.6: Relative Differenzen nach Baujahr und Städtekatgorie (Durchschnitt 2014-2022), Inseratsebene der Angebotsdaten



Eigene Berechnung und Darstellung (basierend auf FUB-IGES Daten).

Regressionsanalyse

In diesem Kapitel werden die Ergebnisse der Regressionsanalyse präsentiert. Als Grundlage dienen die relativen Differenzen $y_{i,t}$ der Städte $i = 1, \dots, N$. Für die Regressionsanalyse werden nur Wohnungen mit Baujahr bis 2014 betrachtet, da in den Folgejahren errichtete Wohnungen von der Mietpreisbremse ausgenommen sind. Zudem wurden Städte, die angebotsseitig weniger als fünf gefilterte Inserate in jeder Jahr-Baujahresklasse-Kombination aufweisen, entfernt, um Verzerrungen vorzubeugen. So verbleiben 73 Städte in der Stichprobe. Im Zeitraum von 2014 bis 2022 weist das Paneel somit 657 Beobachtungen auf.¹⁵

Tabelle A.1 präsentiert drei Modellspezifikationen: (1) das SARAR Basismodell mit einem Maximum-Likelihood-Schätzer¹⁶ wie im Methodik-Abschnitt A.1.3 beschrieben, (2) Modell (1) mit heteroskedastie-robusten Standardfehlern, und (3) Modell (2) mit standardisierten Koeffizienten zur besseren Vergleichbarkeit der Effektstärken. Die robusten Standardfehler adressieren Verzerrungen durch heteroskedastische Fehlerterme, die in unseren Daten auftreten (vgl. Anhang A.1 IX für weitere Validierungstests und deskriptive Statistik). Vor der Interpretation der Koeffizienten prüfen wir, ob die berichteten Effekte durch Multikollinearität zwischen den ökonomisch eng verwandten Kontrollvariablen (Bruttolohn, Bevölkerungsdichte, Arbeitslosenquote, Durchschnittsalter) verzerrt sein könnten. Die Multikollinearitätsdiagnostik in Anhang A.1 IX zeigt Variance-Inflation-Factors zwischen 1,30 und 2,19 (Maximum: Bruttolohn mit $VIF = 2,19$; vgl. Tabelle An.10), deutlich unter dem konventionellen Schwellenwert von 5 (Baltagi, 2021); die paarweisen Korrelationen $|r|$ zwischen den ökonomischen und demografischen Regressoren bleiben in allen Fällen unter 0,7. Die Identifikation der einzelnen Koeffizienten ist damit nicht durch Quasi-Kollinearität gefährdet. Es wurden verschiedene Kombinationen aus erklärenden Variablen getestet und die am besten getesteten Regressionsspezifikationen abgebildet.¹⁷ Da die Regressoren auf unterschiedlichen Skalen variieren, basiert die folgende Effektstärken-Diskussion primär auf den standardisierten Koeffizienten in Spalte (3) der Tabelle.

¹⁵Diese Inseratsfilterung wird in der Regressionsanalyse gewählt, da GAM-Schätzungen für Stadt-Jahr-Baujahres-Zellen mit sehr wenigen Inseraten die identifizierende Variation der abhängigen Variable verzerren könnten. Im deskriptiven Teil wird die vollständige Stichprobe der 107 Städte beibehalten, da die deskriptive Erfassung deutscher Wohnungsmärkte einen eigenständigen Beitrag dieser Arbeit darstellt.

¹⁶Da in räumlichen Modellen Beobachtungen nicht unabhängig sind, würde eine OLS-Schätzung aufgrund der räumlichen Korrelation zu verzerrten und inkonsistenten Regressionskoeffizienten sowie invalider Inferenz führen. Im Gegensatz dazu berücksichtigt die Maximum-Likelihood-Methode diese Abhängigkeiten explizit, indem sie die Parameter so bestimmt, dass die beobachteten Daten unter der angenommenen räumlichen Struktur am wahrscheinlichsten sind.

¹⁷Die Mietspiegelqualität (einfach vs. qualifiziert) wurde trotz theoretischer Relevanz nicht als Kontrollvariable aufgenommen, da sie mit der Bevölkerungsdichte korreliert und somit Multikollinearitätsprobleme verursacht. Anzumerken ist jedoch, dass beide Mietspiegeltypen rechtlich bindende ortsübliche Vergleichsmieten darstellen (§ 558 BGB) und sich primär in ihrer Beweiskraft vor Gericht, nicht aber in ihrer regulatorischen Gültigkeit unterscheiden. Eine systematische Verzerrung der relevanten, tatsächlichen relativen Differenzen durch Mietspiegelqualität ist daher nicht zu erwarten – einfache Mietspiegel bilden die tatsächlich geltenden und damit marktrelevanten Referenzwerte ab, unabhängig von ihrer methodischen Sophistikation.

Tabelle A.1: SARAR-Modell: Determinanten der relativen Differenzen

	(1) SARAR	(2) SARAR Robust	(3) Standardisiert
	Koeffizient	Koeffizient	Std. Koeffizient
Mietpreisbremse	-0,0037 (0,0072)	-0,0037 (0,0049)	-0,077 (0,102)
Einwohner pro km ²	0,0003*** (0,00009)	0,0003*** (0,000003)	0,154*** (0,001)
Baufertigstellungen (Fläche)	-0,2943 (1,0395)	-0,2943 (0,6867)	-0,01 (0,024)
Bruttolohn	0,00002*** (0,0000032)	0,00002*** (0,0000005)	0,191*** (0,007)
Durchschnittsalter	-0,0167 (0,0111)	-0,0167*** (0,0005)	-0,061*** (0,002)
Arbeitslosenquote	0,9298 (0,7439)	0,9298*** (0,1912)	0,049*** (0,01)
Nicht-gewinnorientiert	-0,2987* (0,1419)	-0,2987*** (0,0235)	-0,075*** (0,006)
λ (Räumlicher Lag)	0,477 ^a (0,291)	0,477*** (0,134)	—
ρ (Räumlicher Fehler)	0,163 (0,376)	0,163 (0,173)	—
Beobachtungen	657	657	657

Die abhängige Variable ist die relative Differenz zwischen Angebots- und Mietspiegelmieten.

Spalte (1) berichtet Maximum-Likelihood-Schätzungen des SARAR-Modells mit modellbasierten Standardfehlern. Spalte (2) zeigt eine Näherung heteroskedastie-robuster Standardfehler. Da für das ML-geschätzte SARAR-Modell keine standardisierten robusten SEs im R-Paket “splm” verfügbar sind, wurden sie anhand einer White/Sandwich-Varianzmatrix vom OLS-Typ unter Verwendung der ML-Residuen konstruiert (Kelejian und Prucha, 2007; Drukker et al., 2013). Spalte (3) zeigt standardisierte Koeffizienten: $\beta = b \cdot (SD_X / SD_Y)$ für kontinuierliche Variablen, $\beta = b / SD_Y$ für Dummy-Variablen.

Signifikanzniveaus: *** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$, ^a $p < 0,10$.

Modell enthält Stadt- und Jahr-Fixed-Effects (Within-Transformation).

Räumliche Abhängigkeitsstrukturen Die geschätzten räumlichen Parameter deuten auf das Vorliegen räumlicher Abhängigkeiten hin. Der räumliche Lag-Parameter $\lambda = 0,477$ weist zunächst eine leichte Signifikanz ($p < 0,10$), die unter Verwendung der robusten Standardfehler auf einen hochsignifikanten, substantiellen Zusammenhang zwischen benachbarten Märkten hin: Ein Anstieg der relativen Differenzen in einer Stadt geht tendenziell mit einem Anstieg von rund 48% dieses Effekts in den gewichtet benachbarten Städten einher. Der räumliche Fehlerparameter $\rho = 0,163$ zeigt hingegen keinen klaren Hinweis auf signifikante

räumliche Korrelationen in den unbeobachteten Störgrößen.

Sozioökonomische Determinanten Die Ergebnisse zeigen, dass primär demographische und wirtschaftliche Faktoren die Variation der relativen Differenzen erklären. Das **Bruttolohnniveau** pro Erwerbstätigem ist der ökonomisch stärkste Treiber im Modell ($\beta_{std} = 0,191$); ein Anstieg des durchschnittlichen jährlichen Bruttolohns um 1.000€ erhöht die relative Differenz um 2 Prozentpunkte. Dies reflektiert die höhere Zahlungsbereitschaft in prosperierenden Städten auf der Nachfrageseite: Angebotsmieten reagieren schnell auf Einkommenssteigerungen, während die regulierungsbedingt träger angepassten Mietspiegelwerte hinterherlaufen.

Die **Bevölkerungsdichte** ist mit $\beta = 0,0003$ ($\beta_{std} = 0,154$) der zweitstärkste Treiber. Eine Erhöhung um 1.000 Einwohner pro km² geht mit einem Anstieg der relativen Differenz um 0,3 Prozentpunkte einher; der Rohkoeffizient wirkt klein, der standardisierte Effekt ist jedoch ökonomisch substanziell, da die Variable in der Stichprobe breit streut. Inhaltlich erfasst die Bevölkerungsdichte einen Agglomerationseffekt mit Knappheitsdruck: Höhere Nachfrageintensität in verdichteten Räumen trifft auf raumgebundenes und kurzfristig unelastisches Wohnraumangebot, was Neuvertragsmieten relativ zu regulierten Bestandsmieten nach oben treibt. Bruttolohn und Bevölkerungsdichte sind damit ökonomisch komplementär – sie greifen über unterschiedliche Kanäle (Zahlungsfähigkeit auf der Nachfrageseite, Knappheit im Markt) und liefern beide eigenständige Erklärungsbeiträge zur Mietpreisdivergenz.

Das **Durchschnittsalter** wirkt dämpfend auf die Mietpreisdifferenz ($\beta = -0,0167$; $\beta_{std} = -0,061$). Der standardisierte Effekt ist deutlich kleiner als jener der wirtschaftlich-demografischen Hauptfaktoren, aber ökonomisch nachvollziehbar: Ein um ein Jahr höheres Durchschnittsalter reduziert die Differenz um 1,7 Prozentpunkte; ältere Bevölkerungsstrukturen sind mit geringerer Wohnungsmobilität und damit stabileren Mietverhältnissen assoziiert, was zu kleineren Divergenzen zwischen Neuvertrags- und Bestandsmarkt führt. Zudem entstehen ältere Bevölkerungsstrukturen häufig durch die Abwanderung junger, qualifizierter Arbeitskräfte in prosperierende Regionen mit attraktiveren Beschäftigungsmöglichkeiten. Diese selektive Migration führt zu einer doppelten Dämpfung der Mietpreisdifferenzen: Einerseits reduziert sich die Nachfrage durch den Wegzug kaufkräftiger junger Haushalte, andererseits verbleibt eine weniger mobile Bevölkerung mit längeren Mietvertragsdauern und geringerer Umzugsneigung. Der Alterseffekt absorbiert somit teilweise Konsequenzen wirtschaftlicher Strukturschwäche, die über die bereits kontrollierten ökonomischen Variablen hinausgehen – was die negative Korrelation zwischen Durchschnittsalter und Bruttolohn in unserer Stichprobe stützt.

Die **Arbeitslosenquote** zeigt nach Anwendung robuster Standardfehler einen positiven Effekt, der in standardisierten Größen jedoch klein ausfällt ($\beta = 0,93$; $\beta_{std} = 0,049$). Trotz der geringen Effektgröße ist das positive Vorzeichen erklärungsbedürftig: Da bereits für wirt-

schaftliche Prosperität kontrolliert wird, kann der Koeffizient plausibel auf den Mechanismus staatlicher Transferleistungen im Mietmarkt zurückgeführt werden. Die vollständige Übernahme der Kosten der Unterkunft (KdU) für Transferempfänger generiert eine preisunelastische staatliche Nachfrage im Neuvertragssegment (Holm, 2011; Jacobs et al., 2010). Im Gegensatz zu erwerbstätigen Haushalten, die bei steigenden Mieten ihre Umzugsmobilität reduzieren, garantiert die KdU-Übernahme eine konstante zahlungskräftige Nachfrage bis zu den kommunal festgesetzten Angemessenheitsgrenzen. Diese Richtwerte fungieren implizit als Preissignal für Vermieter und werden regelmäßig an Marktentwicklungen angepasst, wodurch sie eine “erhebliche Steuerungswirkung auf die Wohnungsmärkte” (Jacobs et al., 2010) ausüben. Die resultierende Wettbewerbsverzerrung zwischen staatlich unterstützten und regulären Niedrigeinkommenshaushalten verstärkt die Preisdynamik im unteren Neuvertragssegment. Der positive Koeffizient reflektiert somit nicht die Arbeitslosigkeit per se, sondern den durch staatliche Intervention induzierten Nachfrageeffekt, der die Differenz zwischen Angebots- und Bestandsmieten verstärkt.

Angebotsseitige Faktoren Die **Baufertigstellungen als Flächenanteil** zeigen keinen signifikanten Effekt ($\beta = -0,29$, $SE = 0,69$). Die fehlende Signifikanz könnte auf gegenläufige Kräfte zurückzuführen sein: Einerseits signalisieren hohe Fertigstellungsraten attraktive Märkte mit entsprechend hohen Differenzen, andererseits wirkt das zusätzliche Angebot preisdämpfend. Der Anteil **nicht-gewinnorientierter Vermieter** reduziert die Mietpreisdifferenz signifikant ($\beta = -0,30$; $\beta_{std} = -0,075$): in standardisierter Größe moderat, in praktischer Größenordnung jedoch deutlich, da ein um 10 Prozentpunkte höherer Anteil die Differenz um 3 Prozentpunkte dämpft. Dieser Effekt entspringt der unterschiedlichen Geschäftslogik der Vermietergruppen: Während private Vermieter Maximalmieten erzielen möchten, orientieren sich kommunale Wohnungsunternehmen und Genossenschaften stärker an Kostendeckung und sozialen Zielsetzungen, die oftmals politisch vorgegeben und teils subventioniert sind. Diese preisdämpfende Wirkung strahlt über Referenzeffekte auch auf den privaten Mietmarkt aus: Ein substantieller Bestand an gemeinnützigen Wohnungen erhöht den Wettbewerbsdruck auf private Vermieter.

Die Mietpreisbremse: Kontemporäre und temporale Effekte Im Hauptmodell weist die Mietpreisbremse einen negativen, aber insignifikanten Koeffizienten auf ($\beta = -0,0037$, robust $SE = 0,0049$). Aus statistischer Sicht hat das Vorhandensein einer gültigen Mietpreisbremse somit keinen unmittelbaren signifikanten Effekt auf die relativen Differenzen.¹⁸

Die in Tabelle A.2 präsentierte temporale Analyse offenbart jedoch ein differenzierteres Bild. Die Untersuchung von Lead- und Lag-Variablen liefert zwei zentrale Erkenntnisse: Erstens

¹⁸Die getesteten Kontrollvariablen beschreiben bereits im Wesentlichen das Angespanntheits-Niveau der Städte. Ohne diese Kontrollen zeigt die Mietpreisbremse einen positiven Effekt, da angespannte Märkte sowohl häufiger reguliert werden als auch höhere Differenzen aufweisen.

finden sich keine Belege für Antizipationseffekte. Die Lead-Variablen MPB_{t+1} und MPB_{t+2} sind insignifikant und teilweise negativ, was der Hypothese widerspricht, dass Vermieter Mieten präventiv vor Einführung der Regulierung erhöhen. Dies könnte an der kurzen Vorankündigungszeit oder der Unsicherheit über die tatsächliche Implementation liegen. Zweitens manifestiert sich ein signifikanter verzögerter Dämpfungseffekt. Während die kontemporäre Variable und die einjährige Verzögerung keine signifikanten Effekte zeigen, entfaltet die Mietpreisbremse nach zwei Jahren ihre intendierte Wirkung ($MPB_{t-2} = -0,019$, $p < 0,05$). Diese Anpassungsphase lässt sich dadurch erklären, dass sich dämpfende Effekte erst mit der natürlichen Fluktuation im Markt entfalten müssen; die Kenntnis und Durchsetzung der Regulierung etabliert sich graduell und Marktakteure benötigen Zeit zur Anpassung.

Tabelle A.2: Temporale Effekte innerhalb des robusten SARAR

	Modellspezifikation			
	Symmetrisch	Nur Lags	Nur Leads	Vollständig
	(t-1,t,t+1)	(t-2,t-1,t)	(t,t+1,t+2)	(t-2 bis t+2)
MPB (t-2)	–	-0.0188* (0.0093)	–	-0.0183* (0.0079)
MPB (t-1)	-0.0009 (0.0085)	-0.0000 (0.0103)	–	0.0217 (0.0124)
MPB (t)	0.0059 (0.0092)	-0.0022 (0.0104)	0.0077 (0.0084)	-0.0054 (0.0149)
MPB (t+1)	-0.0152 (0.0094)	–	0.0002 (0.0091)	-0.0125 (0.0119)
MPB (t+2)	–	–	-0.0126 (0.0093)	-0.0175 (0.0122)
Beobachtungen	511	511	511	365

Darstellung temporaler Effekte der Mietpreisbremse in unterschiedlichen Spezifikationen mit Lead-(Antizipation) und Lag-Variablen (Anpassung). Alle Modelle basieren auf dem robusten SARAR-Modell aus Tabelle A.1 mit Stadt- und Jahr-Fixed-Effects (Within-Transformation). Standardfehler sind heteroskedastie-robust und wurden analog zur Hauptspezifikation über eine OLS-Typ-White/Sandwich-Varianzmatrix unter Verwendung der ML-Residuen berechnet (Kelejian und Prucha, 2007; Drukker et al., 2013)).

Signifikanzniveaus: *** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$, ^a $p < 0,10$.

Modellgüte und Erklärungsgehalt Die präsentierten Ergebnisse basieren auf einem robusten Modell mit guter Anpassungsgüte (vgl. Anhang A.1 IX für detaillierte Gütemaße). Der Root Mean Squared Error von 0,0451 zeigt, dass die vorhergesagten relativen Differenzen im Durchschnitt um 4,5 Prozentpunkte von den beobachteten Werten abweichen – bei einer Standardabweichung der abhängigen Variable von 15 Prozentpunkten eine gute An-

passung. Das Within- R^2 von 8,9% erscheint niedrig, ist jedoch typisch für Paneelmodelle mit umfangreichen Fixed Effects, da diese bereits den Großteil der Variation absorbieren (Baltagi, 2021). Ein niedriges Within- R^2 ist somit kein Indikator mangelhafter Modellgüte, sondern reflektiert die Zielsetzung der Analyse: nicht die Prognose absoluter Niveaus der Mietsegmentierung, sondern die Quantifizierung systematischer struktureller Assoziationen zwischen sozioökonomischen Determinanten und relativer Mietpreisdifferenz unter Kontrolle stadt- und zeitspezifischer fixer Effekte sowie räumlicher Abhängigkeit. Die Aussagekraft der Koeffizienten beruht entsprechend auf ihrer ökonomischen Plausibilität, ihrer statistischen Signifikanz unter heteroskedastie-robusten Standardfehlern sowie ihrer Robustheit über die im Anhang A.1 IX dokumentierten Spezifikationstests. Die räumliche Spezifikation verbessert das Modell signifikant gegenüber einem nicht-räumlichen Fixed-Effects-Modell (Likelihood-Ratio-Test: $\chi^2 = 12,32$, $p = 0,002$) und das Spatial- R^2 von 50,4% bestätigt die erfolgreiche Erfassung räumlicher Abhängigkeiten.

Zusammenfassend identifiziert die Analyse primär marktendogene Faktoren als Treiber der Divergenz zwischen Neuvertrags- und Bestandsmieten: Wirtschaftliche Prosperität, demografische Nachfrageintensität und Altersstruktur erklären gemeinsam mit angebotsseitigen Strukturmerkmalen – insbesondere dem dämpfenden Einfluss nicht-gewinnorientierter Vermieter – den Großteil der Variation. Der teils signifikante räumliche Lag-Parameter verdeutlicht zudem, dass lokale Mietmarktdynamiken substantiell auf benachbarte Märkte überschwappen und somit regionale Verstärkungseffekte generieren. Die Mietpreisbremse als zentrales wohnungspolitisches Instrument zeigt hingegen eine ambivalente Bilanz: Während der kontemporäre Effekt statistisch insignifikant bleibt, manifestiert sich nach zweijähriger Verzögerung eine signifikante, aber moderate Dämpfung der Mietpreisdifferenzen. Diese zeitliche Verzögerung reflektiert die strukturelle Trägheit des Instruments – es greift nur bei Neuvermietungen und benötigt Fluktuation zur Entfaltung. Kritisch zu hinterfragen bleibt die praktische Relevanz: Eine Reduktion der relativen Differenz um lediglich 1,9 Prozentpunkte nach zwei Jahren in Städten mit bindender Mietpreisbremse wirft Zweifel an der Effektivität dieses Instruments in ihrer gegenwärtigen Ausgestaltung auf. Angesichts der dominanten Rolle marktstruktureller Faktoren erscheint die Mietpreisbremse (die den Zähler der Zieldifferenz adressiert) als Instrument zu schwach, um die Segregation auszugleichen, die durch die dämpfende Bestandsregulierung (im Nenner) implizit mit erzeugt wird.

A.1.5 Fazit

Die Entwicklung der Wohnungsmieten in Deutschland verläuft zunehmend divergent. Durch die Datenanalyse, bei der für den Neuvertragsmarkt Angebotsmieten als Datenrepräsentation und für den Bestandsmarkt Mietspiegelmieten als Datenrepräsentation gewählt wurden, konnte eine zunehmendes Gefälle zwischen Neuvertrags- und Bestandsmieten festgestellt werden. Die empirische Analyse von 107 Städten über den Zeitraum 2014-2022 offenbart relative Differenzen von durchschnittlich 20 bis 25%, die in den sechs bevölkerungsreichsten Städten auf über 40% ansteigen. Diese Befunde bestätigen unsere Erwartung einer dualen Marktstruktur unter asymmetrischer Regulierung: Während Bestandsmieten durch Kappungsgrenzen und verzögerte Mietspiegelanpassungen effektiv begrenzt werden, unterliegen Neuvertragsmieten trotz Mietpreisbremse faktisch schwächeren Restriktionen.

Die räumlich-ökonomische Analyse identifiziert primär marktendogene Faktoren als Treiber dieser Divergenz. Methodisch quantifiziert die abhängige Variable (die relative Differenz) dabei die Asymmetrie der deutschen Regulierung: Sie bildet inhärent den Kontrast ab zwischen der Mietpreisbremse, die den Zähler (Neuvertragsmieten) begrenzen soll, und der Instrumente im Bestand, also Kappungsgrenze und ortsübliche Vergleichsmiete als gesetzliche Obergrenze, die den Nenner (Bestandsmieten-Proxy) dämpfen. Die Evaluation der Mietpreisbremse offenbart vor diesem Hintergrund eine komplexe Wirkungsstruktur. Während kontemporäre Effekte statistisch nicht nachweisbar sind, manifestiert sich nach zwei Jahren eine signifikante, wenngleich moderate Dämpfung der relativen Differenzen. Diese zeitliche Verzögerung ist plausibel angesichts der Beschränkung auf Neuvermietungen und der graduellen Marktdurchdringung. Die schwache Effektstärke relativiert jedoch die praktische Relevanz des Instruments. Angesichts der dominanten Rolle marktstruktureller Faktoren erscheint die Mietpreisbremse in ihrer gegenwärtigen Ausgestaltung unzureichend, um die dokumentierte Marktsegregation substantiell zu beeinflussen. So kann die Vielzahl gesetzlicher Ausnahmetatbestände, die faktische Umgehungsmöglichkeiten schaffen, und systematische Durchsetzungsdefizite bei asymmetrischer Informationsverteilung zwischen Mietern und Vermietern die in dieser Studie festgestellte limitierte Wirksamkeit begründen.

Die dokumentierte Marktsegregation hat weitreichende alloкатive und distributive Konsequenzen. Allokativ führt sie zu einer Immobilisierung des Wohnungsmarktes: Bestandsmieter verlieren den ökonomischen Anreiz zur Wohnungsanpassung an veränderte Lebensumstände – ein sogenannter Lock-in-Effekt –, während potenzielle Neumieter mit prohibitiv hohen Eintrittsbarrieren konfrontiert sind. Diese Dualisierung wirft zudem Fragen der intergenerationalen Gerechtigkeit auf, da primär junge Haushalte und Arbeitsmarkteinsteiger von hohen Neuvertragsmieten betroffen sind, während etablierte Bestandsmieter von regulierungsbedingten stabilen Bestandsmieten profitieren.

Aus diesen Befunden lassen sich Implikationen für eine evidenzbasierte Wohnungspolitik ableiten. Die dominanten nachfrageseitigen Treiber (ökonomische Prosperität und demografische Verdichtung) zeigen, dass jede Politik, die ausschließlich an der Mietpreisregulierung ansetzt, strukturell unterspezifiziert bleibt. Der nur moderat und mit zweijähriger Verzögerung wirkende Effekt der Mietpreisbremse ist primär Ausdruck der zugrunde liegenden Regulierungsasymmetrie zwischen Bestand und Neuvertrag: Da die im Bestand wirkende Regulierung (Kappungsgrenze sowie die ortsübliche Vergleichsmiete als gesetzliche Obergrenze) und die Mietpreisbremse in der relativen Differenz inhärent gegensätzlich wirken, erfasst der geschätzte Koeffizient den marginalen Beitrag der Mietpreisbremse unter parallel wirkender Bestandsregulierung, nicht den isolierten Effekt einer einseitig auf das Neuvertragssegment gerichteten Regulierung. Der signifikante Dämpfungseffekt nicht-gewinnorientierter Vermieter verweist auf eine Wettbewerbsdynamik im Neuvertragssegment: Selbst ein moderater Anteil von Anbietern mit Mieten unter Marktniveau kann den Wettbewerbsdruck auf gewinnorientierte Vermieter erhöhen und somit auch deren Neuvertragsmieten dämpfen – mehr Angebot über mehr Wettbewerb wirkt damit komplementär zu direkter Preisregulierung. Die hochsignifikante räumliche Spillover-Komponente deutet zudem darauf hin, dass eine regional koordinierte Politik gegenüber isolierten Einzelstadtmaßnahmen wirksamer erscheint.

Konzeptionell kommen aus diesen Befunden zwei grundsätzlich entgegengesetzte Reformpfade in Betracht. Eine regulatorische Konvergenz durch Verschärfung würde die Angleichung der Regulierungsintensität zwischen beiden Marktsegmenten anstreben – durch strengere Durchsetzung der Mietpreisbremse, Reduktion der Ausnahmetatbestände und Einführung von Transparenzpflichten wie der verpflichtenden Offenlegung der Vormiete. Dieser Ansatz würde die Preisdifferenzen direkt adressieren, setzt jedoch effektive Durchsetzungsmechanismen und administrative Ressourcen voraus. Alternativ könnte eine marktorientierte Deregulierung die symmetrische Lockerung der Bestandsschutzregulierung vorsehen, um Marktmechanismen zu stärken und die dokumentierten Allokationsverzerrungen zu reduzieren; dieser Pfad würde die Segregation durch Angleichung auf höherem Preisniveau auflösen, impliziert jedoch potenzielle soziale Härten für einkommensschwache Haushalte. Beide Optionen zielen auf die Schließung der regulatorischen Lücke zwischen den Marktsegmenten, unterscheiden sich jedoch in ihrer normativen Ausrichtung zwischen verstärktem Mieterschutz und erhöhter Markteffizienz. Eine komplementäre angebotsseitige Expansion durch verstärkten Wohnungsbau könnte das Preisniveau im Neuvertragssegment langfristig dämpfen, würde die fundamentalen Allokationsverzerrungen jedoch nicht beheben, solange die asymmetrische Regulierung Lock-in-Anreize aufrechterhält. Die konkrete Wohlfahrts- und Verteilungsbilanz dieser Optionen erfordert eine eigenständige mikroökonomische Analyse, die in Kapitel A.2 der vorliegenden Arbeit für einen konkreten Reformpfad – die Angleichung der Bestandsmieten an das Neuvertragsmietniveau im Sinne der marktorientierten Deregulierung –

lierungsvariante – vorgenommen wird.

Trotz der dokumentierten Aufbereitung und Harmonisierung der Datenquellen verbleiben methodische Limitationen. Die Verwendung von Angebotsmieten als Repräsentation für Neuvertragsmieten kann zu einer leichten Überschätzung der tatsächlichen Differenzen führen. Nicht-beobachtbare Faktoren – Modernisierungszustand, exakte Mikrolage und Vormiethöhe – konnten nicht explizit, nur über dokumentierte Aufbereitung und Harmonisierung, kontrolliert werden. Diese Limitationen implizieren, dass die geschätzten Differenzen als Indikator für Markttrends zu interpretieren sind und nicht als exakte Kennzahl möglicher regulatorischer Verstöße auf Städteebene im betrachteten Zeitraum. Da wir mit unserem Studiendesign der relativen Differenzen auf ebendiese Markttrends abzielen und in der Regressionsanalyse zusätzlich für sämtliche fixe und strukturelle Effekte und Verzerrungen zwischen Städten und zwischen den Perioden kontrollieren, sind die Studienergebnisse robust.

Zukünftige Forschung sollte dennoch die Datenlimitationen adressieren. Der Zugang zu Transaktionsmietdaten würde präzisere Messungen ermöglichen und die Unsicherheit bezüglich der tatsächlichen Neuvertragsmieten reduzieren. Mikrodaten zu Modernisierungen und Vormietenverhältnissen könnten die Identifikation regulatorischer Umgehungen verbessern. Methodisch wären so quasi-experimentelle Designs möglich, die regionale und zeitliche Variation in der Regulierungsintensität zur detaillierteren kausalen Identifikation nutzen könnten.

A.2 Fehlllokationen deutscher Mietpreisregulierung? Ein dynamisches Modell zur Evaluation alternativer Regulierungsformen*

Autoren: Lars Jagemann und Steffen Sebastian

Zusammenfassung: Diese Studie untersucht die ökonomischen Auswirkungen alternativer Mietwohnungsregulierungen in Deutschland. Basierend auf regionalen Mikrozensus-Daten und einem dynamischen Mietwohnungsmarktmodell mit Nachfrageschätzungen und Gleichgewichtsiterationen werden die Auswirkungen auf Mieter und Vermieter sowie die fiskalischen Folgen quantifiziert. Konkret wird die Angleichung von Bestands- und Neuvertragsmieten simuliert. Die Ergebnisse zeigen, dass die Reform zu einer effizienteren Wohnraumallokation führen würde, jedoch mit erheblichen Umverteilungseffekten: Während Vermieter höhere Einkünfte verzeichnen und Wohnungssuchende von erhöhter Verfügbarkeit profitieren würden, müssten Bestandsmieter Mehrbelastungen tragen und öffentliche Haushalte zusätzlich Kosten für Wohngeld und Kosten der Unterkunft aufwenden, die jedoch durch die Besteuerung der Vermieter überkompensiert wird. Die Simulation des iterativen Marktanpassungsprozesses zeigt einen Anstieg der mittleren Mieten, eine Reduzierung der Wohnfläche pro Haushalt und eine Erhöhung des Leerstands. Trotz eines positiven Gesamtwohlfahrtseffekts wären sozialpolitische Maßnahmen notwendig, um bedürftige Gruppen zu schützen.

A.2.1 Einleitung

Die optimale Regulierung von Mietwohnungsmärkten ist Gegenstand wissenschaftlichen Diskurses, der von unterschiedlichen Ansätzen geprägt ist. Während neoklassische Ökonomen häufig die Effizienz freier Märkte betonen, verweisen Vertreter anderer ökonomischer Schulen auf zahlreiche Marktunvollkommenheiten, die regulierende Eingriffe rechtfertigen können. So steht weniger die grundsätzliche Legitimierung staatlicher Mietwohnungsregulierung im Fokus, sondern vielmehr die Effizienzanalyse der Auswirkungen konkreter Regulierungsinstrumente und die daraus ableitbaren politischen Handlungsempfehlungen. Kapitel A.1 konnte aufzeigen, dass divergierende Regulierungsinstrumente im Bestands- und Neuvertragssegment Segregationstendenzen fördern und damit die allokalationseffizienten Marktfunktionen beeinträchtigen. Eine symmetrische Regulierung zwischen Bestands- und Neuvertragssegment wurde dabei als eine mögliche Maßnahme zur Überwindung dieser Ineffizienzen identifiziert. Daran anschließend leiten sich für die vorliegende Studie vier Forschungsfragen ab:

- (i) Welche aggregierten Wohlfahrtseffekte (Mieter, Vermieter, Staat) würde eine Angleichung von Bestands- und Neuvertragsmieten im Rahmen einer kontrafaktischen Reform generieren?

*Die Autoren danken Holger Cischinsky vom Institut Wohnen und Umwelt (IWU) für den fachlichen Austausch und die wertvollen Hinweise zur Modellierung und Ausgestaltung des Analyseansatzes.

- (ii) Wie verteilen sich diese Effekte über Einkommensgruppen und Mietstufen, und ergeben sich daraus regressive oder progressive Wirkungsmuster?
- (iii) Welche Anpassungsreaktionen auf Haushaltsebene – insbesondere hinsichtlich Wohnflächenkonsum, Leerstand und Mietbelastung – sind im modellierten Marktgleichgewicht zu erwarten?
- (iv) Welche fiskalischen Folgewirkungen (Wohngeld, Kosten der Unterkunft, Vermieterbesteuerung) ergeben sich aus dem simulierten Anpassungsprozess?

Die folgende Studie beantwortet diese Fragen durch Mikrosimulation einer hypothetischen Regulierungsreform, die Bestands- und Neuvertragsmieten angleicht. Kalibriert mit regionalen Mikrozensus-Daten wird simuliert, welche Allokations- und Verteilungseffekte entstünden, wenn Preisniveaus von Bestands- und Neuvertragsmieten angeglichen würden. Die Simulation auf Haushaltsebene mit repräsentativer Hochrechnung auf Bundesebene quantifiziert dabei die aggregierte Wohlfahrtseffekte, und ermöglicht eine differenzierte Analyse nach Einkommensschichten und Regionen. Die Integration wohnrelevanter Transferleistungen ermöglicht die Analyse fiskalischer Implikationen. Die Grundlage dieser Mikrosimulation bildet ein aus den Mikrozensus-Daten geschätzter Neuvertragsmietenspiegel.

Der Rest der Studie ist wie folgt strukturiert. Im folgenden Abschnitt wird der Forschungsansatz in den Kontext bisheriger Literatur eingeordnet und die Relevanz unserer Studie hervorgehoben. Der dritte Abschnitt beschreibt die in der Analyse verwendeten Daten und Methoden, insbesondere die Verwendung des Mikrozensus und die Modellierung der Nachfragereaktion. Im vierten Abschnitt folgt ein Überblick über die gewählte mikroökonomische Fundierung, welche eine wohlfahrtstheoretische Einordnung unserer Ergebnisse ermöglicht. Der fünfte Abschnitt präsentiert die Ergebnisse. In den abschließenden Abschnitten werden die Limitationen unserer Studie diskutiert und ein Fazit gezogen.

A.2.2 Literaturübersicht

Die theoretische Literatur zu dynamischen Wohnungsmarktmodellen wird von mehreren grundlegenden Arbeiten dominiert. DiPasquale und Wheaton (1994) legten mit ihrem Stock-Flow-Modell des Wohnungsmarktes den Grundstein für die moderne Analyse der Gesamtdynamik durch Integration von Angebots- und Nachfrageseite, wobei sie frühere Ansätze durch die Berücksichtigung von Verzögerungen und Rückkopplungseffekten erweiterten. Poterba (1984) prägte die Forschung mit seinem Asset-Market-Modell, das die Auswirkungen von Inflationsratenänderungen auf reale Hauspreise und die Gleichgewichtsgröße des Wohnungskapitalstocks analysiert. Fallis und Smith (1984) untersuchten die Wohlfahrtseffekte von Mietpreisregulierungen in einem allgemeinen Gleichgewichtsmodell und zeigten, dass derartige Markteingriffe zu ineffizienten Allokationen und Wohlfahrtsverlusten führen

können. Glaeser und Luttmer (2003) formalisierten die Analyse der Fehlallokation von Wohnraum unter Mietpreiskontrollen und wiesen nach, dass solche Regulierungen zu erheblichen Wohlfahrtsverlusten führen, da Wohnungen nicht zwangsläufig an Haushalte mit der höchsten Zahlungsbereitschaft vergeben werden.

Während die beschriebenen Studien eher makroökonomische Zusammenhänge betrachten, erweiterten Diamond et al. (2019) diesen Forschungsstrang durch ein dynamisches und mikroökonomisch-fundiertes Gleichgewichtsmodell, das langfristige Angebotsreaktionen und räumliche Spillover-Effekte berücksichtigt. Ihre empirische Untersuchung zu San Francisco belegt, dass Mietpreiskontrollen das Angebot an Mietwohnungen reduzieren und Gentrifizierungsprozesse in nicht-regulierte Gebiete verlagern können. Favilukis et al. (2023) entwickelten ein räumliches Gleichgewichtsmodell kalibriert anhand von Daten aus New York, um die Wohlfahrtseffekte von erschwinglichem Wohnraum und Mietpreiskontrollen zu quantifizieren. Ihr Modellrahmen berücksichtigt die räumliche Dimension des Wohnungsmarktes und modelliert die Interaktion zwischen Wohnungs- und Arbeitsmärkten. Keine uns bekannte Studie entwickelt ein dynamisches, mikroökonomisch-fundiertes Mietwohnungsmarktmodell basierend auf Daten des deutschen Mietwohnungsmarktes.

Im deutschen Kontext liegen viele Studien vor, die empirische Auswertungen der Auswirkungen bestimmter Regulierungsinstrumente untersuchen. Die Mehrzahl bisheriger Studien des deutschen Mietwohnungsmarktes verzichtet auf die Auswertung von repräsentativen und granularen Haushaltsdaten und beruht stattdessen auf aggregierten Daten aus Immobilienanzeigen, kleinräumigen und regionalen Daten sowie amtlichen Daten wie ortsübliche Vergleichsmieten. Folgende Studien haben im Kontext von Wohnungsmärkten Mikrozensus-Daten verwendet: Articus et al. (2020) untersuchten die methodischen Möglichkeiten zur Analyse lokaler Mietmärkte auf Basis des deutschen Mikrozensus. Sie heben hervor, dass der Mikrozensus seit 2018 geocodierte Ergebnisse liefert, was eine wesentliche Voraussetzung für kleinräumige Analysen schafft. Die Autoren identifizieren jedoch ein zentrales methodisches Problem: Die starke regionale Disaggregation führt zu kleinen Stichprobengrößen für die interessierenden Einheiten, was bei herkömmlichen Schätzern zu großen Standardfehlern führt. Als Lösung schlagen sie Small-Area-Estimation-Techniken vor, um dennoch zuverlässige lokale Schätzungen zu erhalten. Ergänzend entwickelten Ahlfeldt et al. (2023) einen Algorithmus zur Erstellung mikro-geografischer Immobilienpreis- und Mietindizes, der geocodierte Mikrodaten für beliebige räumliche Einheiten nutzt. Diese Studien konzentrieren sich jedoch primär auf die methodischen Herausforderungen bei der Verwendung von Mikrozensus-Daten für lokale Analysen und nicht auf die Entwicklung dynamischer Modelle zur Simulation von Politikänderungen. Während Thomschke (2019) ebenfalls Mikrozensus-Daten verwendete, kombinierte er diese mit Marktdaten und nutzte eine Difference-in-Differences-Schätzung zur Analyse der regionalen Auswirkungen der Mietpreisbremse.

Ein wesentliches Unterscheidungsmerkmal unseres Ansatzes ist folglich die Erstellung eines dynamischen Mietwohnungsmodell, welches anhand deutscher Mikrozensus-Daten kalibriert wird. Diese haushaltsspezifischen Daten erlauben eine mikroökonomische Fundierung und repräsentative Wohlfahrtsanalyse von bestimmten Schocks, die wir in unserem Modell modellieren können. Obwohl die Verwendung von Mikrozensus-Daten mit methodischen Herausforderungen verbunden ist, adressieren wir diese systematisch durch unsere im folgenden Abschnitt dargestellte Methodik.

A.2.3 Daten und Methodik

Datengrundlage

Unsere Analyse basiert auf dem Scientific Use File¹⁹ (SUF) des deutschen Mikrozensus aus dem Erhebungsjahr 2018 mit einem Sondermodul Wohnen, welches detaillierte Informationen über etwa 1% der deutschen Bevölkerung liefert und repräsentativ auf Bundesland- und Bundesebene ist. Da die Erhebung primär auf Individualebene erfolgt, aggregieren wir die Daten mittels Haushalts-ID auf Haushaltsebene und berechnen haushaltsrelevante Variablen wie Haushaltsgröße, Nettohaushaltseinkommen, Miete pro m² und Wohnfläche. Wir ergänzen die Mikrozensus-Daten mit zusätzlichen Daten, die es ermöglichen, Sozialtransfers, Mietstufen und weitere benötigte Variablen zu modellieren.


Die meisten Haushaltsdaten werden kategorial erfasst, beispielsweise wird das Nettohaushaltseinkommen in Einkommensbereichen (z.B. 2.500-3.000€) abgefragt, wobei wir zur weiteren Verwendung den jeweiligen Kategorienmittelwert als stetigen Wert approximieren. Bei abweichenden Angaben von Haushaltsmitgliedern zu gemeinsamen Variablen wie dem Nettohaushaltseinkommen verwenden wir einen Modus-Ansatz: Geben mindestens zwei Personen denselben Wert an, wird dieser verwendet, andernfalls der Mittelwert aller nicht-fehlenden Antworten. Um die Robustheit unserer Analyse zu gewährleisten, filtern wir zudem Haushalte mit unrealistischen Werten für Schlüsselvariablen heraus. Die Datenaufbereitung folgt dem in Abbildung A.7 dargestellten mehrstufigen Filterprozess. Ausgehend von 587.224 Individuen im Scientific Use File werden diese mittels einer Haushalts-ID zu 281.379 Haushalten aggregiert, wovon 119.764 Miethaushalte für die weitere Analyse selektiert werden.²⁰ Neben

¹⁹Die Verwendung der geocodierten Mikrozensus-Daten über die Forschungsdatenzentren (vor Ort oder via Fernzugriff) ist mit erheblichen praktischen Einschränkungen verbunden: lange Wartezeiten bei der amtlichen Ergebnisprüfung, eingeschränkte Codierungsmöglichkeiten ohne Dateneinsicht beim Fernzugriff sowie begrenzte Flexibilität in der Analyse. Das SUF ermöglicht eine uneingeschränkte Datenbearbeitung bei akzeptablen regionalen Informationsverlusten: Die georeferenzierten Mikrozensus-Daten würden zwar eine kleinräumigere Identifikation der Haushalte erlauben. Diese sind für bundesweit hochgerechnete Aggregataussagen, auf die wir abzielen, aber ohnehin nicht zielführend: Der Mikrozensus ist nur auf Bundesland- und Bundesebene repräsentativ; sub-regionale Auswertungen leiden an erheblichen Schätzunsicherheiten durch geringe Fallzahlen (Articus et al., 2020).

²⁰Wir klassifizieren als Miethaushalte nur die in der Erhebung eindeutig als Mieter angegebenen Haushalte;

der Entfernung von Haushalten mit fehlenden Daten, wird zur Eliminierung von Extremwerten eine kombinierte 1%-Tail-Filterung angewendet, bei der Haushalte im untersten und obersten Perzentil der gemeinsamen Verteilung von Nettohaushaltseinkommen, Nettokaltmiete pro m² und Wohnfläche ausgeschlossen werden. Nach Schätzung des Neuvertragsmietpreises und individueller Mietenzuweisung erfolgt ein finaler Plausibilitätsfilter: Haushalte, deren modellierte Neuvertragsmiete die beobachtete Status-quo-Miete um mehr als 300€ unterschreitet, werden als inkonsistente Zuordnungen eliminiert. Dieser zweistufige Filteransatz reduziert die Stichprobe um 19.398 Haushalte auf final 100.366 Miethaushalte mit vollständigen und plausiblen Daten.

Abbildung A.7: Datengrundlage und Filterung



Eigene Darstellung.


Diese Haushalte werden mittels angepasster Hochrechnungsgewichte auf die Grundgesamtheit von 19,6 Millionen deutschen Miethaushalten²¹ extrapoliert, wobei die Mikrozensus-Standardgewichte proportional um den Faktor 1,256 skaliert werden, um die Diskrepanz zwischen der Mikrozensus-Hochrechnung mit gefilterten Haushalten (15,6 Millionen) und die tatsächlich hochzurechnende Anzahl der Miethaushalte zu korrigieren. Die Validität dieser Gewichtungskorrektur zeigt Abbildung A.8. Die Haushaltsgewichte konzentrieren sich um einen Mittelwert von 0,2 mit moderater Streuung (oberes linkes Panel). Der Vergleich der Haushaltsgrößenverteilung zwischen gewichteter Stichprobe und Grundgesamtheit (oberes

Eigentümer sowie fehlende und ungültige Angaben fallen in die Restkategorie. Die resultierende Eigentumsquote von rund 58% liegt über der amtlichen Wohneigentumsquote (46–48%); die Diskrepanz erklärt sich durch die haushaltsbasierte (statt wohnungsbasierte) Klassifikation sowie die unspezifische Restkategorie. Für die Wohlfahrtsanalyse ist dies nachgelagert, da wir auf die Mieter-Teilstichprobe filtern und gewichten.

²¹Eigene Berechnung auf Basis der Mikrozensus-Hochrechnung. Das Statistische Bundesamt (2020) weist für 2018 offiziell 19,9 Millionen Miethaushalte aus, was einer geringen Abweichung entspricht.

rechtes Panel) zeigt eine leichte Überrepräsentation von Einpersonen-Haushalten (49,5% vs. 41,8% in der Grundgesamtheit), die aus unserem Filterprozess resultiert.²² Zwei- und Mehr-Personen-Haushalte sind entsprechend leicht unterrepräsentiert, wobei die Abweichungen mit zwei bis fünf Prozentpunkten je Kategorie moderat ausfallen.

Abbildung A.8: Validierung der Gewichtungsfaktoren und Repräsentativität



Eigene Berechnung und Darstellung.

Zuordnung von Mietstufen als Lagekriterium

Das Scientific Use File des Mikrozensus enthält keine exakten Standortdaten der befragten Haushalte – verfügbar sind lediglich das Bundesland und die Gemeindegrößenklasse.²³ Da Lageinformationen für die Modellierung von Mietwohnungsmärkten essentiell sind, entwickeln wir ein Verfahren zur probabilistischen Zuweisung von Mietstufen²⁴ als Proxy für eine makro-geografische Lagequalität. Das entwickelte Zuordnungsverfahren basiert auf der empirischen Verteilung der Mietstufen in Deutschland (vgl. Anhang A.2 I für eine grafische Darstellung). Ausgangspunkt sind 11.014 deutsche Gemeinden mit bekannter Mietstufe und Einwohnerzahl. Für jede der 52 möglichen Kombinationen aus 16 Bundesländern und

²²Die Überrepräsentation von Ein- und Zweipersonen-Haushalten ist teilweise eine Folge der 1%-Tail-Filterung: Mehrpersonen-Haushalte weisen häufiger Ausreißerwerte bei Einkommen und Miete auf und werden überproportional ausgeschlossen. Die Abweichung von 7,7 Prozentpunkten bei Ein-Personen-Haushalten liegt in einem akzeptablen Bereich; da das Forschungsdesign auf qualitative Reformwirkungen und nicht auf absolute Punktpräzision zielt, ist eine systematische Verzerrung der Analyseergebnisse nicht zu erwarten.

²³Die Verwendung der im Scientific Use File verfügbaren Aggregationsebene (Bundesland/Gemeindegrößenklasse) folgt den methodischen Erkenntnissen von Articus et al. (2020), die bei kleinräumigen Mikrozensus-Analysen erhebliche Schätzunsicherheiten durch geringe Fallzahlen nachweisen. Da diese Aggregationsebene für die Zuordnung von Mietstufen ausreicht und gleichzeitig robuste Schätzungen gewährleistet, ist eine tiefere regionale Disaggregation nicht notwendig.

²⁴Mietstufen sind ein in § 254 der Wohngeldverordnung verankertes Lagekriterium, das Gemeinden in sechs Stufen (1 = günstigste bis 6 = teuerste, Stand 2018) entsprechend dem örtlichen Mietniveau einteilt und so regionale Mietunterschiede bei der Wohngeldberechnung berücksichtigt. Die Mietstufen werden vom BBSR anhand umfassender Marktanalysen alle zwei Jahre aktualisiert und spiegeln das regionale Mietpreinsniveau wider. Ihre Verwendung als Lagequalitäts-Proxy ist methodisch vertretbar, da sie (1) auf empirischen Marktdaten basieren, (2) regional differenziert sind und (3) regelmäßig validiert werden.

verschiedenen Gemeindegrößenklassen berechnen wir die bedingte Wahrscheinlichkeitsverteilung der Mietstufen, gewichtet nach den jeweiligen Bevölkerungsanteilen (vgl. Anhang A.2 II für die Verteilungstabelle der Grundgesamtheit in Deutschland). Ein Haushalt in Bayern mit Wohnort in einer Stadt zwischen 20.000 und 100.000 Einwohnern erhält beispielsweise mit 7,3% Wahrscheinlichkeit Mietstufe I, mit 25,8% Mietstufe II, mit 26,5% Mietstufe III, mit 15,8% Mietstufe IV, mit 4,0% Mietstufe V und mit 20,7% Mietstufe VI. Die Zufallszuweisung erfolgt für alle Haushalte individuell gemäß ihrer jeweiligen Wahrscheinlichkeitsverteilung mittels Monte-Carlo-Simulation. Dieser probabilistische Ansatz gewährleistet, dass im Aggregat die tatsächliche deutschlandweite Mietstufenverteilung reproduziert wird, während gleichzeitig die natürliche Heterogenität innerhalb der Aggregationsebenen erhalten bleibt. Für detaillierte Zuordnungsergebnisse nach Bundesland und Gemeindegrößenklasse sowie Robustheitstests, die zeigen, dass die Varianz der Modellergebnisse durch unterschiedliche probabilistische Ziehungen vernachlässigbar gering ist, siehe Anhang A.2 III.

Modellierung staatlicher Transferzahlungen


Staatliche Transferzahlungen wie Wohngeld und Kosten der Unterkunft (KdU) sind zentrale Komponenten des deutschen Mietwohnungsmarktes. Ihre Modellierung ist essentiell für die Quantifizierung fiskalischer Effekte der Regulierungsreformen, da sich Empfängerzahlen und Transfervolumina je nach Mietpreisniveau ändern können. Unsere Modellierung basiert auf dem Gesamtregelbedarf als zentraler Bemessungsgröße, der sowohl die Berechnung von KdU-Ansprüchen der Haushalte als auch eine Abgrenzung zu Wohngeldansprüchen ermöglicht. Der Gesamtregelbedarf wird für jeden Haushalt unserer Stichprobe haushaltstypspezifisch berechnet und umfasst den Regelbedarf für Lebenshaltungskosten ohne Wohnkosten sowie die Kosten einer angemessenen Unterkunft. Diese Berechnung erfolgt auf Basis der jeweiligen Haushaltszusammensetzung: Der Regelbedarf für Lebenshaltungskosten eines Haushalts wird anhand folgender Regelbedarfsstufen gemäß § 20 SGB II für das Jahr 2018 basierend auf Alter und Beziehungsstatus der Haushaltsmitglieder berechnet:

- Ehepartner/Lebenspartner: 374€
- Alleinerziehende oder Ein-Personen-Haushalte: 416€
- Kinder unter 6 Jahren: 240€
- Kinder 6-13 Jahre: 296€
- Kinder 14-17 Jahre: 316€
- Andere Personen: 332€

Der Gesamtregelbedarf eines Haushalt ist die Summe der individuellen Regelbedarfe aller Haushaltsmitglieder. Zusätzlich zu den Regelbedarfen wird ebenfalls auf Basis der Haushaltszusammensetzung angemessene Kosten der Unterkunft berechnet.²⁵ Hierzu nutzen wir die Maximalmiete, die bei Wohngeldberechnung anrechenbar ist.²⁶

Abbildung A.9 visualisiert die resultierenden Gesamtregelbedarfe unserer Stichprobe. Die Verteilung ist rechtsschief mit einem Median von 1.173€ und konzentriert sich um 1.200€ – dem typischen Bedarf von Zwei-Personen-Haushalten. Der Gesamtregelbedarf steigt nahezu linear mit der Haushaltsgröße von durchschnittlich 850€ für Alleinstehende auf 2.450€ für Fünf-Personen-Haushalte, wobei die mittlere Abbildung die jeweilige Streuung innerhalb der Haushaltsgrößen zeigt. Regional variiert der Gesamtregelbedarf moderat mit den Mietstufen: Der Median steigt von 1.150€ in Mietstufe I auf 1.250€ in Mietstufe VI, bedingt durch die mietstufenabhängigen angemessenen Wohnkosten.

Abbildung A.9: Verteilung des Gesamtregelbedarfs der Haushalte



Eigene Berechnung und Darstellung. *Anmerkung:* Interquartilsabstand (IQR) beschreibt den Bereich zwischen dem ersten Quartil (25%-Perzentil) und dem dritten Quartil (75%-Perzentil) einer Verteilung.


KdU-berechtigt sind Haushalte mit Nettohaushaltseinkommen unter dem Gesamtregelbedarf. Bei Einkommen $\leq$ Regelbedarf für Lebensunterhalt werden die vollen Mietausgaben bis zu der Maximalmiete der angemessenen Wohnkosten übernommen. Bei Einkommen $>$ Regelbedarf für Lebensunterhalt („Aufstocker“) werden die Wohnkosten bis zur Maximalmiete abzüglich (Einkommen - Regelbedarf Lebensunterhalt) übernommen (vgl. Anhang A.2 IV für weitere Veranschaulichungen und Abgrenzungen).

²⁵ Unsere Modellierung verwendet Nettokaltmieten und ignoriert die Betriebskosten und die Heizkostenkomponente in KdU und Wohngeld, die 2018 ca. 20–30% der Gesamtwohnkosten ausmachte (Rehdanz, 2007; Grösche, 2010; BBSR, 2020). Die Klimakomponente existierte im Jahr 2018 noch nicht. Dies unterschätzt das absolute Unterstützungsniveau, verursacht aber keine systematische Verzerrung der relativen Szenario-Veränderungen, da Heizkosten verbrauchsabhängig und aus empirischer Sicht nahezu unabhängig vom Regulierungsregime sind (Galvin, 2023).

²⁶ Da nur wenige Gemeinden angemessene Kosten der Unterkunft definieren, ist die gängige juristische Praxis ersatzweise auf die Maximalmiete laut Wohngeld zuzüglich eines Aufschlags von 10% zurückzugreifen.

Abbildung A.10 visualisiert die resultierende Verteilung der Bedarfslücken in unserer Stichprobe. Das linke Panel zeigt die Abgrenzung zwischen KdU-Empfängern, Wohngeld-Empfängern und Selbstzahlern. Die 45-Grad-Linie markiert die Schwelle, oberhalb derer Haushalte potentiell KdU-berechtigt sind. Das rechte Panel zeigt die Verteilung der positiven Bedarfslücken mit einem Median von 146€ und einem Mittelwert von 230€, was die erhebliche Streuung der Unterstützungsbedarfe verdeutlicht. Diese Bedarfslücken determinieren sowohl die Höhe der KdU-Transfers als auch die Abgrenzung zum Wohngeldanspruch.

Abbildung A.10: Bedarfslücke und Transferberechtigung



Eigene Berechnung und Darstellung. *Anmerkung:* Links: Haushalte unterhalb der 45-Grad-Linie sind KdU-berechtigt. Rechts: Verteilung der Bedarfslücke für Haushalte mit positivem Unterstützungsbedarf.

Der KdU-Anspruch eines Haushaltes muss nun noch mit dem Wohngeldanspruch abgeglichen werden. In unseren Berechnungen wurde der Wohngeldanspruch für jeden Haushalt anhand der in Deutschland im Jahr 2018 gemäß § 19 WoGG gültigen Wohngeldformel zugewiesen:

$$1.15 \cdot (M - (a + b \cdot M + c \cdot Y) \cdot Y) \quad (\text{A.7})$$

Hierbei repräsentiert M die angepasste Miete des Haushalts und Y steht für das Haushaltseinkommen. Die Parameter a , b und c sind sogenannte Rechengrößen, deren Werte direkt von der Anzahl der zu berücksichtigenden Haushaltsmitglieder abhängen. Diese Parameter wurden der Anlage 2 des § 19 WoGG entnommen. Der Einfluss der Mietstufen auf die Wohngeldberechnung erfolgt über die Mietobergrenzen, welche der Anlage 1 des § 19 WoGG entnommen wurden. Für jede Mietstufe und Personenanzahl sind spezifische Höchstbeträge für die Miete festgelegt, die bei der Wohngeldberechnung berücksichtigt werden. Zusätzlich wurden Untergrenzen für Einkommen und Miete nach gängiger Formel berücksichtigt.

Beim Abgleich zwischen KdU-Anspruch und Wohngeldanspruch wird für jeden Haushalt die Transferleistung mit dem höheren Anspruch gewählt, da beide Leistungen nicht gleichzeitig bezogen werden können. Für die Modellierung wird angenommen, dass jeder positive Anspruch ($>0\text{€}$) vollständig in Anspruch genommen wird, die Inanspruchnahmequote also 100% beträgt. In der Realität liegt diese Quote aufgrund von Informationsasymmetrien, administrativen Hürden, geringen Beträgen oder irrationalen Entscheidungen darunter.²⁷

Fiskalische Modellierung Der Staat wird als aggregierte Fiskalentität modelliert, die sowohl Ausgaben (Transferleistungen) als auch Einnahmen (Besteuerung der Vermietereinkünfte) verzeichnet. Die Nettofiskalposition ergibt sich aus:

$$\Delta F_{\text{netto}} = \tau \cdot \Delta R - (\Delta W + \Delta K) \quad (\text{A.8})$$

wobei τ den effektiven Steuersatz auf Vermietungseinkünfte von hier 30%²⁸, ΔR die Änderung der aggregierten Mieteinnahmen, ΔW die Änderung der Wohngeldausgaben und ΔK die Änderung der KdU-Ausgaben bezeichnet. Diese Aggregation abstrahiert von der föderalen Verteilung zwischen Bund, Ländern und Kommunen.

Modellierung eines Neuvertragsmietniveaus

Zur Simulation der Angleichung von Bestands- und Neuvertragsmieten schätzen wir für alle Haushalte individuelle Neuvertragsmieten mittels eines hedonischen Regressionsmodells. Wir spezifizieren ein Generalisiertes Additives Modell (GAM) mit Tensorprodukt-Interaktionen²⁹:

$$\begin{aligned} \ln(\text{Miete}_i) = & \beta_0 + te(\text{Fläche}_i, \ln(\text{Einkommen}_i)) + \sum_j \gamma_j \text{Bundesland}_{ij} \\ & + \sum_k \delta_k \text{Gemeindegröße}_{ik} + \sum_l \theta_l \text{Heizungstyp}_{il} + \varepsilon_i \end{aligned} \quad (\text{A.9})$$

²⁷Zur Inanspruchnahmequote liegt uns keine offizielle Größenordnung vor. Empirische Studien schätzen die Nicht-Inanspruchnahme von Arbeitslosengeld II (inklusive KdU) auf bis zu 49–67%; diese tritt vor allem bei geringen Ansprüchen auf, wodurch die Transfervolumina weniger stark überschätzt werden, da hohe Ansprüche wahrscheinlicher genutzt werden und den Großteil des Transfervolumens in Deutschland ausmachen (Bruckmeier und Wiemers, 2012).

²⁸Die pauschale Steuerbelastung von 30% für Vermietungseinkünfte (netto kalt) in Deutschland basiert auf einer Approximation für die heterogene Vermieterschaft. Das oberste Einkommensperzentil weist einen effektive (inklusive Abschreibungen und Ähnlichem) Durchschnittssteuersatz von circa 30% auf (Bach et al., 2013). Unter der Annahme, dass Vermieter eher wohlhabend sind, stellt dies für den privaten Bereich eine geeignete Annäherung dar. Für gewerbliche Vermieter liegen effektive Sätze aufgrund von Körperschaft- und Gewerbesteuer im ähnlichen Bereich, ohne die vielseitigen unternehmerischen Steueroptimierungsmöglichkeiten zu betrachten.

²⁹Die Tensorprodukt-Spezifikation folgt Wood (2006), der deren Vorteile bei unterschiedlich skalierten Variablen (hier: Wohnfläche in m^2 vs. log-Einkommen) nachweist.

Der Tensorprodukt-Term $te(\cdot, \cdot)$ erfasst die empirisch beobachtete einkommensabhängige Bewertung von Wohnfläche: Haushalte mit höherem Einkommen weisen eine um 89% höhere marginale Zahlungsbereitschaft für zusätzliche Quadratmeter auf. Diese Interaktion ist essentiell für die realistische Modellierung heterogener Nachfragereaktionen (siehe Anhang A.2 V für ökonometrische Details). Die kategorischen Variablen Bundesland (16 Kategorien), Gemeindegröße (9 Kategorien) und Heizungstyp kontrollieren für regionale und gebäudespezifische Heterogenität.³⁰

Die Schätzung basiert auf 19.635 Haushalten, die in den Jahren 2017 oder 2018 eingezogen sind und somit angenommen wird, dass die Haushalte aktuelle Neuvertragsmieten zahlen. Diese kürzlich ein- oder umgezogene Haushalte und deren Mieten repräsentieren die aktuellen (Stand: analog zum Mikrozensus-Erhebungsjahr 2018) Marktbedingungen. Das geschätzte Modell, welches ein $R^2 = 0,446$ erreicht, wird auf alle Miethaushalte in der Stichprobe angewendet, um deren hypothetische Neuvertragsmiete zu prognostizieren – die Miete, die sie bei heutiger Wohnungssuche zahlen müssten. Diese Modellgüte ist für hedonische Querschnittsmodelle ohne Mikrolage- und Modernisierungsinformationen typisch. Wichtige Kovariate wie der konkrete Modernisierungsstand, die exakte Mikrolage innerhalb der Mietstufe oder die energetische Ausstattung sind im SUF-Mikrozensus nicht enthalten; die Tensorprodukt-Spezifikation fängt nichtlineare Heterogenität in Wohnfläche und Einkommen jedoch flexibel auf, und die kategorialen Kontrollen (Bundesland, Gemeindegröße, Heizungstyp) absorbieren regionale und gebäudespezifische Heterogenität. Eine systematische Verzerrung der individuellen Neuvertragsmieten-Schätzungen ist daher trotz der datenbedingten Heuristik nicht zu erwarten. Die Out-of-Sample-Validierung zeigt einen mittleren absoluten prozentualen Fehler (MAPE) von 8,3%, was die Prognosegüte bestätigt. Nach Zuweisung der Neuvertragsmieten erfolgt ein finaler Plausibilitätsfilter, der unplausible Abweichungen zwischen Status-Quo und prognostizierter Neuvertragsmiete eliminiert.

Anpassungsreaktion der Mieter

Die Einführung eines Neuvertragsmietniveaus als Reformschock wird dynamisch modelliert, wobei die Anpassungsreaktion der Mieter aus Querschnittsdaten approximiert wird. Da Haushalte im Mittel mit höheren Mietpreisen konfrontiert werden, ist die zentrale Frage, wie sie ihren Wohnkonsum anpassen würden. Methodisch nutzen wir die beobachtete Variation zwischen ähnlichen Haushalten, die unterschiedlich große Differenzen zwischen Neuvertrags- und Bestandsmieten aufweisen. Diese Querschnittsvariation interpretieren wir als Proxy für die erwartete Anpassungsreaktion.³¹ Die Spezifikation lautet:

³⁰Die probabilistisch zugewiesene Mietstufe wird nicht separat modelliert, da ihre Variation vollständig durch die inkludierten fixen Effekte für Bundesland und Gemeindegröße erklärt werden kann. Eine zusätzliche Aufnahme würde redundante Information einführen und die Modellidentifikation gefährden.

³¹Unsere Identifikationsstrategie basiert auf der Annahme, dass Haushalte mit ähnlichen Charakteristika, aber unterschiedlichen Preisdifferenzen im Querschnitt, die potentielle Reaktion auf Preisänderungen offen-

$$\ln(h_i) = \beta_0 + \beta_1 \ln(y_i) + \beta_2 n_i + \sum_{j=1}^6 \gamma_j M_{ji} + \sum_k \delta_k G_{ki} + \sum_{l=1}^4 \theta_l [\Delta p_i]^l + \varepsilon_i \quad (\text{A.10})$$

wobei h_i die Wohnfläche, y_i das Haushaltsnettoeinkommen, n_i die Haushaltsgröße, M_{ji} Dummy-Variablen für die Mietstufe, G_{ki} Dummy-Variablen für das Einzugsjahr und $\Delta p_i = \ln(p_{nvm,i}) - \ln(p_{nkm,i})$ die logarithmierte Preisdifferenz zwischen Neuvertrags- und Bestandsmiete darstellt. Die zentrale Identifikationsannahme ist, dass bei Kontrolle für Einkommen, Haushaltsgröße, Region und Einzugszeitpunkt die verbleibende Variation in der Preisdifferenz quasi-zufällig ist und die korrespondierende Variation in der Wohnfläche die Anpassungsreaktion approximiert.³² Die Schätzung basiert auf 100.366 Haushalten und erreicht ein R^2 von 0,456. Zur Berücksichtigung der nachgewiesenen Heteroskedastizität (Breusch-Pagan: $\chi^2 = 179,50$, $p < 0,001$)³³ verwenden wir robuste Standardfehler (HC1), die valide Inferenz ohne Änderung der Punktschätzer gewährleisten (vgl. Anhang A.2 VI für weitere ökonometrische Details). Das geschätzte Modell impliziert eine mittlere Nachfrageelastizität von etwa -0,6: Eine Mieterhöhung um 10% führt durchschnittlich zu einer Wohnflächenreduktion um 6%. Die polynomiale Spezifikation erfasst dabei nicht-lineare Effekte – stärkere Reaktionen bei moderaten Preisschocks, abflachende Anpassungen bei extremen Schocks.

Iterative Gleichgewichtsbestimmung Das geschätzte Nachfragemodell wird in einem iterativen Verfahren³⁴ verwendet, um die simultane Anpassung von Mieten und Wohnflächen zu simulieren:

1. **Ausgangszustand:** Haushalte konsumieren Wohnfläche h_0 zu Bestandsmiete p_{nkm} .
2. **Reformschock:** Mieten ändern sich auf Neuvertragsniveau p_{nvm} (typischerweise $p_{nvm} > p_{nkm}$).
3. **Nachfrageanpassung:** Haushalte reduzieren typischerweise im Durchschnitt ihre Wohnfläche gemäß geschätztem Modell auf $h_1 < h_0$.

baren. Während dies keine klassische Nachfrageschätzung darstellt, folgt der Ansatz der Logik hedonischer Modelle, die Querschnittsvariation zur Inferenz nutzen (Rosen, 1974). Die Verwendung flexibler funktionaler Formen (etwa durch Transformationen von Einkommen und Preisen) ermöglicht nicht-lineare Anpassungen analog zu Goodman (1988).

³²Diese Annahme impliziert, dass zwei ansonsten identische Haushalte mit unterschiedlichen Preisdifferenzen im Querschnitt Informationen über die erwartete Reaktion eines Haushalts auf eine entsprechende Preisänderung liefern. Dies erfordert die Annahme stabiler Präferenzen innerhalb von Haushaltsgruppen.

³³Die Heteroskedastizität ist ökonomisch plausibel: Haushalte mit größeren Wohnungen zeigen heterogenere Präferenzen und damit höhere Residualvarianz. Die robusten Standardfehler beeinflussen nur die statistische Inferenz, nicht die Prognosen oder das Gleichgewicht.

³⁴Die iterative Simulation von Preis- und Nachfrageanpassungen orientiert sich an Ansätzen wie Méré et al. (2023), die mit einem agentenbasierten Modell und granularen Haushaltsdaten schrittweise Gleichgewichte in Mietmärkten nach Marktshocks bestimmen.

4. **Marktreaktion:** Die aggregierte Nachfragereduktion führt zu einem Angebotsüberhang. Die Mietpreise passen sich an:

$$p_{t+1} = p_t \cdot \left(1 + \lambda \cdot \frac{\Delta h_t}{h_t} \right) \quad (\text{A.11})$$

wobei λ die Angebotsreaktion parametrisiert: $\lambda = 0,3$ für Mietstufen 5-6 (angespannte Märkte) und $\lambda = 0,5$ für andere Mietstufen.³⁵

5. **Konvergenz:** Iteration der Schritte 3-4 bis $|\Delta p_t| < 0,001$ und $|\Delta h_t| < 0,01$.

Der Gleichgewichtsprozess generiert für jeden Haushalt individuelle Gleichgewichtsmieten p_i^* und -wohnflächen h_i^* , die die Grundlage für die Wohlfahrtsanalyse bilden (siehe Kapitel A.2.4 für mikroökonomische Fundierung).

Simulationsszenarien und Wohlfahrtsanalyse

Unsere Methodik generiert drei Szenarien, die verschiedene Marktzustände abbilden und deren systematischer Vergleich die Wohlfahrtseffekte einer hypothetischen Mietmarktreform quantifiziert.

Das erste Szenario bildet den Status Quo ab, in dem Bestands- und Neuvertragsmieten koexistieren. Langjährige Mieter zahlen historisch gewachsene Bestandsmieten, während Neumieter zu aktuellen Marktpreisen kontrahieren. Dieses Szenario basiert auf den beobachteten Mieten des Mikrozensus 2018 und den daraus resultierenden Transferleistungen, die das tatsächliche Mietniveau reflektieren.

Das zweite Szenario modelliert den unmittelbaren Effekt einer hypothetischen Angleichung aller Mieten auf Neuvertragsniveau. In diesem kurzfristigen Schockszenario zahlen alle Haushalte die modellierten Neuvertragsmieten bei zunächst unveränderter Wohnfläche. Diese statische Betrachtung ohne Verhaltensanpassungen isoliert den reinen Preiseffekt der Reform und quantifiziert die maximale Umverteilung zwischen Mietern und Vermietern sowie die unmittelbaren fiskalischen Konsequenzen.

Das dritte Szenario beschreibt das langfristige Marktgleichgewicht, in dem Haushalte ihren Wohnkonsum an veränderte Preise anpassen und Vermieter auf Nachfrageänderungen reagieren. Durch den iterativen Prozess entstehen Gleichgewichtsmieten und -mengen, die sowohl individuelle Präferenzen als auch Marktbedingungen berücksichtigen.

³⁵Die Preisanpassungselastizitäten ($\lambda = 0,3$ für angespannte, $\lambda = 0,5$ für entspannte Märkte) orientieren sich an empirischen Befunden zu kurzfristigen Marktreaktionen (Arnott und Igarashi, 2000). Die Differenzierung reflektiert unterschiedliche Marktmacht der Vermieter je nach Angespanntheit und Beliebtheit des Standortes.

Die zentrale wissenschaftliche Fragestellung adressiert die Gesamtwohlfahrtswirkung der Reform durch Vergleich des Gleichgewichtsszenarios mit dem Status Quo. Diese Analyse quantifiziert, ob die Angleichung von Bestands- an Neuvertragsmieten wohlfahrtssteigernd oder -mindernd wirkt, wenn alle Marktanpassungen berücksichtigt werden. Der Nettowohlfahrtseffekt ergibt sich aus der Aggregation über Konsumentenrente (Mieter), Produzentenrente (Vermieter) und fiskalische Effekten (Staat).

A.2.4 Mikroökonomische Fundierung

Nutzenfunktionen der Haushalte

Während die vorherigen Abschnitte die empirische Schätzung der Wohnflächenanpassung beschreiben, erfordert eine wohlfahrtstheoretische Bewertung eine möglichst umfassende mikroökonomische Fundierung. Wir verwenden eine Cobb-Douglas-Nutzenfunktion zur Approximation der Haushaltspräferenzen:

$$U(h, c) = h^\alpha c^{1-\alpha} \quad (\text{A.12})$$

wobei h der Wohnungskonsum, c der Nicht-Wohnungskonsum und α der Präferenzparameter für Wohnen ist.³⁶ Diese stilisierte Nutzenfunktion dient als konsistenter Rahmen zur Wohlfahrtsmessung über alle Haushalte. Der Parameter α wird aus den empirisch beobachteten und geschätzten Wohnentscheidungen kalibriert.³⁷ Konkret nutzen wir die geschätzte Wohnflächenanpassung h^* bei Neuvertragsmietniveau p und gegebenem Einkommen y zur Bestimmung des impliziten Präferenzparameters:

$$\alpha_i = \frac{h_i^* \cdot p_i}{y_i} \quad (\text{A.13})$$

Diese haushaltsindividuelle Kalibrierung erfasst die Heterogenität in den Wohnpräferenzen, die sich aus unterschiedlichen Lebensumständen, regionalen Gegebenheiten und soziodemographischen Faktoren ergibt.³⁸ Der Nicht-Wohnungskonsum wird residual bestimmt:

$$c = y - (p \cdot h) \quad (\text{A.14})$$

Mit diesen kalibrierten Parametern können wir das Nutzenniveau jedes Haushalts in den verschiedenen Simulationsszenarien bestimmen.

³⁶Die Cobb-Douglas-Spezifikation unterstellt konstante Ausgabenanteile und eine Substitutionselastizität von 1 zwischen Wohnen und anderen Gütern. Dies ist restriktiv, ermöglicht aber eine analytisch handhabbare Wohlfahrtsanalyse.

³⁷Die Kalibrierung von Präferenzparametern aus beobachtetem Verhalten ist Standard in der angewandten Wohlfahrtsanalyse. Dies ermöglicht eine strukturelle Interpretation der reduzierten Form-Schätzungen.

³⁸Die Variation in α reflektiert sowohl Präferenzheterogenität als auch nicht modellierte Restriktionen wie Mindestflächenbedarf bei Familien oder eingeschränkte Mobilität bei älteren Haushalten.

Wohlfahrtsanalyse

Die Wohlfahrtsanalyse quantifiziert die Auswirkungen der Reform auf Mieter, Vermieter und den Staat.³⁹ Für Mieter verwenden wir die äquivalente Variation (EV) als Wohlfahrtsmaß, die den Geldbetrag angibt, der einen Haushalt zwischen Status quo und Gleichgewicht indifferent stellen würde:

$$EV_i = y_i \left[1 - \left(\frac{p_1}{p_0} \right)^{\alpha_i} \right] \quad (\text{A.15})$$

wobei p_0 die Ausgangsmiete und p_1 die jeweilige Gleichgewichtsmiete nach der Reform bezeichnet. Eine negative EV indiziert einen Wohlfahrtsverlust.⁴⁰ Die aggregierte Mieterwohl-fahrt ergibt sich aus der gewichteten Summe über alle Haushalte, hochgerechnet auf die deutsche Mieterpopulation.

Auf der Vermieterseite quantifizieren wir Wohlfahrtsänderungen durch die Veränderung der effektiven Mieteinnahmen nach Abzug der Steuer. Da unsere Daten keine Vermietercharakteristika enthalten, modellieren wir die Vermieterschaft als aggregierten Akteur.⁴¹

$$\Delta R = (1 - \tau) \sum_{i=1}^N (p_{1,i} h_{1,i} - p_{0,i} h_{0,i}) \quad (\text{A.16})$$

Die fiskalischen Effekte umfassen drei Komponenten. Erstens ändern sich die Wohngeldausgaben durch veränderte Mietniveaus und durch Änderungen in der Anzahl der Anspruchsberechtigten. Zweitens beeinflussen die Mietänderungen die staatlichen Ausgaben für KdU bei Transferempfängern. Drittens generieren veränderte Vermietereinkommen Steuereffekte. Der Netto-Fiskaleffekt (hier als Mehreinnahmen definiert) beträgt:

$$\Delta F = \tau \Delta R - \Delta W - \Delta K \quad (\text{A.17})$$

wobei ΔW die Wohngeldänderung, ΔK die KdU-Änderung und τ den effektiven Steuersatz auf die veränderten Mieteinnahmen der Vermieter (angenommen mit 30%) darstellt.⁴²

Der Gesamtwohlfahrtseffekt aggregiert über alle Akteure ist folglich:

³⁹Die folgende Partialanalyse abstrahiert von allgemeinen Gleichgewichtseffekten auf andere Märkte, Substitution zwischen Miete und Eigentum sowie Umzugsentscheidungen. Wir nehmen an, dass Haushalte in ihrer aktuellen Wohnung verbleiben und nur die Wohnfläche anpassen können.

⁴⁰Diese Formel approximiert die exakte EV unter der Annahme, dass die Einkommenseffekte klein sind relativ zum Gesamteinkommen. Bei durchschnittlichen Wohnkostenquoten von 27% ist diese Approximation gerechtfertigt.

⁴¹Die Behandlung der Vermieter als homogener Akteur abstrahiert von Heterogenität in Kostenstrukturen und Marktmacht. Implizit nehmen wir an, dass Vermieter keine Anpassungskosten haben und Leerstand sofort auf dem Markt angeboten wird.

⁴²Der effektive Steuersatz von 30% approximiert die durchschnittliche Grenzsteuerbelastung von Vermietungseinkünften nach Abzug von Werbungskosten. Dies abstrahiert von progressiven Steuersätzen und unterschiedlichen Eigentümerstrukturen.

$$\Delta W_{total} = \sum_i EV_i + \Delta R + \Delta F \quad (\text{A.18})$$

Ein negativer Gesamteffekt würde auf Effizienzverluste durch die Reform hindeuten. Unabhängig vom Vorzeichen des Gesamteffekts analysieren wir die Verteilungswirkungen zwischen verschiedenen Einkommensgruppen und Regionen, da selbst paretoverbessernde Reformen mit erheblichen Umverteilungseffekten einhergehen können.⁴³

A.2.5 Ergebnisse

Dieser Abschnitt präsentiert die zentralen Ergebnisse unserer Simulation. Zunächst werden die Charakteristika der Miethaushalte im Status Quo analysiert. Anschließend erfolgt ein detaillierter Vergleich zwischen Status Quo und Neuvertragsmieten, gefolgt von der Analyse der Mietbelastung. Anschließend wird der iterative Gleichgewichtsprozess dargestellt. Außerdem werden die fiskalischen Auswirkungen betrachtet. Zuletzt werden die Ergebnisse in einer Gesamtwohlfahrtsanalyse eingeordnet.

Status Quo: Charakteristika der Miethaushalte


Haushaltsstruktur und Wohnfläche Die Analyse basiert auf 100.366 Miethaushalten, die hochgerechnet 19,6 Millionen deutsche Miethaushalte repräsentieren.⁴⁴ Die Struktur dieser Haushalte determiniert maßgeblich die Reformauswirkungen. Abbildung A.11 zeigt die Dominanz kleiner Haushalte: 49,6% der Miethaushalte sind Ein-Personen-Haushalte, weitere 30,4% entfallen auf Zwei-Personen-Haushalte. Zusammen repräsentieren diese beiden Gruppen knapp acht von zehn Miethaushalten, was die späteren Reaktionsmuster bei Mietschocks maßgeblich prägt. Die durchschnittliche Wohnfläche beträgt 71m² (Median: 66m²), wobei die Pro-Kopf-Fläche erwartungsgemäß mit der Haushaltsgröße sinkt (Abbildung A.12): von 62m² bei Alleinstehenden auf 22m² bei Haushalten mit fünf oder mehr Personen. Diese Skaleneffekte sind zentral für die spätere Anpassungsreaktion.⁴⁵ Die Konzentration auf kleine Haushalte hat Implikationen für die Reformwirkungen: Diese Haushalte weisen geringere Einkommenspuffer auf und können Mieterhöhungen schlechter durch Wohnflächenreduktion kompensieren, da sie bereits nahe am Minimum operieren. Die durchschnittliche Wohnfläche von 49m² bei Alleinstehenden lässt wenig Spielraum für weitere Reduktionen ohne Unterschreitung sozial akzeptabler Standards.

⁴³Diese Wohlfahrtsberechnung gewichtet alle Geldäquivalente gleich (keine soziale Wohlfahrtsfunktion mit Ungleichheitsaversion). Zudem abstrahieren wir von Transaktionskosten und Kosten der Anpassung durch veränderte Wohnumstände.

⁴⁴Die Hochrechnung erfolgt mittels angepasster Mikrozensus-Gewichte. Die tatsächliche Anzahl der Miethaushalte im Jahr 2018 betrug laut Statistischem Bundesamt (2020) 19,9 Millionen.


⁴⁵Für detaillierte Analysen zur regionalen Wohnflächenverteilung vgl. Anhang A.2 VII. Die durchschnittliche Wohnfläche variiert zwischen 65m² in Stadtstaaten und über 72m² in Baden-Württemberg (siehe Abbildung An.22).

Abbildung A.11: Verteilung der Haushaltsgrößen




Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 vor 1%-Tail-Filterung.

Abbildung A.12: Wohnflächenverteilung und Pro-Kopf-Fläche



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 vor 1%-Tail-Filterung.

Abbildung A.13: Einkommensverteilung der Miethaushalte



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 vor 1%-Tail-Filterung.

Einkommensstruktur Die Verteilung der monatlichen Nettohaushaltseinkommen der Miethaushalte, dargestellt in Abbildung A.13 (linker Teil), weist eine deutliche Rechtsschiefe auf. Dies wird durch den Mittelwert von 2.371€, der signifikant über dem Median von 2.000€ liegt, bestätigt. Ein Großteil der Miethaushalte konzentriert sich im unteren bis mittleren Einkommensbereich von 1.000€ bis 3.000€, während eine lange Ausprägung zu höheren Einkommen hin existiert. Die Quintilsanalyse (rechter Teil) verdeutlicht das Ausmaß der Einkommensspreizung: Das unterste Quintil (Q1) verfügt im Durchschnitt über lediglich 898€, während das oberste Quintil (Q5) durchschnittlich 4.878€ erreicht.

Diese ausgeprägte Einkommensungleichheit unter den Miethaushalten ist fundamental für die Bewertung der Verteilungswirkungen der simulierten Regulierungsreform. Da Ausgaben für Wohnen typischerweise einen degressiven Anteil am Einkommen ausmachen – also bei niedrigeren Einkommen einen größeren Prozentsatz des Budgets beanspruchen (wie später in Abbildung A.20 quantifiziert) –, legt die hier dokumentierte Einkommenskonzentration im unteren Bereich nahe, dass eine allgemeine Anhebung der Mieten regressive Effekte nach sich ziehen könnte. Das heißt, einkommensschwächere Haushalte würden relativ zu ihrem Einkommen stärker belastet als einkommensstärkere Haushalte, selbst wenn die absoluten Mieterhöhungen moderat ausfielen.

Darüber hinaus tragen regionale Einkommensunterschiede, insbesondere das bekannte West-Ost-Gefälle (detailliert in Anhang An.21), zur Heterogenität der Reformauswirkungen bei. Regionen mit strukturell niedrigeren Durchschnittseinkommen dürften im Mittel vulnerabler gegenüber den simulierten Mietanpassungen sein.⁴⁶

Status Quo vs. Neuvertragsmieten (Schockeffekt)

Die Modellierung der Neuvertragsmieten basiert auf einer hedonischen Regression (siehe Anhang A.2 V) und zeigt systematische Unterschiede zu Bestandsmieten.

Mietpreisvergleich Der Vergleich zwischen den beobachteten Bestandsmieten (Status Quo) und den modellierten Neuvertragsmieten (NVM) offenbart systematische Unterschiede, wie in Abbildung A.14 dargestellt. Zunächst zeigt die Verteilung der Monatsmieten (oberes linkes Panel) eine deutliche Rechtsverschiebung der Neuvertragsmieten. Dies spiegelt sich in den statistischen Kennzahlen wider (oberes rechtes Panel): Die mittlere Neuvertragsmiete liegt mit 490€ um 51€ (+11,6%) über der mittleren Bestandsmiete von 439€. Auch der Median steigt von 405€ auf 471€. Gleichzeitig reduziert sich die Streuung der Neuver-

⁴⁶Zusätzlich sinkt das verfügbare Pro-Kopf-Einkommen tendenziell mit zunehmender Haushaltsgröße (von circa 1.600€ bei Ein-Personen-Haushalten auf unter 700€ bei Fünf-Personen-Haushalten), was auf Haushalts-Skaleneffekte, aber auch auf die Einkommenssituation von Familien mit Kindern hinweist (siehe Anhang An.20). Dies kann die Anpassungsfähigkeit größerer Haushalte im unteren Einkommenssegment weiter einschränken.

tragsmieten signifikant, was sich in einer geringeren Standardabweichung und einer visuell komprimierteren Dichtefunktion äußert (vgl. unteres rechtes Panel für €/m²). Diese Verdichtung um ein höheres Niveau könnte teils auf die Glättungseigenschaften des Schätzmodells der Neuvertragsmieten zurückzuführen sein, deutet aber auch auf eine potenziell geringere Varianz im Neuvertragssegment selbst hin.


Der Quantil-Quantil-Vergleich (unteres linkes Panel) visualisiert die distributional unterschiedlichen Effekte. Die Kurve verläuft durchgehend oberhalb oder auf der 45-Grad-Linie, was bestätigt, dass die modellierten Neuvertragsmieten in allen Segmenten tendenziell höher sind als die Bestandsmieten. Besonders ausgeprägt ist der Abstand im unteren Bereich: Haushalte mit aktuell niedrigen Bestandsmieten würden die größten relativen Mietsteigerungen erfahren, um das geschätzte Neuvertragsniveau zu erreichen. Mit steigenden Quantilen nähert sich die Kurve der Diagonalen an, was auf geringere relative Unterschiede im oberen Marktsegment hindeutet, auch wenn die absoluten Differenzen dort am größten sein können.

Zusammenfassend lässt sich feststellen, dass die Simulation nicht nur ein generell höheres Mietniveau für Neuverträge ergibt, sondern auch eine Nivellierung des Marktes nahelegt: Die Preisspanne, vor allem im unteren Bereich, verengt sich, und die Verteilung wird homogener. Diese Nivellierung auf höherem Niveau hat direkte Konsequenzen für die nachfolgende Mietbelastungs- und Wohlfahrtsanalyse.

Verfügbares Einkommen (Schockeffekt) Die unmittelbare finanzielle Auswirkung dieses Preisschocks auf das verfügbare Einkommen nach Mietzahlung wird in Abbildung A.15 detailliert. Im Gesamtvergleich (oben links) sinkt das mediane verfügbare Einkommen von 1.556€ im Status Quo auf 1.486€ unter dem zugeordneten Neuvertragsmietniveau. Die Analyse nach Haushaltsgröße (oben rechts) und Mietstufe (unten links) zeigt jedoch eine heterogene Betroffenheit: Absolute Verluste sind tendenziell bei größeren Haushalten und in mittleren Mietstufen am höchsten. Die Verteilung der Einkommensänderung (unten rechts) verdeutlicht das Ausmaß der Umverteilung: Etwa 69% der Miethaushalte wären durch den Schock finanziell schlechter gestellt (Medianverlust: 57€), während 31% aufgrund ihrer bereits im Status Quo hohen Mieten (nahe oder über dem modellierten NVM) keine Einbußen oder sogar leichte Verbesserungen verzeichnen würden.


Mietbelastungsanalyse (Schockeffekt) Korrespondierend zum verfügbaren Einkommen verschärft sich die relative Wohnkostenbelastung im Schockszenario, wie Abbildung A.16 darstellt. Die Gesamtverteilung der Mietbelastungsquote (oben links) erfährt eine deutliche Rechtsverschiebung; die Dichte verschiebt sich hin zu höheren Belastungswerten, was die Kurve flacher und breiter erscheinen lässt. Der Anteil der Haushalte mit einer als kritisch betrachteten Belastung von über 30% steigt von 20,7% im Status Quo auf 28,0% im

Abbildung A.14: Vergleich: Status Quo vs. Neuvertragsmieten



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 vor 1%-Tail-Filterung.


Abbildung A.15: Verfügbares Einkommen: Detailanalyse



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 vor 1%-Tail-Filterung.

NVM-Szenario (unten links). Die Analyse nach Einkommensquintilen (oben in der Mitte) bestätigt das im vorherigen Abschnitt antizipierte regressive Muster: Die durchschnittliche Belastung steigt im untersten Quintil (Q1) von bereits hohen 34% auf über 38%, während sie im obersten Quintil (Q5) nur marginal von ca. 14% auf 15% anwächst. Auch nach Haushaltstyp (oben rechts) zeigen sich Unterschiede, wobei Alleinstehende die höchsten Quoten aufweisen. Die Verteilung der Veränderung der Mietbelastungsquote (unten in der Mitte) hat ihren Schwerpunkt bei +1,1 Prozentpunkten, zeigt jedoch eine erhebliche Streuung. Die regionale Betrachtung (unten rechts) nach Bundesländern offenbart ebenfalls heterogene Anstiege der Durchschnittsbelastung. Diese unmittelbare Erhöhung der Belastungsquoten, insbesondere für vulnerable Gruppen, bildet den Anreiz für die nachfolgend modellierten Anpassungsreaktionen.

Abbildung A.16: Mietbelastungsquote im Vergleich




Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 vor 1%-Tail-Filterung.

Gleichgewichtsanpassungsprozess

Der durch die Angleichung an Neuvertragsmieten ausgelöste Preisschock induziert Anpassungsreaktionen von Mietern (primär Reduktion der Wohnfläche) und Vermietern (Preisreaktion auf Nachfrageänderung), die in einem iterativen Prozess zu einem neuen Marktgleichgewicht konvergieren. Abbildung A.17 visualisiert diesen Prozess anhand von Medianwerten für zentrale Marktindikatoren.

Abbildung A.17: Gleichgewichtskonvergenz - Medianwerte



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 nach 1%-Tail-Filterung.


Konvergenzdynamik Abbildung A.17 zeigt, dass der Markt nach dem Preisschock rasch zu einem stabilen Zustand findet. Die Quadratmetermiete stabilisiert sich nach zwei Iterationen⁴⁷ bei einem Durchschnitt von 7,33€ beziehungsweise einem Median von 7,05€ – leicht unter dem initialen Schockniveau. Die Wohnfläche reduziert sich von 68,6m² auf 63,5m²

⁴⁷Der iterative Prozess konvergiert schnell zu einem stabilen Gleichgewicht, da die geringe Elastizität der Nachfrage und angenommen Elastizität der Angebotsseite (0,3 bis 0,5) kleine Anpassungen erzeugen, die bereits nach wenigen Iterationen in den Nachkommastellen liegen. Gegeben dem externen Preisschock fallen die Preisanpassungen nach unten durch geringere Nachfrage aus, ohne vollständige Markträumung zu erreichen; stattdessen entsteht ein stabiler Zustand mit Leerstand, der in Wohnungsmärkten normal ist und auch als „natürliche Leerstandsquote“ bezeichnet wird (Gabriel und Nothaft, 2001).

(-7,4%). Die schnelle Konvergenz (7,4% Leerstand nach erster Nachfrageanpassung) deutet auf die gering angenommen Elastizitäten der Vermieterseite hin (siehe Anhang [An.23](#) für die Entwicklung der Durchschnittswerte). Abbildung [A.17](#) zeigt die entsprechenden Medianwerte, die einen ähnlichen Konvergenzverlauf aufweisen. Die unelastische Mietnachfrage mit einer Preiselastizität von -0,6 reflektiert die Besonderheit des Wohnungsmarktes: Wohnen ist ein Grundbedürfnis mit hohen Friktionskosten und begrenzten Substitutionsmöglichkeiten. Dies impliziert, dass Preisschocks primär über Einkommenseffekte wirken und weniger über Mengenanpassungen kompensiert werden können.

Aggregierte Mietausgaben Die gesamten Mietausgaben (Abbildung [A.18](#)) steigen von 101,5 Mrd.€ im Status Quo auf 115,3 Mrd.€ nach initialem Schock (+13,6%), konvergieren dann auf 107,4 Mrd.€ im Gleichgewicht (+5,8%). Die Differenz zwischen Schock und Gleichgewicht (7,9 Mrd.€) reflektiert die Anpassungskapazität der Haushalte. Diese 7,9 Mrd.€ quantifizieren die aggregierte Konsumentenreaktion: Haushalte substituieren 7,4% Wohnfläche gegen anderen Konsum und die mittlere Miete reduziert sich durch den Konvergenzprozess leicht im Vergleich zum initialen Schock, wodurch der Ausgabenanstieg von 13,6% auf 5,8% sinkt. Für die Vermieterseite bedeutet die um 5,8 Mrd.€ gestiegenen Mieteinnahmen, dass bei einer effektiven Besteuerung von 30% rund 4,09 Mrd.€ netto an zusätzlichen Einkommen verbucht werden können.


Abbildung A.18: Gesamte Mietausgaben nach Szenario



Eigene Berechnung und Darstellung. *Anmerkung:* Dargestellt sind auf die Grundgesamtheit Deutschland hochgerechnete (vgl. [A.2.3](#)) Werte.

Verteilungseffekte im Gleichgewicht

Abbildung A.19: Mietbelastung: Detailanalyse nach Gruppen




Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 nach 1%-Tail-Filterung.

Mietbelastung im Gleichgewicht Die Analyse der Verteilungseffekte fokussiert nun auf den Gleichgewichtszustand im Vergleich zum Status Quo. Abbildung A.19 zeigt die Auswirkungen auf die Mietbelastungsquoten nach erfolgter Marktanpassung. Die durchschnittliche Mietbelastungsquote (oben rechts) liegt im Gleichgewicht mit 24,1% zwar unter dem Schockniveau (25,7%), aber immer noch deutlich über dem Status Quo (22,6%). Die Gesamtverteilung der Belastungsquoten (unten links, orange Kurve) hat sich gegenüber dem Schock (rot) leicht nach links verschoben, bleibt aber klar rechts von der Ausgangsverteilung (blau). Dies bestätigt sich im Boxplot-Vergleich (oben links), wo Median und Quartile im Gleichgewicht höher liegen als im Status Quo. Auch der Anteil der Haushalte mit einer Belastung von über 30% bleibt im Gleichgewicht erhöht. Abbildung A.20 bestätigt, dass das regressive Muster der Belastungsänderung auch im Gleichgewichtszustand fortbesteht. Die durchschnittliche Mietbelastungsquote für das unterste Einkommensquintil (Q1) stabilisiert sich bei ca. 37% – ein deutlicher Anstieg gegenüber den 34% im Status Quo. Im Gegensatz dazu erhöht sich die Quote für das oberste Quintil (Q5) nur geringfügig von ca. 14% auf knapp 15%. Die Marktanpassungen mildern zwar den initialen Schock, ändern aber nichts

an der grundsätzlichen regressiven Verteilungswirkung der Reform: Einkommensschwache Haushalte tragen auch im Gleichgewicht die relativ höchste Mehrbelastung. Dies spiegelt sich auch im mittleren verfügbaren Einkommen nach Miete wider (vgl. Abbildung A.19, unten rechts), das sich im Gleichgewicht zwar leicht vom Schockniveau (1.785€) auf 1.819€ erholt, aber unter dem Status Quo (1.844€) verbleibt – die Marktanpassungen können die initialen Einkommensverluste also nur teilweise kompensieren.

Abbildung A.20: Mietbelastung nach Einkommen



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 nach 1%-Tail-Filterung.


Transferempfänger und fiskalische Auswirkungen

Die Reform hat begrenzte fiskalische Implikationen, da die regulatorischen Höchstgrenzen für Transferleistungen unverändert bleiben.

Transferempfänger Abbildung A.21 zeigt die Entwicklung der Empfängerzahlen. Wohngeldempfänger steigen von 1,02 auf 1,29 Millionen (+26,5%), während KdU-Empfänger von 2,66 auf 2,43 Millionen sinken (-8,6%). Diese Bewegung erklärt sich durch die Systematik der Transferleistungen: Steigen die Mieten, erhöht sich der Wohngeldanspruch innerhalb dieser Grenzen mechanisch über die Formel und kann das durch KdU erreichbare Leistungsniveau übersteigen; genau in diesen Grenzbereichen kommt es zur in Abbildung A.21 sichtbaren Substitution zugunsten des Wohngeldes. Die Gesamtzahl der geförderten Haushalte ändert sich dagegen nur moderat. Das Muster ist mit der Logik beider Systeme konsistent. Sowohl

beim Wohngeld als auch bei KdU wirken regionale Obergrenzen für die anerkannten Wohnkosten; innerhalb dieser Grenzen reagiert der Wohngeldanspruch unmittelbar auf höhere Mieten über die Wohngeldformel, während KdU durch die Angemessenheitsgrenzen weitgehend gedeckelt bleibt. In der Abbildung spiegelt sich dies als Verschiebung von KdU zu Wohngeld wider, die vor allem in Schwellenbereichen auftritt: Haushalte, die bereits knapp an den jeweiligen Grenzen lagen (einschließlich „Aufstockern“), werden bei steigenden Mieten im Schock- und im Gleichgewichtsszenario häufiger durch Wohngeld besser gestellt als durch KdU und wechseln entsprechend.

Abbildung A.21: Empfängerhaushalte von Transferleistungen



Eigene Berechnung und Darstellung. *Anmerkung:* Dargestellt sind auf die Grundgesamtheit Deutschland hochgerechnete (vgl. A.2.3) Werte. Balken nach Szenario (Status Quo, Schock, Gleichgewicht).


Die Neuaufnahme von Transferempfängern beschränkt sich auf Grenzfälle – Haushalte, deren Mietbelastung durch die Reform erstmals die Anspruchsschwellen überschreitet.⁴⁸ Die Asymmetrie zwischen 270.000 neuen Wohngeldempfängern und nur 230.000 weniger KdU-Empfängern erklärt sich folglich durch unterschiedliche Einkommensschwellen: Die Wohngeldgrenze liegt bei etwa 1.200€ für Alleinstehende, die KdU-Grenze bei 800€. Haushalte im Einkommensbereich 800-1.200€ können durch die Mieterhöhung erstmals wohngeldberechtigt werden, ohne vorher KdU-berechtigt gewesen zu sein.

Fiskalische Bilanz Die moderaten Transfervolumenänderungen resultieren aus der Konstanz der regulatorischen Parameter: Da weder Wohngeld-Höchstbeträge noch angemessene Wohnkosten angepasst werden, steigen die Transferausgaben nur für Haushalte, die bereits im Status Quo unterhalb dieser Grenzen lagen sowie neue Transferbezieher. Die jährlichen

⁴⁸Die regionale Heterogenität ist erheblich: Ostdeutsche Länder weisen Transferquoten über 20% auf, während Bayern und Baden-Württemberg unter 10% liegen (siehe Anhang An.27). Die Transferintensität korreliert mit der Mietstufe, wobei KdU in höheren Mietstufen dominiert (siehe Anhang An.26).


Transferausgaben (Abbildung A.22) erhöhen sich leicht von 8,49 auf 8,56 Mrd. € (+0,8%).⁴⁹ Diese geringe Steigerung reflektiert, dass die Mehrheit der Transferempfänger bereits an den Höchstgrenzen operiert und keine zusätzlichen Leistungen erhält.

Abbildung A.22: Jährliche Transferausgaben



Eigene Berechnung und Darstellung. *Anmerkung:* Dargestellt sind auf die Grundgesamtheit Deutschland hochgerechnete (vgl. A.2.3) Werte. Balken nach Szenario (Status Quo, Schock, Gleichgewicht).

Abbildung A.23: Fiskalische Nettobilanz



Eigene Berechnung und Darstellung. *Anmerkung:* Dargestellt sind auf die Grundgesamtheit Deutschland hochgerechnete (vgl. A.2.3) Werte.

Demgegenüber generieren die höheren Vermietereinkünfte substantielle Steuermehreinnahmen. Bei einem effektiven Steuersatz von 30% auf Vermietungseinkünfte ergeben sich Mehr-


⁴⁹Zusätzlich zur Nichtberücksichtigung von Heiz- und Betriebskosten unterschätzen die Querschnittsdaten des Mikrozensus 2018 Transfervolumina und -empfänger systematisch durch Nichtangaben bei Einkommen und Sozialleistungen sowie Nichtteilnahme-Bias (Emmenegger und Münnich, 2023), was die geringeren Volumina im Vergleich zu tatsächlichen 2018-Werten in Summe erklärt; da wir uns auf mikrosimierte Szenario-Veränderungen konzentrieren, führt dies zu keinen Verzerrungen.

einnahmen von 1,75 Mrd.€ im Gleichgewicht.⁵⁰ Der fiskalische Nettoeffekt beträgt somit +1,68 Mrd.€ (Abbildung A.23). Die Diskrepanz zwischen substantiellen Mieterhöhungen und nur marginalen Transfererhöhungen demonstriert die Rigidität des deutschen Transfer-systems: Die Fixierung der Höchstgrenzen verhindert eine automatische Stabilisierung bei Preisschocks. Von den 3,72 Millionen Transferempfängern profitieren nur etwa 560.000 von leicht erhöhten Zahlungen, während 3,16 Millionen trotz höherer Mieten keine zusätzliche Unterstützung erhalten.

Gesamtwohlfahrtseffekt

Die abschließende Analyse quantifiziert die Wohlfahrtseffekte der simulierten Reform. Die Bewertung erfolgt auf Ebene der Miethaushalte über die äquivalente Variation (EV), die den Geldbetrag misst, der Haushalte zwischen Status Quo und dem finalen Gleichgewichtszustand indifferent stellen würde.

Abbildung A.24: Wohlfahrtsanalyse: Äquivalente Variation der Miethaushalte



Eigene Berechnung und Darstellung. *Anmerkung:* Grundgesamtheit sind hier die Miethaushalte im MZ 2018 nach 1%-Tail-Filterung.

⁵⁰Die föderale Verteilung der fiskalischen Effekte wird hier nicht analysiert. In der Praxis tragen Kommunen die KdU-Lasten, während Steuereinnahmen zwischen Bund, Ländern und Kommunen aufgeteilt werden.

Verteilung der Wohlfahrtseffekte Abbildung A.24 präsentiert eine Analyse der Verteilung der Wohlfahrtsänderungen der Miethaushalte. Die Verteilung der individuellen Wohlfahrtseffekte (oberes linkes Panel) zeigt eine rechtsschiefe Verteilung mit einem Median von -36€ monatlich. Während 73% der Haushalte Wohlfahrtsverluste erleiden, erfahren die restlichen 27% der Miethaushalte keine Verluste oder sogar Wohlfahrtsgewinne im Vergleich zum Status Quo. Die einkommensabhängige Analyse (oberes rechtes Panel) offenbart systematische Muster: Die absoluten Verluste steigen monoton mit dem Einkommen von 27€ (Q1) auf 47€ (Q5) monatlich. Die relativen Belastungen (unteres linkes Panel) zeigen jedoch eine regressive Struktur: Einkommensschwache Haushalte verlieren 1,9% an Wohlfahrt gemessen als äquivalente Variation relativ zum Einkommen, während das oberste Quintil nur 0,6% einbüßt. Diese Diskrepanz erklärt sich durch die im unteren rechten Panel dargestellten Mietanteile am Einkommen: Das unterste Quintil wendet bereits im Status Quo 34% des Einkommens für Miete auf, das oberste nur 14%.

Aggregierte Wohlfahrtsbilanz Die Gesamtwohlfahrtsbilanz (Tabelle A.3) aggregiert die Effekte über alle Akteure. Der jährliche Wohlfahrtsverlust der Mieter von 5,39 Mrd.€ wird durch die zusätzlichen Vermietermehreinnahmen nach der Besteuerung von 4,09 Mrd.€ und positive fiskalische Nettoeffekte von 1,68 Mrd.€ überkompensiert, was zu einem positiven Gesamteffekt von 0,38 Mrd.€ führt.

Tabelle A.3: Gesamtwohlfahrtseffekt im Gleichgewichtszustand

Akteur	Wohlfahrtseffekt (Mrd.€/Jahr)
Mieter (äquivalente Variation)	-5,39
Vermieter ⁵¹ (Mehreinnahmen)	+4,09
Staat ⁵² (Nettofiskaleffekt)	+1,68
Gesamt	+0,38

Anmerkung: Dargestellt sind auf die Grundgesamtheit Deutschland hochgerechnete (vgl. A.2.3) Werte.

Interpretation der Ergebnisse Der positive Gesamtwohlfahrtseffekt suggeriert eine Effizienzsteigerung durch die Reform. Diese resultiert aus zwei Mechanismen: Erstens ermöglicht die Wohnflächenanpassung eine Nutzenoptimierung gemäß den individuellen Präferenzen, wodurch der tatsächliche Wohlfahrtsverlust der Mieter (5,39 Mrd.€) unter ihren monetären Mehrausgaben (5,8 Mrd.€) liegt – die Differenz von 0,41 Mrd.€ reflektiert den Nutzen Gewinn durch optimierte Wohnflächenwahl. Zweitens induziert die Reform eine effizientere Allokation durch Abbau der Verzerrungen zwischen Bestands- und Neuvertragsmarkt, was sich im entstehenden Leerstand manifestiert, der die Marktliquidität erhöht.

Die Verteilungsanalyse offenbart jedoch erhebliche Umverteilungseffekte mit regressivem Charakter. Während höhere Einkommensgruppen absolut stärkere Verluste tragen, ist die relative Belastung für einkommensschwache Haushalte deutlich höher – sie büßen 1,9% ihrer Wohlfahrt relativ zum Einkommen ein im Vergleich zu nur 0,6% im obersten Quintil. Diese asymmetrische Belastung ergibt sich aus der höheren Wohnkostenquote unterer Einkommensschichten und ihrer begrenzten Substitutionsmöglichkeiten. Die Reform wirkt somit zwar allokativ effizient, aber distributiv problematisch.

Die Zunahme des Leerstands auf 7,4% der Gesamtwohnfläche kann aus zwei Perspektiven interpretiert werden: Einerseits signalisiert sie eine Ineffizienz durch ungenutzte Ressourcen, andererseits erhöht sie die Marktliquidität und reduziert Suchkosten für mobile Haushalte. In angespannten Wohnungsmärkten kann diese Erhöhung die Funktionsfähigkeit des Marktes verbessern und Lock-in-Effekte reduzieren.

A.2.6 Limitationen der Studie

Jede Modellierung der Realität erfordert Vereinfachungen und Annahmen, die die Übertragbarkeit der Ergebnisse beeinflussen können. Auch die vorliegende Studie unterliegt verschiedenen Limitationen, die im Folgenden erörtert werden. Es ist wichtig zu betonen, dass diese Einschränkungen zwar die Komplexität der Realität reduzieren, die grundlegenden Trends und Schlussfolgerungen unserer Analyse jedoch nicht fundamental verzerren.

Eine wesentliche Limitation betrifft die Modellierung der staatlichen Transferleistungen. In unserer Simulation werden lediglich Wohngeld und KdU als relevante Transfers berücksichtigt. Dabei wird angenommen, dass jeder berechnete Haushalt den höheren der beiden Transferansprüche vollständig in Anspruch nimmt. Dies überschätzt die tatsächlichen Transfervolumina, da empirische Evidenz auf substantielle Nicht-Inanspruchnahme hindeutet. Zudem werden weitere wichtige Sozialtransfers wie Heizkostenkomponenten, Kindergeld oder ergänzende Leistungen, die ebenfalls das verfügbare Haushaltseinkommen beeinflussen, aufgrund der Datenlage des Mikrozensus nicht explizit modelliert. Diese Vereinfachungen waren aufgrund der Komplexität der deutschen Sozialgesetzgebung und der verfügbaren Daten notwendig. Sie führen zu gegenläufigen Effekten: Einerseits überschätzen wir durch die 100%-Inanspruchnahme die Transfervolumina, andererseits unterschätzen wir durch Vernachlässigung weiterer Transfers das tatsächliche Unterstützungsniveau. Die relativen Veränderungen zwischen den Szenarien sollten von diesen Effekten nicht systematisch verzerrt werden.

Ein weitere vereinfachende Annahme betrifft den Leerstand im Status Quo. Wir gehen implizit davon aus, dass im Ausgangszustand kein Leerstand besteht. Dies ist eine Vereinfachung, da in realen Märkten immer eine natürliche Leerstandsquote existiert – selbst in angespannten Märkten liegt diese bei circa 2,5% (Deschermeier et al., 2024), die als “Fluktuationsre-

serve” für einen funktionierenden Wohnungsmarkt gilt und eine natürliche Fluktuation ohne übermäßige Suchkosten ermöglicht. Diese Annahme ist jedoch für unsere Analyse vertretbar, da wir uns primär auf die Veränderung des Leerstands als Reaktion auf einen Regulierungsschock konzentrieren. Die absolute Höhe des Leerstands im Gleichgewicht ist somit als relativer Anstieg zum angenommenen Null-Leerstand im Status Quo zu interpretieren. Die qualitativen Aussagen über die Zunahme der Auswahlmöglichkeiten für Wohnungssuchende bleiben davon unberührt.

Die Modellierung der Wohnflächennachfrage basiert auf der Annahme, dass Wohnen ein perfekt teilbares Gut ist und Haushalte ihre präferierte Wohnfläche langfristig ohne Einschränkungen wählen können. Dies impliziert eine hohe Mietermobilität. In der Realität ist die Mietermobilität durch substantielle Such- und Umzugskosten sowie die Verfügbarkeit passender Wohnungen begrenzt. Die beobachtete geringe jährliche Umzugsquote in Deutschland indiziert erhebliche Mobilitätshemmnisse.⁵³ Diese Annahme könnte dazu führen, dass die simulierten Anpassungen der Wohnfläche und die daraus resultierenden Wohlfahrtseffekte die tatsächliche kurzfristige Anpassungsfähigkeit der Haushalte überschätzen. Dennoch ist diese Annahme für die Modellierung eines langfristigen Gleichgewichtsprozesses gerechtfertigt, da sie die theoretisch optimalen Reaktionen der Haushalte abbildet. Die Auslassung expliziter Transaktionskosten von Umzügen folgt dabei der etablierten Praxis hedonischer Wohlfahrtsanalysen (Glaeser und Luttmer, 2003): Bei wiederkehrenden jährlichen Effizienzgewinnen gegen einmalige Umzugskosten verlieren letztere im Zeitverlauf an Gewicht. Die qualitative Richtung der simulierten Anpassungen wird damit korrekt erfasst.⁵⁴

Des Weiteren abstrahiert die Analyse von Interaktionen zwischen dem Miet- und dem Eigentumsmarkt, indem sie ausschließlich Miethaushalte und deren Anpassungen innerhalb des Mietsegments betrachtet. Die „Tenure Choice“-Entscheidung, also der potenzielle Wechsel von Haushalten zwischen Mieten und Kaufen als Reaktion auf relative Preisänderungen, bleibt unberücksichtigt. Die simulierte Angleichung der Bestandsmieten an das Neuvertragsniveau könnte theoretisch die relative Attraktivität von Wohneigentum erhöhen und Substitutionseffekte auslösen: Eine Substitution in den Eigentumsmarkt könnte freiwerdenden Mietwohnraum schaffen und die Neuvertragsmieten im Gleichgewicht dämpfen. Diese Vereinfachung stellt eine Limitation dar, da eine zusätzliche Anpassungsoption für Haushalte ignoriert wird. Allerdings deuten empirische Studien für Deutschland auf Hemmnisse hin, die eine starke Substitution zwischen Mieten und Kaufen begrenzen. Insbesondere hohe Transak-

⁵³Die jährliche Umzugsquote in Deutschland liegt bei etwa 8–10% der Haushalte und erscheint im internationalen Vergleich deutlich niedriger, was auf Mobilitätshemmnisse etwa durch Wohnungsengpässe und hohe explizite wie implizite Umzugskosten hindeutet (Stawarz et al., 2021; Causa und Pichelmann, 2020).

⁵⁴Ein expliziter Diskontfaktor wird nicht ausgewiesen; Mietanpassungen verteilen sich in der Realität über mehrere Jahre, gebunden an Mieterfluktuation und Kündigungsfristen, sodass die berichteten Mieter-Verluste und Vermieter-Gewinne diskontierungsbedingt geringer ausfielen. Die Steady-State-Größen sind daher als Vergleich zweier Regulierungsregime im Gleichgewicht zu lesen, nicht als zeitliche Anpassungstrajektorie.

tionskosten beim Immobilienerwerb wie Grunderwerbsteuer und Notargebühren sowie rigide Kreditvergabestandards und ein vergleichsweise gut funktionierender Mietmarkt dämpfen die Wechselbereitschaft und schränken die kurz- bis mittelfristige Substitutionselastizität ein (Voigtländer, 2009; Kaas et al., 2021). Der Fokus dieser Studie liegt daher bewusst auf den direkten Effekten der Reform innerhalb des Mietmarktes.

Das Modell hält die Haushalte zudem in ihrem Bundesland-Gemeindegrößenklasse-Cluster fixiert; sub-regionale Migrationen in günstigere Nachbarregionen, die durch reformbedingte Mietenanhebungen in Hochpreislagen ausgelöst werden könnten, werden somit nicht modelliert. Diese Restriktion ist datenbedingt: Da die Mietstufen den SUF-Haushalten probabilistisch zugewiesen werden, ließe sich eine endogene Migrationsentscheidung zwischen Mietstufen nicht trennscharf von der Zuweisungsmechanik separieren. Da innerdeutsche Wohnortwechsel als Reaktion auf relative Mietniveau-Verschiebungen empirisch zudem begrenzt sind (Stawarz et al., 2021), dürfte die Verzerrung der aggregierten Wohlfahrtseffekte gering ausfallen. Ein systematisches Risiko der Überschätzung verbleibt jedoch in Hochpreislagen, wo Verdrängungsdruck zu sub-regionalen Ausweichbewegungen führen könnte. Eine feinere räumliche Modellierung erfordert georeferenzierte Mikrodaten und bleibt zukünftiger Forschung vorbehalten.

Weitere Annahmen betreffen die ökonomischen Parameter und Beziehungen im Modell. Die Cobb-Douglas-Nutzenfunktion ist eine gängige und analytisch handhabbare Form, die spezifische Annahmen über die Substituierbarkeit von Wohnungs- und Nicht-Wohnungskonsum trifft – insbesondere impliziert sie eine konstante Substitutionselastizität von Eins zwischen Wohnungs- und Nicht-Wohnungskonsum sowie konstante Budgetanteile, die durch die empirische Stabilität der Wohnausgaben-Anteile (Davis und Ortalo-Magné, 2011) gestützt sind, jedoch nur approximativ gelten. Die Cobb-Douglas-Nutzenfunktion erfüllt im vorliegenden Modell eine spezifische Funktion: Sie dient als parametrisierbare Heuristik für die Wohlfahrtsmessung, nicht als Modell des Nachfrageverhaltens selbst. Die tatsächliche Wohnflächen-Anpassung der Haushalte wird empirisch über einen polynomialen Nachfrageansatz (vgl. Anhang A.2 VI) im hedonischen Querschnittsmodell geschätzt, der haushaltsspezifische Reaktionen ohne enge funktionale Form abbildet. Cobb-Douglas wird ausschließlich zur Aggregation monetärer Effekte in äquivalente Variation eingesetzt und auf jeden einzelnen Haushalt aus dessen empirisch beobachtetem Konsumverhalten kalibriert. Eine flexiblere CES- oder Stone-Geary-Spezifikation könnte heterogenere Substitutionsmuster – insbesondere für einkommensschwache Haushalte mit höheren Wohnkostenanteilen – besser abbilden, würde aber eine deutlich umfangreichere Parameterschätzung erfordern, die mit den verfügbaren Mikrozensus-Querschnittsdaten nicht stabil identifizierbar wäre. Die Vermieter-Elastizitäten wurden auf Basis der Literatur festgelegt und vereinfachen die komplexe Angebotsseite des Marktes. Die Annahme eines einheitlichen effektiven Steuersatzes von 30% auf Vermieterein-

künfte abstrahiert von der progressiven Einkommensteuer und unterschiedlichen Eigentümerstrukturen. Zudem werden die resultierenden Steuermehreinnahmen in der Wohlfahrtsbilanz als unverzerrte fiskalische Größe behandelt. Eine vollständige Bilanz müsste die Effizienzkosten ihrer alternativen Verwendung berücksichtigen, da jeder Rücktransfer mindestens Reibungsverluste der öffentlichen Mittelallokation impliziert. Diese Annahmen sind für die Handhabbarkeit des Modells notwendig und beeinflussen primär die exakte Quantifizierung der Effekte, nicht aber die qualitative Richtung der Ergebnisse.

Zwar könnte unsere polynomiale Spezifikation theoretisch sensibel auf extreme Preisschocks reagieren, die in unserem Modell implizit ermittelte Preiselastizität der Nachfrage liegt jedoch implizit im Mittel bei $-0,6$. Dieser Wert deutet auf eine unelastische, aber langfristig anpassungsfähige Nachfrage hin und fügt sich in die Literatur ein: Während Studien wie Friedman und Weinberg (1981) oder Ermisch et al. (1996) noch inelastischere Preiselastizitäten der Mietnachfrage im Bereich $-0,2$ bis $-0,4$ berichteten, zeigen Analysen langfristiger Gleichgewichte etwas elastischere Werte im Bereich $-0,2$ bis $-0,9$ (Hanushek und Quigley, 1980). Albouy et al. (2016) ermitteln einen Wert von $-0,67$ und Davis und Ortalo-Magné (2011) argumentieren auf Basis konstanter Ausgabenanteile für eine Preiselastizität der Mietwohnnachfrage nahe -1 . Vor diesem Hintergrund erscheint die mittlere Preiselastizität der Nachfrage in diesem Modell, trotz potentiell verzerrender polynomiale Spezifikation, valide.

Eine weitere Limitation betrifft die regionale Konzentration der Verteilungseffekte. Wie Kapitel A.1 dieser Arbeit zeigt, sind die Diskrepanzen zwischen Bestands- und Neuvertragsmieten räumlich heterogen und konzentrieren sich auf wenige Großstädte mit angespannten Wohnungsmärkten. Daraus folgt, dass die aggregiert ausgewiesenen Umverteilungseffekte in der Realität nicht gleichmäßig über das Bundesgebiet anfallen, sondern überproportional in den Top-Großstädten greifen. Die in Abschnitt A.2.3 dargestellte probabilistische Mietstufenzuweisung approximiert diese räumliche Heterogenität, ersetzt aber keine vollständige kleinräumige Analyse.

Schließlich ist zu beachten, dass unsere Analyse auf Querschnittsdaten des Mikrozensus basiert. Obwohl der Mikrozensus eine repräsentative Stichprobe der deutschen Bevölkerung darstellt, können Querschnittsdaten keine kausalen Zusammenhänge im Zeitverlauf identifizieren. Die dynamische Simulation ist daher als kontrafaktisches “Was-wäre-wenn”-Szenario zu verstehen, das die Anpassungsprozesse unter den getroffenen Annahmen abbildet.

Trotz dieser Limitationen liefert unsere Studie robuste Erkenntnisse über die Richtung und relative Größenordnung der Effekte einer Mietregulierungsreform. Die diskutierten Annahmen wurden in ihren Verzerrungspotentialen abgewogen und wirken nicht in eine einheitliche Richtung, sodass eine systematische Verzerrung der qualitativen Schlussfolgerung nicht zu er-

warten ist. Zugleich sind diese Annahmen integraler Bestandteil des methodischen Beitrags, indem sie eine geschlossene Wohlfahrtsanalyse einzig auf Basis des Mikrozensus ermöglichen. Quantitative Verfeinerungen über die hier gesetzten Grenzen hinaus sind Gegenstand weiterführender Studien.

A.2.7 Fazit

Die vorliegende Studie quantifiziert mittels eines dynamischen Gleichgewichtsmodells die Auswirkungen einer hypothetischen Angleichung von Bestands- und Neuvertragsmieten im deutschen Mietwohnungsmarkt. Basierend auf Mikrozensus-Daten von 100.366 gefilterten Miethaushalten simulieren wir die Anpassungsprozesse und Wohlfahrtseffekte dieser Regulierungsreform.

Zentrale Befunde Die Simulation prognostiziert einen positiven Nettowohlfahrtseffekt von 0,38 Mrd.€ jährlich. Dieser setzt sich zusammen aus Wohlfahrtsverlusten der Mieter (-5,39 Mrd.€), Netto-Mehreinnahmen der Vermieter (+4,09 Mrd.€) und fiskalischen Nettogewinnen (+1,68 Mrd.€). Die aggregierte Effizienzsteigerung resultiert primär aus der Nutzenoptimierung durch Wohnflächenanpassung: Haushalte reduzieren ihre Wohnfläche durchschnittlich um 7,4%, wodurch der tatsächliche Wohlfahrtsverlust unter den monetären Mehrausgaben liegt. Der entstehende Leerstand von 7,4% erhöht die Marktliquidität, geht jedoch mit ungenutzten Ressourcen einher.

Die Verteilungsanalyse offenbart substantielle regressive Effekte: Während 73% aller Miethaushalte Wohlfahrtsverluste erleiden, trifft die relative Belastung einkommensschwache Haushalte überproportional. Diese asymmetrische Belastung reflektiert die höhere Wohnkostenquote und geringere Anpassungsflexibilität vulnerabler Gruppen.

Politikimplikationen Gegeben dieser Verteilungswirkungen illustrieren die Ergebnisse die notwendige Abwägung zwischen allokativer Effizienz und distributiver Gerechtigkeit. Eine Angleichung der Mietpreissegmente könnte Marktverzerrungen reduzieren und Investitionsanreize stärken, würde jedoch ohne flankierende Maßnahmen zu sozialen Härten führen. Drei Handlungsoptionen ergeben sich: Erstens könnte eine graduelle Reformimplementierung die Anpassungskosten zeitlich strecken. Zweitens würde eine Erhöhung der Wohngeld-Höchstbeträge und KdU-Angemessenheitsgrenzen die identifizierten Verteilungseffekte abmildern – unsere Simulation zeigt, dass die Transfervolumina ohne Parameteranpassung nur im geringen Umfang steigen. Drittens könnten die fiskalischen Mehreinnahmen (1,68 Mrd.€) zusätzlich zu bestehenden Transfersystemen zur gezielten Kompensation betroffener, bedürftiger Haushalte verwendet werden.

Methodische Einordnung Unsere Analyse basiert auf mehreren vereinfachenden Annahmen: perfekte Mobilität ohne Transaktionskosten, Cobb-Douglas-Präferenzen und vollständige Inanspruchnahme von Transfers. Die polynomiale Modellierung der Preisreaktion ermöglicht flexible Anpassungsmuster, die in der Verwendung von Querschnittsdaten begründet ist und kausale Interpretationen einschränkt. Dennoch liefert die Studie robuste Richtungsaussagen über die zu erwartenden Effekte.

Forschungsperspektiven Zukünftige Arbeiten sollten folgende Erweiterungen priorisieren: Die Integration von Umzugskosten würde realistischere kurzfristige Anpassungen abbilden. Die Modellierung endogener Angebotsreaktionen könnte Effekte auf der Vermieterseite besser quantifizieren. Eine Modellierung von Substitutionseffekten mit dem Eigentümer-Markt erscheint als Erweiterung ebenfalls sinnvoll. Die Verwendung von Paneeldaten oder natürlichen Experimenten würde zudem kausale Identifikationen ermöglichen. Darüber hinaus wäre die Simulation alternativer Reformszenarien im Rahmen dieses oder ähnlicher Modelle erstrebenswert, um ein vollständiges Bild aller möglichen Reformpfade und ihrer Implikationen hinsichtlich Effizienz und Verteilung zu zeichnen.

Insgesamt demonstriert diese Studie, dass Effizienzgewinne am Mietwohnungsmarkt möglich, aber nicht kostenfrei sind. Eine evidenzbasierte Reformdebatte muss beide Dimensionen – Effizienz und Verteilung – explizit abwägen. Unser Modellrahmen bietet hierfür eine quantitative Grundlage, die durch weitere empirische Forschung zu validieren ist.

Teil B

Subtile Markteinflüsse: Politische Unsicherheit

Während die vorangegangenen Analysen die direkten Wirkungszusammenhänge zwischen Marktmechanismen und regulativen Eingriffen auf deutschen Wohnungsmärkten untersuchten, richtet sich der Blick im Folgenden auf eine subtile, jedoch als zunehmend relevant wahrgenommene Einflussgröße: politische Unsicherheit. Diese bezeichnet die durch unklare Zielsetzungen, häufige Reformankündigungen oder instabile institutionelle Rahmenbedingungen hervorgerufene Unsicherheit über künftige politische Entscheidungen. Im Kontext von Wohnungsmärkten betrifft sie vor allem Erwartungen über Regulierungen, steuerliche Rahmenbedingungen oder energetische Auflagen, die Faktoren künftiger Renditen darstellen.

Die ökonomische Literatur zeigt, dass Unsicherheit über politische Maßnahmen bereits vor deren Umsetzung Marktprozesse beeinflussen kann. Aufgrund der Irreversibilität und Kapitalintensität von Wohnungsinvestitionen erhöht politische Unsicherheit den Wert des Abwartens und führt dazu, dass Investoren Entscheidungen aufschieben, bis mehr Klarheit über die künftigen Rahmenbedingungen herrscht (Dixit und Pindyck, 1994; Bulan et al., 2009). Gleichzeitig steigen Risikoaufschläge, da Unsicherheit die erwartete Volatilität zukünftiger Erträge und die Wahrscheinlichkeit regulatorischer Eingriffe erhöht (Pástor und Veronesi, 2013; Ling und Naranjo, 2015). Zudem kann sie die Marktliquidität beeinträchtigen, da Käufer und Verkäufer eine abwartende Haltung einnehmen (Clayton et al., 2008).

In einem Umfeld kontinuierlicher wohnungspolitischer Diskussionen und Reformvorhaben bildet die Unsicherheit über deren Ausgestaltung einen eigenständigen Bestimmungsfaktor der Marktentwicklung. Dieses Umfeld ist zugleich geprägt von externer Unsicherheit und globalen Krisen – etwa geopolitischen Spannungen, Migration oder energiepolitischen Umbrüchen –, die auf die politische Stabilität und die Erwartungsbildung im wohnungspolitischen Bereich ausstrahlen. Politische Unsicherheit wirkt dabei nicht erst über realisierte Maßnahmen, sondern bereits über Erwartungen an künftige Politikentscheidungen, die sich in Investitionsentscheidungen und Preisbildung niederschlagen (Luo et al., 2021; Hilber und Vermeulen, 2016). Die nachfolgende Analyse untersucht diesen Mechanismus und knüpft damit an die übergeordnete Fragestellung dieser Arbeit an, wie politische Steuerung – in diesem Fall über Erwartungen und Unsicherheit – die Dynamik regionaler Wohnungsmärkte prägt.

B.1 The Price of Politics: A County-Level Analysis of Political Uncertainty and German House Prices*

Authors: Julius Range and Lars Jagemann

Abstract: This study examines the linkage between political uncertainty and residential real estate market behavior in Germany. We measure politically related uncertainty using the media-based Uncertainty Perception Index, which captures domestic political uncertainty more comprehensively than conventional policy-focused measures and examine its effects on residential real estate markets using transaction data covering all 400 counties in Germany. Applying spatial regression techniques to address neighborhood spillover effects, we identify county-level residential real estate house and apartment prices to be negatively associated with increased political uncertainty. The negative effect is further increased in counties with higher unemployment rates with house prices showing greater sensitivity than apartment prices. Our results suggest that political uncertainty has a significant impact on real estate investment behavior, with implications for housing supply development in Germany.

B.1.1 Introduction

„When policies and rules are subject to repeated changes at the hands of politicians largely eyeing short-term political gains, it becomes increasingly difficult to make economic decisions and plan for the future.“ (Luo et al., 2021)

Frequent policy changes, shifts of political power, or unclear political intentions result in uncertainty over political outcomes. Over the last decade, Germany and many other countries experienced higher than usual uncertainty over political outcomes, largely driven by exogenous shocks such as migration, the COVID pandemic, and the war in Ukraine.¹ Market participants take these uncertainties into account when making decisions that affect their economic outcomes. These reactions differ individually, but also among sectors.

The housing sector serves as a prime case in point; its investments are long-lived and partially irreversible, making it particularly sensitive to uncertainty. Few other sectors are as heavily regulated as housing in Germany: while housing can be viewed as a private good

*This version is currently under review in the Journal of Housing Research. The version under review does not contain an extensive appendix; an appendix is included only in this dissertation version.

¹The German Economic Policy Uncertainty (EPU) Index (Baker et al., 2016) rose sharply during major geopolitical and social shocks over the past decade. The index reached unprecedented peaks during the European migration crisis (2015–2016), the COVID-19 pandemic (2020), and following the Russian invasion of Ukraine (2022), reflecting heightened uncertainty over fiscal, energy, and housing policy. These spikes illustrate how exogenous shocks have translated into persistently elevated political and economic uncertainty in Germany.

with significant externalities (e.g., urban planning and social stability; see Glaeser and Gyourko (2008)), it is often treated as a social good in policy contexts. Additionally, energy-efficiency requirements have been expanded in recent years while energy-efficient housing is still subject to political discourse. These features distinguish the German market from more market-oriented systems like the US or UK, where regulations are less pervasive and tenant protections weaker (e.g., no nationwide rent caps), making Germany an ideal context to examine how political uncertainty amplifies regulatory risks and affects investment decisions across diverse regional markets. Because housing is a long-lived and illiquid asset, expectations about the regulatory environment are capitalized into current prices. Political uncertainty therefore affects housing not only through realized policy changes but also through anticipatory adjustments in expected returns and risk premia. These features make Germany a compelling case to study how political uncertainty shapes housing investment and pricing behavior.

In general, real estate market outcomes depend on overall economic conditions such as household income, economic growth, interest rates and demographics as well as regulatory settings. While variation in real estate returns and investment activity can be largely explained by sensitivity to these fundamentals and market cycles (Knoll et al., 2017; Zhang and Wan, 2024), a significant share of unexplained variation persists. This remaining variation can be attributed, at least in part, to shifts in political or regulatory uncertainty, as shown by prior works linking political uncertainty to real estate activity (Luo et al., 2021) and by studies demonstrating that regulatory constraints such as planning restrictions or building codes increase the sensitivity of house prices to shocks in constrained markets (Hilber and Vermeulen, 2016; Gyourko and Molloy, 2015).

The existing literature on political uncertainty and real estate investment performance mainly focuses on Anglo-Saxon countries. Recent studies identified negative effects of election uncertainty on construction activity in the US (Luo et al., 2021; Canes-Wrone and Park, 2014). According to Antonakakis et al. (2015) and André et al. (2017), political uncertainty exerts negative effects on house prices. Choudhry (2020) found similar results for the UK. Similarly, Demiralay and Kilincarslan (2022) and Lang et al. (2022) analyze the effect of different uncertainty types including political nature on commercial real estate returns and REIT performance. Most of these studies rely on the Economic Policy Uncertainty (EPU) Index by Baker et al. (2016), which captures policy-related uncertainty once political developments have produced measurable economic repercussions. However, the EPU primarily reflects realized policy-related uncertainty, and may miss earlier, perception-driven stages of political instability. The Uncertainty Perception Index (UPI) developed by Rieger et al. (2023) captures broader perceived political uncertainty—including ambiguity about future government actions and institutional reliability—before these perceptions translate into eco-

nomic consequences. Using the UPI therefore allows us to test whether housing markets respond to the anticipation of political instability itself rather than to its realized macroeconomic effects. This distinction is particularly relevant for the housing sector, where long investment horizons make perception-based uncertainty especially influential.

To our knowledge, this is the first study to investigate how broad, perception-based political uncertainty influences residential housing investment in Germany. This gap arises from both the scarcity of granular data and the dominant focus on Anglo-Saxon markets. Our analysis leverages newly available county-level transaction data and spatial econometric techniques to examine how political uncertainty, measured through the Uncertainty Perception Index (UPI), shapes regional housing prices and investment dynamics.

This study contributes to the literature in three ways. First, we extend existing findings on policy-related uncertainty by showing that perceived political uncertainty (UPI) affects housing prices even before it manifests in economic policy uncertainty (EPU). This highlights an anticipatory channel whereby expectations about political instability are priced into housing markets. Second, we identify important market heterogeneity: uncertainty effects vary by local economic conditions and property types, with houses in high-unemployment regions showing the strongest sensitivity. Third, we apply spatial econometric techniques to all 400 German counties using novel transaction-level data, explicitly accounting for spatial dependencies inherent in real estate markets.

The remainder of the paper is organized as follows: Section 2 reviews the related literature and provides the theoretical background on uncertainty in the real estate sphere. In Section 3, we present the methodology, namely our data and empirical design. Section 4 reviews the results of our spatial regressions and Section 5 concludes.

B.1.2 Uncertainty in Real Estate

The relationship between uncertainty and economic outcomes has been extensively documented. Uncertainty surrounding economic, fiscal, monetary, or regulatory policies exerts broad adverse effects on the real economy. Studies show that heightened uncertainty can depress economic growth (Bloom et al., 2018), have adverse impacts on the labor market (Ferrara and Guérin, 2018) and reduce production levels as well as output (Basu and Bundick, 2017). Just like uncertainty in general, the reason for adverse effects of political uncertainty is among others: delaying investments, causing volatility and corresponding risk premiums² and transaction costs that ultimately distort the allocation of productive resources.

²Note that uncertainty is not comparable to risk: unlike risk, uncertainty implies unknown outcomes, so assigning probabilities to future states is not feasible.

Theoretical Framework of Uncertainty in Real Estate

Real estate investments possess three critical features that make them particularly sensitive to uncertainty: irreversibility, timing flexibility, and high capital intensity (Dixit and Pindyck, 1994). These characteristics create a framework where uncertainty significantly alters optimal investment behavior through several key economic mechanisms.

Real options concepts, early applied to real estate by Titman (1985) in his work on urban land prices and later formalized into a comprehensive theoretical framework by Dixit and Pindyck (1994), provide the primary theoretical foundation for understanding investment under uncertainty. When investments are irreversible – as is typically the case with real estate development – uncertainty increases the option value of waiting. The investor holds a “call option” on the investment opportunity, and exercising this option eliminates the possibility of waiting for new information. Political uncertainty increases this waiting option’s value by expanding the potential range of future outcomes. Mathematically, the option value of waiting increases with the variance of expected returns, which political uncertainty directly amplifies (Bulan et al., 2009). This creates a zone of inaction where even projects with positive net present values remain unexecuted as investors rationally wait for uncertainty resolution (Geltner et al., 2007).

Political uncertainty affects real estate investment through financial channels. The risk premium component increases as uncertainty raises both the discount rate applied to future cash flows and the perceived volatility of rental income and property values (Pástor and Veronesi, 2013; Baker et al., 2016). Simultaneously, credit markets tighten—lenders reduce loan-to-value ratios and increase spreads, while existing leveraged owners face refinancing risks that can trigger distressed sales (Gissler et al., 2016; Brunnermeier and Sannikov, 2014). These financing constraints particularly impact real estate due to high leverage ratios and external financing dependence (Ling and Naranjo, 2015).

Certain real estate markets are heavily regulated, making them particularly sensitive to political uncertainty through the regulatory channel. Uncertainty about future regulations regarding zoning, rent controls, property taxation, or environmental requirements directly affects expected returns (Nguyen and Vergara-Alert, 2023). Anticipated changes in regulatory frameworks create uncertainty about future compliance costs, which are often substantial in real estate development (Gyourko and Molloy, 2015). This regulatory channel is especially pronounced in housing markets due to their social importance and consequent political salience (Hilber and Vermeulen, 2016).

Review of Empirical Literature

The empirical literature on political uncertainty can be categorized into three distinct strands: studies examining political uncertainty's impact on general investment activity, research specifically addressing real estate investment, and analyses of political uncertainty's effects on asset prices including housing.

Several studies examining general investment activity found that political uncertainty hinders investment and financial activities at the firm level. Using primarily US data and election-based uncertainty measures, Azzimonti (2018) shows that political uncertainty negatively affects corporate investment while Çolak et al. (2017) associate political uncertainty with dampened IPO activity. Similarly, Julio and Yook (2012) found that during election years, firms reduce investment expenditures by an average of 4.8% compared to non-election years, suggesting firms hold cash until election uncertainty resolves. Contrary to these findings, when examining uncertainty in financial markets more broadly, Shleifer and Vishny (2011) argue that uncertainty can lead to fire sales, as market participants facing economic downturns liquidate assets to raise cash, potentially increasing certain types of investment activity. However, the evidence of Shleifer and Vishny (2011) bases on asymmetric information of market participants, whereas political uncertainty generally does not give any market participant an information advantage. Therefore, political uncertainty can manifest itself in a variety of ways and is not, or not fully, reflected in premiums or discounts for market uncertainty (Lei and Luo, 2023).

The effects of uncertainty in real estate are amplified by the sector's illiquid nature. Buildings are durable, site-specific, and expensive to modify or repurpose. Once construction begins, sunk costs cannot be fully recovered if future conditions worsen (Dixit and Pindyck, 1994). Most empirical studies confirm a negative impact of uncertainty on housing investment activity. Using election-based uncertainty measures, Canes-Wrone and Park (2014) found that political uncertainty during elections leads to delayed real estate investments, with this effect more pronounced in competitive electoral races with significant policy differences between candidates. Similarly, Luo et al. (2021), using the EPU as well as partisan conflict indices, establish that political uncertainty negatively impacts residential construction activities, leading to a decline in building permits.

Political uncertainty exerts downward pressure on housing prices through several channels. Christou et al. (2020) found that heightened uncertainty reduces household willingness to make major purchases, particularly for owner-occupied housing. This demand reduction is amplified by housing purchases' substantial leverage, making households more sensitive to uncertainty about future income (Ngai and Sheedy, 2020). Real estate investors incorporate

higher risk premiums during periods of political uncertainty, directly reducing prices they are willing to pay (Ling et al., 2018). Political uncertainty also reduces market liquidity as both buyers and sellers adopt a wait-and-see approach, increasing the liquidity premium in transaction prices (Clayton et al., 2008).

The impact on housing supply operates primarily through investment decisions. Developers delay or cancel projects during heightened political uncertainty, reducing new housing supply (Luo et al., 2021). This effect is particularly strong because real estate development involves substantial sunk costs and long time horizons (Bulan et al., 2009). Existing homeowners and investors may delay listing properties during uncertain periods (Ngai and Tenreyro, 2014), while institutional investors may reallocate capital away from real estate development toward more liquid assets (Demiralay and Kilincarslan, 2022).

These supply-side effects have significant implications for housing affordability. As Luo et al. (2021) demonstrate, political uncertainty leads to reduced construction activity, exacerbating housing shortages in supply-constrained markets. The combination of price and supply effects creates a feedback loop: reduced development activity constrains housing supply, putting upward pressure on prices once uncertainty resolves, potentially triggering further political interventions (Hilber and Vermeulen, 2016).

Regarding specific effects on housing prices, Choudhry (2020) obtains long and short-term negative effects of economic policy uncertainty on housing prices in England and Wales using the EPU index. El-Montasser et al. (2016) suggest a bi-directional causality between policy uncertainty and housing prices, indicating that uncertainty regarding future economic fundamentals can lead to increased housing price volatility, amplifying financial cycles. André et al. (2017) uncovers a causal relationship between EPU and real housing returns in the US, demonstrating that high EPU may lead to lower housing prices especially during downturns. Similarly, Antonakakis et al. (2015) found that economic policy uncertainty has a significant negative impact on housing market returns in the US from 1984 to 2012.

B.1.3 Data

Measuring Political Uncertainty

Researchers have conceptualized political uncertainty in different ways, each approach capturing distinct aspects of this multifaceted phenomenon. Baker et al. (2016) developed the EPU index, which requires articles to simultaneously contain terms from three categories: economy (e.g., “economic”, “economy”), policy (e.g., “regulation”, “deficit”), and uncertainty (e.g., “uncertain”, “uncertainty”). This narrow intersection captures uncertainty only after

it manifests in economic policy discourse. Election-based measures (Julio and Yook, 2012; Canes-Wrone and Park, 2014) use electoral cycles and competitiveness as proxies for political uncertainty, focusing on uncertainty about future policy directions.

For our analysis, we utilize the German Politics category of the Uncertainty Perception Index (UPI) developed by Rieger et al. (2023). Unlike EPU’s restrictive three-category requirement, the UPI measures generic political uncertainty by identifying any political content in articles containing uncertainty terms, making it particularly suitable for analyzing real estate markets where political decisions impact investment conditions through multiple channels beyond economic policy.

The UPI employs a Rolling-LDA (Rolling Latent Dirichlet Allocation), a dynamic topic modeling approach that maintains temporal consistency while allowing topics to evolve. This contrasts with EPU’s static keyword counting. Using a corpus of three leading German newspapers – “Süddeutsche Zeitung” (center-left), “Die Welt” (center-right), and “Handelsblatt” (business-focused) – the system processes articles containing uncertainty-related terms and identifies political content through unsupervised clustering rather than predetermined categories.³


Crucially, the topic-specific words update quarterly through machine learning, ensuring the index captures contemporary political concerns. While EPU misses uncertainty that has not yet entered economic policy vocabulary, UPI detects emerging political uncertainties before they crystallize into policy debates. The German Politics UPI encompasses uncertainty surrounding structural reforms, legislative processes, and electoral outcomes – a broader scope than EPU’s economic policy focus. Applying the UPI to the German real estate market thus allows us to examine the effects of political uncertainty that are not necessarily economic in nature. National political uncertainty encompasses not only economic uncertainty but also social policy uncertainty in the context of tenant protection or social welfare, as well as domestic political uncertainty with regard to public safety or social order. The various aspects of politics and the associated uncertainty covered by the UPI enable insights that go beyond economic policy contexts.

Figure B.1 illustrates the index development over time, showing clear spikes during major political events. Notably, the UPI – unlike the widely used EPU – does not show high peaks during federal elections. The only moderate correlation between the two measures, reported in Table B.2, underscores the difference in the type of political uncertainty that the two

³The index does not show separately which underlying medium accounts for what share of the total number of media analyzed. It cannot therefore be ruled out that individual media contribute disproportionately to the overall score.

indices reflect.⁴ The monthly UPI data is aggregated into quarterly means to align with our market data frequency. Table B.1 provides summary statistics, while Appendix B.1 I presents an example of the dynamically selected words for the first quarter of 2021.

Figure B.1: Development of UPI German Politics Index 2013-2022



Own calculations and illustration. *Note:* This chart illustrates the UPI index developed by Rieger et al. (2023) over time in level values.

Housing Investment Activity and Prices


Housing investment activity can be measured through several indicators, e.g. building permits, construction activity, transactions or offer activity. As building permits or constructions do not adequately represent real estate investment decision as they come with inconsistent delays to the investment decision of e.g. applying for a permit, transaction or offer data better represents investment decisions. Even though transactions might not cover the whole scope as new constructions are only captured after construction, transactions offer the most accurate representation of investment sentiment (Fisher et al., 2007).

As mentioned earlier, since local German real estate markets are heterogeneous and might exhibit varying market features, we allow for regional differences and control for spatial dependencies by gathering panel data for all 400 German counties. County-specific transac-

⁴The conceptual lead-lag relationship, that is the UPI capturing political uncertainty before it crystallises into the EPU's economic-policy vocabulary, is theoretically motivated by the broader semantic scope and the dynamic Rolling-LDA construction. A formal empirical test of the temporal precedence (e.g. via Granger causality between the two indices) is beyond the scope of this analysis and is left for future research. The complementary orthogonalised residual UPI_EPU_RES (Section B.1.4) addresses the overlap concern by isolating UPI variation that is uncorrelated with EPU.

tion data is provided by Verband Deutscher Pfandbriefbanken (2023). About 590 regional and national member banks report accompanied transactions making it the biggest German transaction database. Our obtained data include quarterly transaction numbers of condominium and detached houses as well as median per square meter prices for each county and quarter from 2013-Q2 to 2022-Q2. The sample consists of observations for each of the 400 counties in Germany over a period of 36 quarters, totaling 14,400 data points. We construct two different segments, namely transactions of detached houses as well as transactions of apartments. Transactions prices normalized by the floor space for each county and quarter represent the housing prices in our panel. Figures B.2 and B.3 illustrate sample averages as well as data availability for German counties.

Figure B.2: Average House Prices 2013-2022 (in €)




Own calculations and illustration. *Note:* This figure illustrates sample-averages of transaction house prices in Germany in € per m². Darker color denotes higher prices while brighter color denotes lower prices.

Analyzing the transaction numbers provided by Verband Deutscher Pfandbriefbanken (2023), it became clear that the reporting institutions increased over time, rendering this data not suitable in representing changes in investment activity over time. Thus, the panel dataset is expanded by offer data derived from RWI and ImmobilienScout24 (2023). This dataset includes the quarterly total number of all property listings on Germany's largest online real

estate platform “Immobilienscout24”. Analogously, we distinguish between of apartments and detached houses. While this approach is suboptimal as it captures mostly private selling intentions rather than actual transactions, it allows to accurately represent the supply side of the private housing investment market. Together with transaction prices it allows for a holistic approach to isolate the effects of political uncertainty on housing markets.

Figure B.3: Average Apartment Prices 2013-2022 (in €)



Own calculations and illustration. *Note:* This figure illustrates sample-average apartment transaction prices in € per m². Darker color denotes higher prices while brighter color denotes lower prices. Uncolored parts of the map symbolize missing data not included in the data set subsample for apartment prices.

Control Variables

Our analysis bases on a comprehensive dataset of quarterly data for all 400 German counties between April 1, 2013 and June 30, 2022. Broader macroeconomic conditions are controlled for by including regional determinants of housing supply and demand such as interest rates, unemployment and land prices. The interest rate variable denotes real interest rates for security backed mortgages, which are most common for residential property financing, and are derived from Deutsche Bundesbank (2024). The unemployment rate serves as economic

indicator and is derived from Bundesagentur für Arbeit (2024). Land prices are normalized per square meter and serve as real estate market indicator. We collect land price data from Statistisches Bundesamt (2024b).

In addition, demographic variables like age-coefficients, population density and migration⁵ are included. All demographic variables serve as housing demand indicators and are derived from Statistisches Bundesamt (2024c). Table B.1 reports descriptive statistics for our data set. If feasible, control variables are at quarterly frequency and county level. If county-level data is not available, the next best is chosen, i.e. federal state level or national level. Table B.2 reports pairwise correlations. Notably, political uncertainty is negatively correlated with house and apartment prices.

Table B.1: Descriptive Statistics

	Obs.	Mean	Std. Dev.	25%	50%	75%
House Prices	14,400	1,733.02	820.93	1,181.60	1,552.66	2,083.34
Apartment Prices	8,892	1,918.00	931.75	1,257.40	1,707.70	2,361.20
House Listings	14,400	409.00	364.65	163.00	307.00	544.00
Apartment Listings	8,892	361.99	1,120.26	87.75	167.00	339.00
Political Uncertainty	14,400	3,303.00	947.23	2,544.00	3,469.00	3,886.00
Unemployment Rate	14,400	5.46	2.53	3.50	5.00	6.83
Population Density	14,400	532.60	700.92	115.70	199.80	674.60
Population Age	14,400	44.97	1.95	43.70	44.70	46.10
Interest Rate	14,400	1.74	0.47	1.30	1.75	1.90
Land Prices	14,400	159.56	231.10	48.89	91.08	180.72
Migration per 10,000 inhabitants	14,400	66.06	61.39	28.70	57.10	93.33
EPU index	14,400	229.90	116.72	147.70	191.50	256.40
Political Uncertainty_EPU_RES	14,400	56.56	837.35	-627.46	42.62	556.60

Note: This table presents summary statistics for the house prices and apartment prices data set. Variables are reported in levels and before transformations to provide an overview of the applied data sets.

⁵The migration variable is normalized by 10,000 inhabitants.

Table B.2: Pairwise Correlations

	House Prices	Apartment Prices	House Listings	Apartment Listings	Political Uncertainty	Unemployment Rate	Population Density	Population Age	Interest Rate	Land Prices	Migration per 10,000 inhabitants	EPU index	Political Uncertainty_ EPU_RES
House Prices	1												
Apartment Prices	0.763***	1											
House Listings	-0.213***	-0.303***	1										
Apartment Listings	-0.274***	-0.298***	0.616	1									
Political Uncertainty	-0.026***	-0.035***	-0.099***	-0.086***	1								
Unemployment Rate	-0.297***	-0.304***	0.036***	0.076***	-0.005*	1							
Population Density	0.405***	0.182***	-0.013**	-0.001***	0.000	0.401***	1						
Population Age	-0.547***	-0.246***	-0.033***	-0.084***	-0.004	0.257***	-0.446***	1					
Interest Rate	0.110***	0.129***	-0.179***	-0.207***	-0.071***	-0.029***	0.002	0.019**	1				
Land Prices	0.799***	0.620***	-0.090***	-0.100***	-0.007	-0.178***	0.593***	-0.665***	0.046***	1			
Migration per 10,000 inhabitants	0.103***	-0.037***	0.068***	0.139***	0.022***	-0.080***	0.022***	-0.183***	0.082***	0.138***	1		
EPU index	0.121***	0.147***	-0.118***	-0.127***	0.470***	-0.070***	0.002	0.024***	0.087***	0.045***	0.092***	1	
Political Uncertainty_EPU_RES	-0.063***	-0.080***	-0.075***	-0.059***	0.969***	0.014***	0.000	-0.011	-0.102***	-0.020**	-0.002	0.236***	1

Note: This table presents the correlation matrix of the applied data set. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

B.1.4 Empirical Analysis

This section presents the empirical findings on the relationship between political uncertainty and real estate market behavior in Germany. We first conduct preliminary tests, then present our main regression results, followed by an analysis of regional heterogeneity in the effects of political uncertainty on real estate markets. Finally, we conduct several robustness checks.

Political Uncertainty and Economic Fundamentals

The preliminary analysis of our data reveals non-stationarity in political uncertainty measures and interest rates applying a panel unit root test. Non-stationarity of economic fundamentals and interest rates is a common issue in economic research, as this data underlies trends or shocks (Rapach and Weber, 2004; Kim, 2018). However it comes not as a surprise to observe a similar behavior for political uncertainty measures. The UPI and other uncertainty measures amplify whenever uncertainty arises or decreases. As illustrated in B.1.3, the perception of uncertainty rises sometimes suddenly and sometimes shows trending behavior. Observing both variables, interest rates and uncertainty perception measures, at the same time, reveals a causal relationship. Interest rates are driven by monetary policy and market expectations. Whenever political uncertainty arises influencing market expectations, interest rates show a time-delayed reaction. Additionally, both variables respond to common economic fundamentals that affect monetary conditions and political stability. This observation is in line with the evidence of Hartzmark and Solomon (2016) proving a robust relation between real interest rates and market uncertainty. The studies of Amisano and Tristani (2019) on uncertainty shocks and long-term interest rates and Wang and Boatwright (2019) on financial markets reaction on political uncertainty further prove the fundamental relation between interest rates and political uncertainty measures.


Given this theoretical relationship and the non-stationarity of both variables, we test for cointegration. We employ the Johansen test on cointegration developed by Johansen (1991) to isolate a potential long-term relationship between these measures. The test results indicate a highly significant cointegration relationship between both variables allowing us to isolate an error correction term.⁶ This error correction term is included in all regression specifications to obtain unbiased short-term effects. Further, we use first differences of the UPI as well as of the interest rate variable to prevent biases because of identified non-stationarity in levels.

⁶The cointegration finding confirms that German mortgage rates and political uncertainty move together in the long run, consistent with the risk premium channel where sustained political uncertainty becomes priced into credit markets.

Spatial Regression Methodology

While working with a georeferenced price data set it becomes evident, that emerging price dynamics overcome geographical borders of analyzed German counties. The visual presentation of sample-average values in Figures B.2 and B.3 indicates spatial clustering of converging prices printed in darker color. An examination of the illustrative map excerpts for sample-average house prices in the federal state of Bavaria (Figure B.4) and sample-average apartment prices in the federal state of Baden-Wurttemberg (Figure B.5) strengthens this impression. Spatial clustering of higher and lower prices, expressed through darker and lighter color, respectively, across several districts, becomes apparent. The analytical assessment of this observation based on Morans' I test on spatial autocorrelation, first developed by Moran (1950), further strengthens the graphical perception. The test statistics appear highly significant for every time-wave of the sample (see Appendix B.1 II). This spatial dependence (spatial autocorrelation) is particularly pronounced in metropolitan areas and their surrounding counties, highlighting the importance of accounting for spatial effects in our analysis.

Figure B.4: Average House Prices in the State of Bavaria 2013-2022 (in €)




Own calculations and illustration. *Note:* This figure illustrates sample-average house transaction prices in in € per m² in the federal state of Bavaria. Darker color denotes higher prices while brighter color denotes lower prices.

The evidence of previous studies analyzing residential real estate prices further supports our spatial approach. Kajuth et al. (2016) and Otto and Schmid (2018) document pronounced spatial autocorrelation and clustering in German house prices, while Ehlert et al. (2024) show that regional price dynamics are shaped by socio-economic fundamentals and partly

transmitted across neighbouring regions. International evidence points in the same direction: Helbich et al. (2014) and Conway et al. (2010) find that ignoring spatial dependence leads to misspecified hedonic models in Austrian and US housing markets. For rental markets, Fuess and Koller (2016) and Deppner and Cajias (2022) demonstrate that explicitly modelling spatial structure improves model fit and predictive performance.

Figure B.5: Average Apartment Prices in the State of Baden-Wuerttemberg 2013-2022 (in €)



Own calculations and illustration. *Note:* This figure illustrates sample-average apartment transaction prices in in € per m² in the federal state of Baden-Wuerttemberg. Darker color denotes higher prices while brighter color denotes lower prices.

To address the identified spatial autocorrelation, we set up a neighborhood matrix based on decreasing influences with increasing geographical distance. We employ a maximum impact distance of 300 kilometers.⁷ This allows us to capture influences that can be observed across several district boundaries. Aiming to isolate the effect political uncertainty has on housing investment activity and prices in German counties, a panel regression analysis is conducted. To address general spatial autocorrelation as well as spillover effects from transaction prices of counties into neighboring counties, we apply spatial regression techniques. Thereby, the properties of neighboring counties are included in the regression equation. The weight with which neighboring counties influence each other is based on the distance-based weight matrix. In contrast to common queen neighborhood matrices, counties do not necessarily have

⁷Kajuth et al. (2016) document significant spatial spillovers in German house prices using a distance-based weighting matrix in a spatial panel model. Their findings indicate that these dependencies are primarily local and diminish substantially beyond regional scales (typically 200–300 km), justifying our gradual capture of spatial effects up to 300 km.

to share a common border to express spatial dependency in terms of real estate prices.

We use a spatial auto-regressive model (SAR) to investigate the effect of political uncertainty on residential real estate transaction prices. Developed by Elhorst (2010) and LeSage (2014) among others, this regression model allows us to compute global spillover effects of spatial neighbors depicted in a neighborhood matrix. The equally well-known spatial error model (SEM) would have been appropriate to include local spillover effects. However, as shown in Figures B.2 and B.3, the identified spatial dependencies appear across several county borders and are therefore classified rather global than local. We employ the following baseline regression equation:

$$\log(\text{Price}_{i,t}) = \rho \sum_{j=1}^N W_{i,j} \log(\text{Price}_{j,t}) + \beta UPI_{t-1} + \gamma C_{i,t-1} + ECTerm_{t-1} + \mu_i + \delta_y + \varepsilon_{i,t}$$

with $i, j = 1, \dots, N$

(B.1)

where the indices i or j and t refer to counties and quarter within our panel, respectively. $\log(\text{Price}_{i,t})$ denotes the logarithmized transaction price per square-meter of residential dwellings or houses within a county and quarter.⁸ Standard errors are computed using the Newey–West approach to ensure robustness to heteroskedasticity and within-county auto-correlation. The sum of $W_{i,j} \log(\text{Price}_{j,t})$ refers to the spatial spillover effects of neighboring counties. W is a spatial weights matrix inversely based on distances between two respective counties, where $W_{i,j}$ is the i, j -th weight for counties i and j . ρ measures the spatial response factor with neighboring counties. UPI_{t-1} denotes our proxy for political uncertainty lagged by one quarter, whereas β refers to the estimated coefficient.⁹ $C_{i,t-1}$ is a $1 \times K$ vector of one quarter lagged control variables with γ denoting the estimated parameter. The control variables include real residential mortgage interest rate, unemployment rate, population density, mean age of a counties population, building land prices per square meter, migration per 10,000 inhabitants as well as the number of house listings and apartment listings, respectively.¹⁰ Descriptive statistics are reported in Table B.1. $ECTerm_{t-1}$ refers to the one quarter lagged error correction term¹¹ controlling for the identified long-term relation between interest rate and political uncertainty measure. We lag all independent variables

⁸We apply natural logarithms of transaction prices per square meter to ensure linearity.

⁹We mean-scaled the UPI variable for ease of interpretation.

¹⁰We mean scaled the house and apartment listings for ease of interpretation and logarithmized building land prices to ensure linearity.

¹¹The error correction term represents residuals from the cointegrating regression between interest rates and political uncertainty, capturing deviations from their long-run equilibrium. Including this term ensures that our political uncertainty coefficients reflect direct effects on housing prices rather than indirect effects through disequilibrium in credit markets.

by one quarter to allow for market adjustment. μ_i and δ_y denote the county and year fixed effects included to control for unobserved heterogeneity in all model specifications. Lastly, $\varepsilon_{i,t}$ refers to the identically and independently normally distributed error term.

Main Regression Results

We apply the regression model on our two panel data sets for house prices and apartment prices, respectively. The applied sample consists of 14,400 observations for house prices and 8,892 observations for apartment prices within a time span from 2013Q2 to 2022Q1. The estimated regression results are presented in Table B.3. In columns (1) and (3) we report the results for regressions without control variables whereas in columns (2) and (4) all mentioned control variables are applied. Our results reveal a consistent and statistically significant negative relationship between our political uncertainty proxy and residential real estate transaction prices. For all model specifications. Further, the coefficient ρ for the spatial response factor is highly significant and positive in all model specifications indicating strong spatial spillover effects for transaction prices. Other variables behave as expected throughout all regression models. For example, transaction prices appear higher in denser populated counties and prices decline in counties where listings increase. However, the estimated coefficients of spatial autoregressive models (SAR) cannot be interpreted as marginal effects without considering spatial impact analysis. Therefore, we report the spatial impact analysis for the regression estimates of Table B.3 in Table B.4. Direct impacts refer to the effect of a covariate on the dependent variable within a county. Indirect impacts present the spillover effects of all neighboring counties' properties on the dependent variable in a specific county. The sum of direct and indirect impacts equals the reported total impact, which can again be interpreted as marginal effects. Our analysis suggests that approximately 40 to 50 % of the total effect of political uncertainty on real estate markets comes from spatial spillovers, highlighting the importance of considering spatial dependencies when analyzing real estate markets. The significant influence of spatial spillover effects also shows that the interconnection of habitats extends beyond county boundaries. This interdependence proves that both positive and negative externalities do not affect real estate markets in isolation, but rather across regions. Shared infrastructure, commuting behavior, and geographical proximity render subordinate regions interdependent, like pieces of a puzzle. Whenever one piece of the puzzle is affected by external factors, such as increased political uncertainty, all other pieces are also affected by spatial transmission effects. This also demonstrates that diversification can be crucial in minimizing asset risk from a geographic perspective. It furthermore appears plausible that national political uncertainty has a transregional impact on real estate markets and does not merely result in local price reductions. However, these may be tempered by local circumstances.

In economic terms, our regression results indicate that a one standard deviation increase in

Table B.3: Political Uncertainty and Transaction Prices

	House Prices (log)		Apartment Prices (log)	
	(1)	(2)	(3)	(4)
Political Uncertainty	-0.0085*** (0.0027)	-0.0133*** (0.0030)	-0.0092** (0.0041)	-0.0138*** (0.0042)
Interest Rate	-0.0007 (0.0198)	0.0232 (0.0215)	-0.0276 (0.0280)	-0.0191 (0.0290)
Error Correction Term	-0.0050 (0.0036)	-0.0124*** (0.0038)	-0.0003 (0.0055)	-0.0084 (0.0060)
Unemployment Rate		0.0046 (0.0034)		0.0186*** (0.0055)
Population Density		0.0011*** (0.0002)		0.0008*** (0.0002)
Population Mean Age		-0.0341*** (0.0108)		0.0470*** (0.0170)
Land Prices (log)		0.0397*** (0.0066)		0.0354*** (0.0087)
Migration		-0.0003*** (0.0001)		-0.0001 (0.0001)
House Offerings		-0.0026 (0.0020)		
Apartment Offerings				-0.0006 (0.0037)
Spatial Parameter (ρ)	0.4016*** (0.0276)	0.4016*** (0.0276)	0.4836*** (0.0266)	0.4436*** (0.0276)
Year Fixed Effects	Yes	Yes	Yes	Yes
County Fixed Effects	Yes	Yes	Yes	Yes
Observations	14,400	14,400	8,892	8,892
Counties	400	400	247	247
Sigma	0.1773	0.1747	0.2109	0.2091
AIC	-35,652	-36,015	-19,062	-19,116
BIC	-35,554	-35,871	-18,970	-18,982

Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI Index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. Independent variables are lagged by one quarter. The sample period is 2013Q2 to 2022Q2. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

the political uncertainty proxy results in a decrease of house prices of approximately 2.19% on average and a decrease of apartment prices of approximately 2.42% on average, respectively, *ceteris paribus*. To contextualize these values, we employ a numerical example for a political uncertainty shock, comparable to the COVID-19 pandemic, where the uncertainty measure increases by approximately 2.8 standard deviation units within one quarter. Applying our estimated values, this political uncertainty shock would result in a drop in house prices by on average 6.13% and a drop in apartment prices by on average 6.78%, respectively, *ceteris paribus*. To summarize, our spatial regression approach results provide empirical evidence for the significant negative effect of political uncertainty proxied by the UPI developed by Rieger et al. (2023) on residential real estate prices in German counties. While apartment prices appear to react slightly stronger on increases of political uncertainty, the overall negative relationship indicates significant explanation power of residential real estate transaction prices in Germany.

Table B.4: Spatial Impacts for Political Uncertainty and Transaction Prices

	House Prices (log)		Apartment Prices (log)	
	(1)	(2)	(3)	(4)
<i>Direct Impact</i>				
Political Uncertainty	-0.0086*** (0.0027)	-0.0132*** (0.0029)	-0.0094** (0.0041)	-0.0135*** (0.0043)
<i>Indirect Impact</i>				
Political Uncertainty	-0.0069*** (0.0023)	-0.0087*** (0.0022)	-0.0088** (0.0039)	-0.0106*** (0.0035)
<i>Total Impact</i>				
Political Uncertainty	-0.0156*** (0.0051)	-0.0219*** (0.0050)	-0.0182** (0.0084)	-0.0242*** (0.0080)


Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI Index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. The independent variable reported is the mean-scaled UPI index. For brevity, we only report coefficients of interest. The given coefficients refer to direct, indirect, and total spatial impact measures, respectively. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

Political Uncertainty Exposure and Local Economy

Based on the identified negative relationship between political uncertainty and residential real estate prices, we analyze the local exposure to political uncertainty effects on real estate prices in this subsection. As previous studies have found evidence for local economic indicators influencing the magnitude of uncertainty effects on financial outcomes and property

related variables (Luo et al., 2021; Francis et al., 2014; Waisman et al., 2015) we expect to find similar evidence analyzing German county-level real estate prices. Local real estate markets with stronger economic environment may appear rather robust against political uncertainty while economically underdeveloped regions may show higher vulnerability to political uncertainty. This expectation aligns with the evidence of Hwang and Quigley (2006) on real estate market variance being dependent on economic surroundings.

Figure B.6: Average Unemployment Rate 2013-2022 (in Percentage)



Own calculations and illustration. *Note:* This figure illustrates sample-average unemployment rates in German counties in percentage. Higher unemployment rates are denoted by darker color while lower unemployment rates are denoted by brighter color.

To empirically test the moderation effect of political uncertainty and local economic environment, we include the interaction between the UPI German Politics (referred to as political uncertainty) as proxy for political uncertainty and the county unemployment rate in our regression approach. Figure B.6 illustrates sample-averages of the county unemployment rate. Spatial clusters of high unemployment rates are visible especially in the rural northeastern and the former industrial western part of Germany and marked in darker color. We report the results of the spatial regression approaches with unemployment interactions in Table B.4. The coefficient for the interaction term is negative and highly significant for house prices, indicating a stronger impact of political uncertainty in counties where unemployment rates are higher. However, we find no significant correlation for the interaction term on apartment

prices. This might probably occur because of missing data on apartment transaction in the rural northeastern and western parts of Germany, where unemployment rates appear higher (see Figure B.6).

Table B.5: Spatial Heterogeneous Effects of Political Uncertainty on Transaction Prices

	House Prices (log)		Apartment Prices (log)	
	(1)	(2)	(3)	(4)
Political Uncertainty $\times$ Unemployment Rate	-0.0067** (0.0033)	-0.0062* (0.0032)	-0.0010 (0.0051)	-0.0022 (0.0051)
Political Uncertainty	-0.0104*** (0.0028)	-0.0132*** (0.0030)	-0.0124*** (0.0042)	-0.0136*** (0.0043)
Unemployment Rate	0.0086** (0.0036)	0.0045 (0.0034)	0.0183*** (0.0055)	0.0185*** (0.0055)
Spatial Parameter (ρ)	0.4380*** (0.0271)	0.3969*** (0.0278)	0.4706*** (0.0270)	0.4423*** (0.0276)
Controls	No	Yes	No	Yes
Year Fixed Effects	Yes	Yes	Yes	Yes
County Fixed Effects	Yes	Yes	Yes	Yes
Observations	14,400	14,400	8,892	8,892
Counties	400	400	247	247
Sigma	0.1772	0.1746	0.2104	0.2091
AIC	-35,667	-36,014	-19,073	-19,115
BIC	-35,553	-35,862	-18,966	-18,973

Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI Index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. Independent variables are the mean-scaled UPI index, unemployment rate, and the interaction term between mean-scaled UPI index and unemployment rate. Independent variables are lagged by one quarter. For brevity we report only coefficients of interest. The sample period is 2013Q2 to 2022Q2. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

Robustness Checks

To ensure the validity and generalizability of our findings on the relationship between political uncertainty and residential real estate markets, we conducted several robustness checks. These checks examine whether our results hold across different regional and temporal subsamples as well as uncertainty measures.

Baker et al. (2016) develop a proxy measure for economic policy uncertainty based on newspaper archive analysis applying uncertainty related dictionaries. Even though our analysis does not focus on economic policy uncertainty but refers to generic political uncertainty, a

comparative analysis of the economic policy uncertainty indicator (EPU) and the uncertainty perception indicator (UPI German Politics) appears appropriate. Media coverage might not separate both aspects of political uncertainty as strictly as we try to and both indices rely at least partly on similar uncertainty key words. Furthermore, the EPU is available in a version focused solely on Germany.

While we identify only moderate positive correlation between the EPU index and the UPI index used in the main regression, we use the EPU index as an alternative uncertainty measure. Doing so, we replace the UPI German Politics by the EPU index in our baseline regression depicted in equation (1) and run the regression on house and apartment prices again.¹² The results are reported in Table B.6. The estimated coefficients in columns (1) and (2) as well as (5) and (6) are weakly significant and positive for the effect of the EPU index on house prices and insignificant for the EPU on apartment prices. The contrasting results—negative for UPI, weakly positive for EPU—diverge from international evidence where EPU typically shows negative effects on real estate. Several factors may explain this divergence. First, the measures capture different uncertainty dimensions: UPI’s broader scope includes political uncertainties before they translate into economic policy concerns, while EPU focuses specifically on policy-related uncertainty. This suggests market participants may respond differently to generic versus policy-specific uncertainty. Second, Germany’s institutional context differs fundamentally from Anglo-Saxon markets studied in most EPU literature. The German market’s heavily regulated nature, strong tenant protections, and historical perception as a “safe haven” (Kofner, 2014) may create different transmission mechanisms. When uncertainty becomes policy-specific (EPU), German real estate’s stable rental yields and regulatory framework may attract capital seeking refuge from more volatile assets—a pattern less likely in liberalized markets.

However, to rule out potential overlapping between both indices, we run a variance decomposition process by regressing the EPU index on the UPI German Politics index considering the interest rate and an error correction term calculated as described in section B.1.4. The residuals of this regression, named UPI_EPU_RES are again included in the baseline regression model stated in equation (1).¹³ The resulting variable appears filtered for potential impacts that might result from economic policy uncertainty. The regression results applying the UPI_EPU_RES variables are reported in Table B.6 in columns (3) to (4) and (7) to (8). All coefficients remain highly significant and negative, indicating that the filtered political uncertainty proxy has a significant negative impact and detached house and apartment prices. The spatial impacts of the mentioned regressions are reported at the bottom of Table

¹²We mean scale the EPU index and lag it by one quarter to ensure comparability to the main regression applying the UPI index. The cointegration process is redone applying the EPU index.

¹³Descriptive statistics for the resulting variable are illustrated in Table B.1. The UPI_EPU_RES variable is mean-scaled and lagged by one quarter to ensure comparability to the previous regressions

[B.6](#). In economic terms, a one standard deviation increase of UPI_EPU_RES decreases house and apartment prices by on average approximately 2.66 and 2.95 %, respectively, *ceteris paribus*. These estimates are slightly higher than the ones of the main regression reported in [Table B.3](#) and equally significant.

Table B.6: Robustness Checks for Political Uncertainty and Economic Policy Uncertainty


	House Prices (log)				Apartment Prices (log)			
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
EPU	0.0112** (0.0048)	0.0112** (0.0048)			0.0131* (0.0071)	0.0134* (0.0070)		
UPI_EPU_RES			-0.0108*** (0.0026)	-0.0162*** (0.0029)			-0.0111*** (0.0040)	-0.0165*** (0.0042)
Spatial Parameter (ρ)	0.4475*** (0.0269)	0.4064*** (0.0276)	0.4373*** (0.0272)	0.3900*** (0.0280)	0.4893*** (0.0264)	0.4462*** (0.0275)	0.4759*** (0.0269)	0.4337*** (0.0279)
Controls	No	Yes	No	Yes	No	Yes	No	Yes
Year Fixed Effects	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
County Fixed Effects	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
Observations	14,000	14,000	14,000	14,000	8,892	8,892	8,892	8,892
Counties	400	400	400	400	247	247	247	247
Sigma	0.1773	0.1748	0.1777	0.1746	0.2111	0.2092	0.2107	0.2089
AIC	-35,650	-36,003	-35,659	-36,022	-19,058	-19,114	-19,068	-19,123
BIC	-35,551	-35,859	-35,560	-35,878	-18,965	-18,979	-18,975	-18,988
Spatial Impacts								
<i>Direct Impact</i>								
EPU	0.0113** (0.0049)	0.0115** (0.0049)			0.0127* (0.0074)	0.0137* (0.0072)		
UPI_EPU_RES			-0.0108*** (0.0026)	-0.0163*** (0.0029)			-0.0111*** (0.0040)	-0.0168*** (0.0043)
<i>Indirect Impact</i>								
EPU	0.0091** (0.0039)	0.0078** (0.0341)			0.0119* (0.0070)	0.0109* (0.0056)		
UPI_EPU_RES			-0.0083*** (0.0022)	-0.0103*** (0.0021)			-0.0099*** (0.0039)	-0.0127*** (0.0035)
<i>Total Impact</i>								
EPU	0.0205** (0.0098)	0.0193** (0.0089)			0.0245* (0.0161)	0.0246* (0.0145)		
UPI_EPU_RES			-0.0191*** (0.0050)	-0.0266*** (0.0049)			-0.0210*** (0.0079)	-0.0295*** (0.0080)

Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. Independent variables are mean-scaled EPU index by Baker et al. (2016) and UPI_EPU_RES. Independent variables are lagged by one quarter. For brevity we report only coefficients of interest. The sample period is 2013Q2 to 2022Q2. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

Another robustness test is conducted to rule out potential biases due to regional disparities within our data sample.¹⁴ Therefore, we split our samples for house prices and apartment prices in four subsamples each. Figure B.7 illustrates the apportionment based on the four main geographical regions in Germany. We then run our baseline regression depicted in equation (1) again. Table B.7 reports the results for the subsample regressions. The coefficient for political uncertainty proxied by the UPI German Politics index come out negative and highly significant for house prices. Eastern German counties, which experienced significant political and economic transformations following reunification, show the strongest sensitivity of house prices to political uncertainty. This heightened sensitivity might stem from the region’s historical experience with political instability and economic restructuring. In contrast, Western German counties, with their longer history of stable market economies, exhibit a somewhat lower sensitivity to political uncertainty. However, coefficients for UPI impact on apartment prices are negative but partly insignificant. The northern and eastern subsamples include too few observations because of missing data and their coefficients can therefore not be soundly interpreted. To sum up, the effect of political uncertainty on residential real estate prices seem to vary slightly across spatial regions but is robustly negative and significant for all interpretable subsamples.

¹⁴The four-region partition (North, West, South, East) follows the established North–South and East–West gradient in German economic geography and balances spatial granularity against subsample size given the panel’s overall dimension. Substantial regional heterogeneity in German housing markets is well-documented (Brausewetter et al., 2024). The aim is to verify whether the estimated effect of political uncertainty is robust across major geographical sub-markets rather than driven by particular sub-regions. We acknowledge that coverage is uneven, with the apartment East subsample comprising of fewer counties.

Figure B.7: Spatial Regions of Germany



Own calculations and illustration. *Note:* This figure illustrates the apportionment of Germany in four spatial regions. Northern, southern, eastern and western part are depicted in different colors.

Table B.7: Robustness Checks for Spatial Regions

	House Prices (log)				Apartment Prices (log)			
	(North)	(West)	(South)	(East)	(North)	(West)	(South)	(East)
Political Uncertainty	-0.0119** (0.0046)	-0.0151*** (0.0040)	-0.0109** (0.0043)	-0.0340*** (0.0115)	-0.0083 (0.0125)	-0.0161** (0.0072)	-0.0101* (0.0052)	-0.0192 (0.0351)
Interest Rate	0.0200 (0.0323)	0.0206 (0.0295)	0.0111 (0.0276)	0.0731 (0.0834)	-0.0581 (0.0850)	0.0003 (0.0480)	-0.0210 (0.0359)	-0.2086 (0.1648)
Error Correction Term	-0.0113* (0.0062)	-0.0159** (0.0059)	-0.0137** (0.0057)	-0.0253 (0.0154)	0.0015 (0.0185)	-0.0135 (0.0102)	0.0026 (0.0076)	0.0040 (0.0417)
House Offerings	-0.0012 (0.0034)	-0.0117*** (0.0036)	0.0011 (0.0027)	-0.0083 (0.0057)				
Apartment Offerings					-0.0039 (0.0090)	-0.0021 (0.0074)	0.0094** (0.0045)	-0.0225 (0.0221)
Spatial Parameter (ρ)	0.4464*** (0.0502)	0.3886*** (0.0502)	0.3696*** (0.0374)	0.0791 (0.0658)	0.2251*** (0.0639)	0.3565*** (0.0551)	0.4522*** (0.0408)	-0.0716 (0.0638)
Controls	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
Year Fixed Effects	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
County Fixed Effects	Yes	Yes	Yes	Yes	Yes	Yes	Yes	Yes
Observations	2,268	4,356	5,040	2,736	1,620	3,384	3,636	252
Counties	63	121	140	76	45	94	101	7
Sigma	0.1122	0.1379	0.1441	0.2823	0.2582	0.2167	0.1672	0.2402
AIC	-7,697	-12,931	-14,544	-4,169	-2,759	-6,975	-9,460	-450
BIC	-7,588	-12,810	-14,420	-4,056	-2,656	-6,858	-9,342	-383
Spatial Impacts								
<i>Direct Impact</i>								
Political Uncertainty	-0.0125** (0.0048)	-0.0152*** (0.0038)	-0.0108** (0.0043)	-0.0348*** (0.0117)	-0.0085 (0.0122)	-0.0164** (0.0071)	-0.0101* (0.0051)	-0.0186 (0.0329)
<i>Indirect Impact</i>								
Political Uncertainty	-0.0096** (0.0043)	-0.0097*** (0.0030)	-0.0062** (0.0026)	-0.0033 (0.0028)	-0.0025 (0.0030)	-0.0093** (0.0043)	-0.0083* (0.0044)	-0.0014 (0.0051)
<i>Total Impact</i>								
Political Uncertainty	-0.0218** (0.0093)	-0.0249*** (0.0069)	-0.0170** (0.0069)	-0.0380*** (0.0132)	-0.0111 (0.0164)	-0.0257** (0.0118)	-0.0184* (0.0101)	-0.0199 (0.0373)

Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. The data sets are divided in spatial regions for robustness tests. Independent variables are lagged by one quarter. For brevity we report only coefficients of interest. The sample period is 2013Q2 to 2022Q2. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

In addition, we address potential urban and rural differences in the effect of political uncertainty on residential real estate prices since the population density significantly influences residential real estate markets within our baseline regression approach (see Table B.3). We split our samples in an urban and rural subsample each.¹⁵ Then we rerun the main regression as stated in equation (1) to identify potential differences in political uncertainty perception based on settlement structure. The results are reported in Table B.8.

Urban counties show a stronger negative response to political uncertainty compared rural counties. This pattern may reflect the greater integration of urban real estate markets with national and international economic trends, making them more responsive to political developments. Additionally, urban real estate markets typically have higher price levels and greater investor participation, potentially amplifying the effects of uncertainty. The stronger effect of political uncertainty in urban areas may also be explained by the higher valuation levels in urban areas. Whenever political uncertainty leads to an increase in the discount rate, real estate values in urban and thus more expensive regions are more severely affected than less expensive regions, which are more likely to be in rural areas. However, the negative relationship of political uncertainty and residential real estate prices remains significant even though population settlement shows some moderating effect.

Further, we conduct robustness checks on temporal biases within our data. Spanning from 2013 to 2022, our data set includes the COVID-19 pandemic. This major external shock is found to have substantial impact on real estate markets across the globe. Qian et al. (2021) find empirical evidence for declining house prices in China during the pandemic. Głuszak and Belniak (2020) report similar effects analyzing house prices in UK. In contrast, Gamber et al. (2023) as well as Zhang et al. (2023) find evidence for increasing house prices due to and increasing demand meeting limited supply analyzing US data. To further address the potential impact of the COVID-19 pandemic on the effect of political uncertainty perception analyzing residential real estate prices, we split our samples in pre and post COVID-19 subsamples each. We then rerun the regression stated in equation (1) on the data subsamples. Table B.9 reports the results. The coefficients for political uncertainty remain negative and highly significant in all outcomes. However, we observe a small decline in coefficients in the post COVID-19 samples compared to the pre COVID-19 samples. This may probably occur due to constant higher levels of political uncertainty (see Figure B.1 for illustration) and eventuating familiarization effects.

Conducting several robustness tests to address potential biases within our sample or variable definitions, we empirically prove stable and significant negative effects of political uncertainty on residential real estate prices in German counties.

¹⁵Counties with a population density above 250 inhabitants/km² are defined as urban, below as rural.

Table B.8: Robustness Checks for Urbanity

	House Prices (log)		Apartment Prices (log)	
	(Urban)	(Rural)	(Urban)	(Rural)
Political Uncertainty	-0.0132*** (0.0046)	-0.0101*** (0.0038)	-0.0165*** (0.0052)	-0.0151** (0.0068)
Interest Rate	0.0142 (0.0272)	0.0143 (0.0269)	-0.0042 (0.0343)	-0.0378 (0.0431)
Error Correction Term	-0.0140** (0.0062)	-0.0061 (0.0052)	-0.0135* (0.0074)	-0.0025 (0.0097)
Spatial Parameter (ρ)	0.1662*** (0.0372)	0.4331*** (0.0320)	0.3690*** (0.0317)	0.2779*** (0.0372)
Controls	Yes	Yes	Yes	Yes
Year Fixed Effects	Yes	Yes	Yes	Yes
County Fixed Effects	Yes	Yes	Yes	Yes
Observations	6,192	8,208	4,572	4,320
Counties	172	228	127	120
Sigma	0.1790	0.1683	0.1823	0.2334
AIC	-15,106	-21,161	-11,074	-8,277
BIC	-14,978	-21,028	-10,952	-8,156
Spatial Impacts				
<i>Direct Impact</i>				
Political Uncertainty	-0.0132*** (0.0048)	-0.0101*** (0.0038)	-0.0166*** (0.0053)	-0.0149** (0.0068)
<i>Indirect Impact</i>				
Political Uncertainty	-0.0027** (0.0011)	-0.0077*** (0.0030)	-0.0095*** (0.0030)	-0.0056** (0.0023)
<i>Total Impact</i>				
Political Uncertainty	-0.0159** (0.0059)	-0.0179*** (0.0068)	-0.0260*** (0.0088)	-0.0205** (0.0097)

Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. The data sets are divided into subsamples containing urban and rural regions, respectively. Independent variables are lagged by one quarter. For brevity we report only coefficients of interest. The sample period is 2013Q2 to 2022Q2. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

Table B.9: Robustness Checks for COVID-19

	House Prices (log)		Apartment Prices (log)	
	(Pre COVID19)	(Post COVID19)	(Pre COVID19)	(Post COVID19)
Political Uncertainty	-0.0173*** (0.0049)	-0.0140*** (0.0033)	-0.0152** (0.0075)	-0.0163*** (0.0045)
Interest Rate	-0.0190 (0.0229)	0.2734*** (0.0379)	-0.0438 (0.0321)	0.2374*** (0.0509)
Error Correction Term	-0.0172*** (0.0058)	-0.0073 (0.0060)	-0.0086 (0.0085)	-0.0004 (0.0097)
Spatial Parameter (ρ)	0.2941*** (0.0361)	0.3818*** (0.0505)	0.4315*** (0.0327)	0.3474*** (0.0585)
Controls	Yes	Yes	Yes	Yes
Year Fixed Effects	Yes	Yes	Yes	Yes
County Fixed Effects	Yes	Yes	Yes	Yes
Observations	10,400	4,000	6,422	2,470
Counties	400	400	247	247
Sigma	0.1859	0.1112	0.2274	0.1248
AIC	-24,637	-13,605	-12,721	-7,828
BIC	-24,521	-13,530	-12,613	-7,756
Spatial Impacts				
<i>Direct Impact</i>				
Political Uncertainty	-0.0172*** (0.0048)	-0.0139*** (0.0035)	-0.0154* (0.0079)	-0.0164*** (0.0044)
<i>Indirect Impact</i>				
Political Uncertainty	-0.0072*** (0.0024)	-0.0086*** (0.0028)	-0.0115* (0.0062)	-0.0088*** (0.0031)
<i>Total Impact</i>				
Political Uncertainty	-0.0244*** (0.0070)	-0.0226*** (0.0059)	-0.0269* (0.0139)	-0.0252*** (0.0072)

Note: This table presents the results of spatial autoregressive regressions analyzing the impact of political uncertainty proxied by the UPI index by Rieger et al. (2023) on house prices and apartment prices. The dependent variables are logarithmized average house prices and apartment prices per square meter, respectively. The data sets are divided into subsamples with sample periods from 2013Q2 to 2019Q4 and from 2020Q1 to 2022Q2, respectively. The subsampling is detailed in Section B.1.4 and performed for robustness tests. Independent variables are lagged by one quarter. For brevity we report only coefficients of interest. Newey–West robust standard errors are in parentheses. Significance levels are indicated by *** $p < 0.01$, ** $p < 0.05$, and * $p < 0.10$.

B.1.5 Conclusion

This study examines how political uncertainty affects real estate markets in Germany using the Uncertainty Perception Index rather than commonly used indicators like the EPU as the UPI German Politics captures a broader spectrum of political uncertainty, making it well-suited for Germany’s heavily regulated housing markets where political decisions directly impact investment conditions. Germany provides an ideal setting for this research due to its extensive housing regulations and recent experiences with significant political uncertainty from migration, COVID-19, and geopolitical tensions. Our analysis uses a dataset covering all 400 German counties over 2013-2022, allowing us to capture local market variations while controlling for regional conditions.

Our spatial econometric approach addresses the inherent neighborhood dependencies in real estate markets, with findings showing that 40-50% of political uncertainty’s effect comes from spatial spillovers. Robustness checks reveal stronger negative effects in Eastern Germany and economically underdeveloped counties, with intensified impacts before the COVID-19 pandemic emerges.

Our results show that political uncertainty leads to lower residential real estate prices as investors may adopt a wait-and-see approach. This uncertainty-induced investment delay constrains housing supply, potentially worsening affordability challenges. Therefore, alongside conventional measures, clear and consistent policy frameworks that minimize uncertainty could help stimulate real estate activity and address housing shortages. However, the price discounts due to political uncertainty identified may also represent investment opportunities for investors willing to take risks.

While we rely on a nation-wide political uncertainty measure, developing regional-specific political uncertainty indices at the county level could capture local variations and provide more granular insights. In addition to national political uncertainty, there is also local and supraregional political uncertainty. This arises, for example, as a result of building regulations, citizens’ initiatives, funding allocations, or local representative elections, and would need to be measured individually on a local basis. Despite this limitation, our primary interest was first understanding how generic nation-wide political uncertainty unfolds regionally in real estate markets. Our analysis period (2013-2022) may not capture longer-term market cycles, suggesting value in extended timeframe studies. Additional research could explore uncertainty’s differential impacts across property types, price segments, and investor categories, while comparative studies across countries with different regulatory environments would provide valuable insights into how institutional contexts mediate uncertainty’s effects on housing markets.

Teil C

Synthese

Diese Dissertation untersucht die Wechselwirkungen zwischen regulatorischen Eingriffen, Marktdynamiken und politischer Unsicherheit regionalspezifisch auf deutschen Wohnungsmärkten. Der Titel spannt dabei die zentralen Analyseebenen auf: das „Spannungsfeld“ zwischen sozialpolitischen Zielen und ökonomischen Marktreaktionen, die „regionale Heterogenität“ als entscheidende Kontextebene und die „politische Steuerung“ als Untersuchungsgegenstand. Die empirischen Analysen offenbaren ein fundamentales Spannungsverhältnis: Während die deutsche Wohnungspolitik auf soziale Stabilität und Mieterschutz zielt, erzeugen die implementierten Instrumente nicht intendierte Marktverzerrungen, die paradoxerweise genau jene Gruppen belasten können, die sie schützen sollen.

Die duale Marktstruktur als empirische Diagnose Die Analyse der Mietpreisdynamiken (Kapitel A.1) dokumentiert eine zunehmend als Kernproblem wahrgenommene Segmentierung deutscher Wohnungsmärkte zwischen Neuvertrags- und Bestandsmieten mit relativen Differenzen von durchschnittlich 20-25%, die in den bevölkerungsreichsten Metropolen auf über 40% ansteigen. Diese Divergenz ist primär marktgetrieben – ökonomische, demografische und angebotsseitige Faktoren erklären den Großteil der Variation. Die zentrale Repräsentation der „politischen Steuerung“, die Mietpreisbremse, zeigt sich ad hoc als ineffektiv; ihre Wirkung entfaltet sich erst verzögert und senkt die relativen Differenzen statistisch signifikant um lediglich 1,9 Prozentpunkte. Die Ursachen liegen systemisch: Ausnahmen und Durchsetzungsdefizite schwächen den Schutz bei Neuverträgen, während effektiverer Bestandsschutz die Segregation verstärkt. Räumliche Spillover verschärfen darüber hinaus regionale Disparitäten.

Wohlfahrtstheoretische Ambivalenzen der Regulierung Aufbauend auf der Diagnose der Marktsegmentierung, evaluiert Kapitel A.2 per Mikrosimulation die kontrafaktischen Effekte einer Auflösung dieser Asymmetrie. Die Simulation einer Angleichung von Bestands- an Neuvertragsmieten illustriert das Dilemma zwischen Effizienz und Verteilung. Der positive Nettowohlfahrtseffekt (+0,38 Mrd.€ per annum) suggeriert aggregierte Effizienzgewinne. Diese resultieren aus der Auflösung von Lock-In-Effekten und effizienterer Wohnraumallokation. Mieter kompensieren einen Teil der Mehrkosten durch optimierte Flächenwahl, wodurch

ihr Wohlfahrtsverlust unter den Mehrausgaben liegt. Disaggregiert zeigen sich aber erhebliche Verteilungskonflikte: 73% der Miethaushalte weisen Wohlfahrtsverluste auf, wobei die relative Belastung für untere Einkommensgruppen am höchsten ist. Zentral ist die fiskalische Reaktion: Der Staat als fiskalische Entität profitiert netto. Dies resultiert aus rigiden Transfersystemen bei gleichzeitig steigenden Steuereinnahmen aus Vermietung. Die Effizienzgewinne fallen somit primär bei Vermietern und Staat an, während die Mieterlasten regressiv verteilt sind.

Von der direkten Steuerung zur subtilen Einflussgröße Während Teil A die realisierten Auswirkungen von Regulierungsinstrumenten auf dem Mietmarkt analysierte, erweitert Teil B den Fokus. Er untersucht, wie „politische Steuerung“ bereits vor ihrer Implementierung, als Unsicherheit, wirkt. Dieser Ansatz wechselt von der ex-post-Betrachtung zur ex-ante-Perspektive der Antizipation und Erwartungsbildung. Damit wird ein subtiler, aber fundamentaler Mechanismus der politischen Steuerung beleuchtet: die Verhaltensänderung von Investoren als Reaktion auf wahrgenommene Instabilität. Methodisch verschiebt sich der Fokus vom Mietmarkt auf den Investment- und Eigentumsmarkt, um die Kapitalisierungs- und Angebotseffekte zu messen.

Politische Unsicherheit als Einflussfaktor Die Analyse des Einflusses politischer Unsicherheit (Kapitel B.1) quantifiziert diese subtilen Einflüsse. Die isolierte Reduktion der Immobilienpreise bei höherem Unsicherheitsindex mag moderat erscheinen, doch die kumulativen Effekte über Zeit und Raum sind substantiell. Das „wait-and-see“-Verhalten könnte Angebotserweiterungen verzögern und damit Knappheit verschärfen. Hier schließt sich der Kreis zu Teil A: Die ineffektive Regulierung verzerrt die Allokation im Bestand, während politische Unsicherheit scheinbar implizit den Neubau ausbremsen könnte. Problematisch ist die Verstärkung in wirtschaftlich schwachen Regionen, wo Unsicherheit auf fragile Märkte trifft. Räumliche Spillover zeigen zudem, dass nationale Unsicherheit regional unterschiedliche Dynamiken auslöst.

Implikationen für eine evidenzbasierte Wohnungspolitik Aus diesen Syntheserkenntnissen lassen sich folgende Schlussfolgerungen für die deutsche Wohnungspolitik ableiten:

Erstens erweist sich die derzeitige Regulierungsarchitektur als dysfunktional. Die asymmetrische Regulierung zwischen Bestands- und Neuvertragssegment erzeugt Marktverzerrungen ohne Schutzwirkung für bestimmte vulnerable Gruppen im Neuvertragssegment. Gerade mobile Gruppen wie junge Erwerbstätige und Familien, die ihren Wohnraum häufiger anpassen müssen, leiden unter einem Mangel an bezahlbarem Wohnraum im Neuvertragsmarkt, während sesshaftere Bestandsmieter vom stärkeren Schutz profitieren und folglich keiner-

lei Anreiz haben, ihre Wohnsituation anzupassen. Zur Überwindung der Ineffizienzen dieses Lock-in-Effekts kommen zwei grundsätzlich entgegengesetzte Reformpfade in Betracht: Eine regulatorische Konvergenz durch Verschärfung, etwa durch strengere Durchsetzung der Mietpreisbremse, Reduktion von Ausnahmen und mehr Transparenz, würde die Preisdifferenzen direkt adressieren. Alternativ könnte eine marktorientierte Deregulierung die Bestandsschutzregulierung symmetrisch lockern, um Allokationsverzerrungen abzubauen.

Zweitens zeigt die dominante Rolle marktstruktureller Determinanten in der Erklärung der Segmentierung, dass angebotsseitige Maßnahmen ebenfalls flankierend Wirkung entfalten können. Die dämpfende Wirkung nicht-gewinnorientierter Vermieter deutet auf das Potenzial alternativer Eigentumsstrukturen. Zwar können sowohl eine allgemeine Angebotsausweitung das Preisniveau im Neuvertragssegment unter Druck setzen als auch mehr nicht-gewinnorientierte Anbieter über Preissignale und Wettbewerb die Mieten dämpfen, jedoch wirken diese Effekte primär langfristig. Zudem stehen nicht-gewinnorientierte Wohnungsunternehmen oft in Verbindung mit Subventionen, deren mögliche Ineffizienzen in dieser Arbeit nicht betrachtet werden. Gleichzeitig zeigt Kapitel [B.1](#), dass die Reduktion von politischer Unsicherheit selbst eine effektive Angebotspolitik darstellen kann, indem sie Investitionszurückhaltung löst.

Drittens erfordert die regressive Verteilungswirkung der dokumentierten Marktanpassungen einer Angleichung von Bestand- an ein Neuvertragsmietniveau (Kapitel [A.2](#)) gezielte sozialpolitische Flankierungen. Die Simulation zeigt, dass bestehende wohnrelevante Transfersysteme ohne Parameteranpassung nur geringfügig auf einen Preisschock reagieren. Aus sozialpolitischer Sicht könnten Transferhöhen in Folge einer solchen Reform dynamisch an Marktentwicklungen gekoppelt werden, um die in Kapitel [A.2](#) identifizierten fiskalischen Mehreinnahmen zur Kompensation bedürftiger Miethaushalte zu nutzen.

Viertens muss politische Kommunikation die ökonomischen Kosten der Unsicherheit im Kontext von Wohnungsmärkten anerkennen. Die nachgewiesenen Preisverwerfungen und Investitionsverzögerungen durch politische Unsicherheit verschärfen Angebotsengpässe. Klare, langfristige regulatorische Rahmenbedingungen – selbst wenn sie Einschränkungen beinhalten – sind politisch unsicheren Situationen vorzuziehen.

Fünftens unterstreicht diese Arbeit die Notwendigkeit stärkerer quantitativer Forschung im Bereich der Wohnungsmärkte. Die hier angewandten Ansätze – von der räumlichen Ökonometrie bis zur dynamischen Mikrosimulation – sind entscheidend, um die komplexen Wechselwirkungen und unbeabsichtigten Folgen politischer Steuerung auf regional heterogenen Märkten zu antizipieren und zu bewerten. Politische Entscheidungen sollten daher systematisch auf solchen Analysen fußen. Um die Belastbarkeit dieser Evidenzbasis künftig weiter

zu erhöhen, müssen die in dieser Arbeit identifizierten methodischen Limitationen adressiert werden. Zwar erlauben die verwendeten Proxies und Modelle robuste Trendaussagen – beispielsweise wird die tendenzielle Überschätzung der Mietdifferenzen durch Angebotsmieten teilweise durch die konservative Schätzung mittels Mietspiegelmieten als Proxy für Bestandsmieten kompensiert, und die Simulation auf Basis von Querschnittsdaten bildet trotz statischer Grundlage plausible Langfrist-Anpassungen ab – jedoch bleibt Raum für Verfeinerungen. Priorität für zukünftige Forschung haben daher die Entwicklung granularer Mikrodaten zu tatsächlichen Transaktionsmieten inklusive Vertragshistorien, die Evaluation natürlicher Experimente bei Regulierungsänderungen zur präziseren kausalen Identifikation von Politikeffekten sowie die Entwicklung regionalisierter Indikatoren für politische Unsicherheit. Eine konsequente Investition in Dateninfrastruktur und quantitative Analysemethoden ist somit selbst eine zentrale wohnungspolitische Maßnahme zur Verbesserung zukünftiger wohnungspolitischer Maßnahmen.

Fazit: Die Grenzen technokratischer Lösungen Die Wohnungsfrage ist ein inhärent politisches Problem, das technokratische Lösungsansätze übersteigt. Die dokumentierten Zielkonflikte – etwa zwischen der Effizienz einer flexiblen Wohnraumallokation und der sozialen Stabilität durch starken Bestandsschutz, oder zwischen dem intendierten Schutz lokaler Märkte und den unbeabsichtigten regionalen Spillover-Effekten aufgrund vernetzter Märkte – sind nur bedingt durch optimale Regulierung auflösbar, sondern erfordern eine ehrliche Aushandlung über Prioritäten.

Die im Vorwort zitierte Mahnung Hayeks über die Grenzen wirtschaftspolitischer Gestaltung findet in den empirischen Befunden Bestätigung: Komplexe Marktsysteme reagieren auf Interventionen mit unerwarteten Anpassungen, die intendierte Wirkungen konterkarieren können. Dies negiert nicht die Legitimität sozialpolitischer Zielsetzungen, mahnt aber zu Bescheidenheit bezüglich der Steuerbarkeit von Marktergebnissen.

Die zentrale Erkenntnis dieser Arbeit ist paradox: Gerade weil Wohnen ein soziales Grundbedürfnis darstellt, müssen wohnungspolitische Interventionen die inhärenten Marktmechanismen respektieren. Regulierungen, die gegen fundamentale ökonomische Anreize arbeiten, erzeugen Ausweichreaktionen, die vulnerable Gruppen zusätzlich belasten können. Eine nachhaltige Wohnungspolitik muss daher Marktmechanismen nicht bekämpfen, sondern intelligent nutzen - durch Anreizgestaltung statt Verboten, durch Angebotsexpansion statt Preisdeckelung, durch transparente, langfristige Regulierung statt volatiler Interventionen.

Literaturverzeichnis

- Ahlfeldt, G. M., S. Heblich und T. Seidel (2023). “Micro-geographic property price and rent indices”. In: *Regional Science and Urban Economics* 98, S. 103836.
- Albouy, D., G. Ehrlich und M. Liu (2016). “Housing Demand, Cost-of-Living Inequality, and the Affordability Crisis”. In: *NBER Working Paper* No. 22816.
- Allen, M. T., R. C. Rutherford und T. A. Thomson (2009). “Residential Asking Rents and Time on the Market”. In: *The Journal of Real Estate Finance and Economics* 38.4, S. 351–365.
- Amisano, G. und O. Tristani (2019). “Uncertainty Shocks, Monetary Policy and Long-Term Interest Rates”. In: *ECB Working Paper* 2279.
- André, C., L. Bonga-Bonga, R. Gupta und J. W. Muteba Mwamba (2017). “Economic Policy Uncertainty, U.S. Real Housing Returns and Their Volatility: A Nonparametric Approach”. In: *Journal of Real Estate Research* 39.4, S. 493–514.
- Anenberg, E. und P. Bayer (2013). “Endogenous Sources of Volatility in Housing Markets: The Joint Buyer–Seller Problem”. In: *International Economic Review* 61.3, S. 1195–1228.
- Anselin, L. (1988). *Spatial Econometrics*. Bd. v.4. Studies in Operational Regional Science Ser. Dordrecht: Springer Netherlands.
- Antonakakis, N., R. Gupta und C. André (2015). “Dynamic Co-movements between Economic Policy Uncertainty and Housing Market Returns”. In: *Journal of Real Estate Portfolio Management* 21.1, S. 53–60.
- Arnott, R. (1995). “Time for revisionism on rent control?” In: *Journal of Economic Perspectives* 9.1, S. 99–120.
- Arnott, R. (2003). “Tenancy Rent Control”. In: *Swedish Economic Policy Review* 10.1, S. 89–121.
- Arnott, R. und M. Igarashi (2000). “Rent Control, Mismatch Costs and Search Efficiency”. In: *Regional Science and Urban Economics* 30.3, S. 249–288.
- Articus, C., H. Brenzel und R. T. Münnich (2020). “Analysing local-level rental markets based on the German Mikrozensus”. In: *Research Papers in Economics, Universität Trier* 9/20.
- Autor, D. H., C. J. Palmer und P. A. Pathak (2014). “Housing Market Spillovers: Evidence from the End of Rent Control in Cambridge, Massachusetts”. In: *Journal of Political Economy* 122.3, S. 661–717.

- Azzimonti, M. (2018). “Partisan conflict and private investment”. In: *Journal of Monetary Economics* 93, S. 114–131.
- Bach, S., G. Corneo und V. Steiner (2013). “Effective Taxation of Top Incomes in Germany”. In: *German Economic Review* 14.2, S. 115–137.
- Baker, S. R., N. Bloom und S. J. Davis (2016). “Measuring Economic Policy Uncertainty*”. In: *The Quarterly Journal of Economics* 131.4, S. 1593–1636.
- Baldenius, T., S. Kohl und M. Schularick (2020). “Die neue Wohnungsfrage. Gewinner und Verlierer des deutschen Immobilienbooms”. In: *Leviathan* 48.2, S. 195–236.
- Baltagi, B. H. (2021). *Econometric Analysis of Panel Data*. 6. Aufl. Springer Texts in Business and Economics. Cham: Springer.
- Basu, S. und B. Bundick (2017). “Uncertainty Shocks in a Model of Effective Demand”. In: *Econometrica* 85.3, S. 937–958.
- Baye, V. und V. Dinger (2024). “Investment incentives of rent controls and gentrification: Evidence from German micro data”. In: *Real Estate Economics* 52.3, S. 843–884.
- BBSR (2020). *Strukturelle Verbesserung der Anreize und Dynamisierung des Wohngeldes*. BBSR-Online-Publikation 16/2019. BBSR.
- BBSR (2021). *Wohnungs- und Immobilienmärkte in Deutschland 2020*. Einzelpublikation. Bonn: Bundesinstitut für Bau-, Stadt- und Raumforschung.
- BBSR (2025). *Mietpreisbremse und abgesenkte Kappungsgrenze: Eine Bestandsaufnahme*. BBSR-Online-Publikation. Bonn: Bundesinstitut für Bau-, Stadt- und Raumforschung im Bundesamt für Bauwesen und Raumordnung.
- Bloom, N., M. Floetotto, N. Jaimovich, I. S. Eksten und S. J. Terry (2018). “Really Uncertain Business Cycles”. In: *Econometrica* 86.3, S. 1031–1065.
- Boeing, G., J. Wegmann und J. Jiao (2020). “Rental Housing Spot Markets: How Online Information Exchanges Can Supplement Transacted-Rent Data”. In: *Journal of Planning Education and Research* 43.4, S. 903–920.
- Brausewetter, L., S. L. Thomsen und J. Trunzer (2024). “Regional Supply and Demand Fundamentals in the German Housing Price Boom”. In: *German Economic Review* 25.1, S. 1–36.
- Breidenbach, P., L. Eilers und J. Fries (2022). “Temporal dynamics of rent regulations – The case of the German rent control”. In: *Regional Science and Urban Economics* 92, S. 103737.
- Bruckmeier, K. und J. Wiemers (2012). “A new targeting: a new take-up?” In: *Empirical Economics* 43.2, S. 565–580.
- Brunauer, W. A., S. Lang, P. Wechselberger und S. Bienert (2010). “Additive Hedonic Regression Models with Spatial Scaling Factors: An Application for Rents in Vienna”. In: *The Journal of Real Estate Finance and Economics* 41.4, S. 390–411.
- Brunnermeier, M. K. und Y. Sannikov (2014). “A Macroeconomic Model with a Financial Sector”. In: *American Economic Review* 104.2, S. 379–421.

- Bulan, L., C. Mayer und C. T. Somerville (2009). “Irreversible Investment, Real Options, and Competition: Evidence from Real Estate Development”. In: *Journal of Urban Economics* 65.3, S. 237–251.
- Bundesagentur für Arbeit (2024). *Statistik der Bundesagentur für Arbeit: Lange Zeitreihen zur Arbeitslosigkeit*. https://statistik.arbeitsagentur.de/DE/Navigation/Statistiken/Interaktive-Statistiken/Zeitreihen/Lange-Zeitreihen-Nav.html?Fachstatistik=alo&DR_Gebietsstruktur=d&Gebiete_Region=Deutschland&DR_Region=d&DR_Region_d=d&DR_RK=insg&mapHadSelection=false&toggleswitch_saison=0.
- Bundesbank (2023). *Indikatorensystem zum Wohnimmobilienmarkt*.
- Cameron, A. C. und D. L. Miller (2015). “A Practitioner’s Guide to Cluster-Robust Inference”. In: *Journal of Human Resources* 50.2, S. 317–372.
- Canes-Wrone, B. und J.-K. Park (2014). “Elections, Uncertainty and Irreversible Investment”. In: *British Journal of Political Science* 44.1, S. 83–106.
- Causa, O. und J. Pichelmann (2020). *Should I Stay or Should I Go? Housing and Residential Mobility Across OECD Countries*. OECD Economics Department Working Papers 1626. Paris: OECD Publishing.
- Choudhry, T. (2020). “Economic Policy Uncertainty and House Prices: Evidence from Geographical Regions of England and Wales”. In: *Real Estate Economics* 48.2, S. 504–529.
- Christou, C., R. Gupta und C. Hassapis (2020). “Does Economic Policy Uncertainty Forecast Real Housing Returns in a Panel of OECD Countries? A Bayesian Approach”. In: *Quarterly Review of Economics and Finance* 77, S. 115–126.
- Clayton, J., G. MacKinnon und L. Peng (2008). “Time Variation of Liquidity in the Private Real Estate Market: An Empirical Investigation”. In: *The Journal of Real Estate Research* 30.2, S. 125–160.
- Çolak, G., A. Durnev und Y. Qian (2017). “Political Uncertainty and IPO Activity: Evidence from U.S. Gubernatorial Elections”. In: *Journal of Financial and Quantitative Analysis* 52.6, S. 2523–2564.
- Conway, D., C. Q. Li, J. Wolch, C. Kahle und M. Jerrett (2010). “A Spatial Autocorrelation Approach for Examining the Effects of Urban Greenspace on Residential Property Values”. In: *The Journal of Real Estate Finance and Economics* 41.2, S. 150–169.
- Davidson, R. und J. G. MacKinnon (1993). *Estimation and Inference in Econometrics*. New York: Oxford University Press.
- Davis, M. A. und F. Ortalo-Magné (2011). “Household Expenditures, Wages, Rents”. In: *Review of Economic Dynamics* 14.2, S. 248–261.
- Demiralay, S. und E. Kilincarslan (2022). “Uncertainty Measures and Sector-Specific REITs in a Regime-Switching Environment”. In: *The Journal of Real Estate Finance and Economics*, S. 1–40.

- Deppner, J. und M. Cajias (2022). “Accounting for Spatial Autocorrelation in Algorithm-Driven Hedonic Models: A Spatial Cross-Validation Approach”. In: *The Journal of Real Estate Finance and Economics* 68.2, S. 235–273.
- Deschermeier, P., H. Haas, M. Hude und M. Voigtländer (2016). “A First Analysis of the New German Rent Regulation”. In: *International Journal of Housing Policy* 16.3, S. 293–315.
- Deschermeier, P., R. Henger und M. Voigtländer (2024). *Mehr Wohnungsmangel durch steigende Bedarfe und sinkende Bautätigkeit*. Gutachten. Im Auftrag der Deutsche Reihenhaus AG. https://www.iwkoeln.de/fileadmin/user_upload/Studien/Gutachten/PDF/2024/IW-Gutachten_2024-Wohnungsbaubedarfe.pdf. Institut der deutschen Wirtschaft Köln.
- Deutsche Bundesbank (2024). *MFI-Zinsstatistik: Effektivzinssätze Banken DE / Neugeschäft / besicherte Wohnungsbaukredite an private Haushalte*. <https://www.bundesbank.de/de/statistiken/geld-und-kapitalmaerkte/zinssaetze-und-renditen/mfi-zinsstatistik-bestaende-neugeschaefte--650658>.
- Deutsche Bundesbank (2025). “Vermögen und Finanzen privater Haushalte in Deutschland: Ergebnisse der Vermögensbefragung 2023”. In: *Monatsbericht der Deutschen Bundesbank*.
- Deutscher Bundestag (2025). *Entwurf eines Gesetzes zur Änderung der Regelungen über die zulässige Miethöhe bei Mietbeginn*. Bundestags-Drucksache.
- Diamond, R., T. McQuade und F. Qian (2019). “The Effects of Rent Control Expansion on Tenants, Landlords, and Inequality: Evidence from San Francisco”. In: *American Economic Review* 109.9, S. 3365–3394.
- DiPasquale, D. und W. C. Wheaton (1994). “Housing market dynamics and the future of housing prices”. In: *Journal of Urban Economics* 35.1, S. 1–27.
- DiPasquale, D. und W. C. Wheaton (1996). *Urban Economics and Real Estate Markets*. Englewood Cliffs, NJ: Prentice Hall.
- Dixit, A. K. und R. S. Pindyck (1994). *Investment Under Uncertainty*. Princeton University Press.
- Drukker, D. M., I. R. Prucha und R. Raciborski (2013). “Maximum likelihood and generalized spatial two-stage least-squares estimators for a spatial-autoregressive model with spatial-autoregressive disturbances”. In: *Stata Journal* 13.2, S. 221–241.
- Ehlert, A., A. Lagemann und J. Wedemeier (2024). “Regional Variation in German Real Estate Prices: Socio-Economic and Pandemic Influences”. In: *Bremen Papers on Economics & Innovation* 2402.
- Elhorst, J. (2010). “Applied Spatial Econometrics: Raising the Bar”. In: *Spatial Economic Analysis* 5.1, S. 9–28.
- Emmenegger, J. und R. Münnich (2023). “Localising the Upper Tail: How Top Income Corrections Affect Measures of Regional Inequality”. In: *Journal of Economics and Statistics* 243.3-4, S. 285–317.

- Ermisch, J. F., J. Findlay und K. Gibb (1996). “The Price Elasticity of Housing Demand in Britain: Issues of Sample Selection”. In: *Journal of Housing Economics* 5.1, S. 64–86.
- Eurostat (2024). *Distribution of population by tenure status - EU-SILC survey*. Eurostat Database. Data extracted for reference year 2023. Code: [ilc_lvh002].
- Fallis, G. und L. B. Smith (1984). “Uncontrolled Prices in a Controlled Market: The Case of Rent Controls”. In: *The American Economic Review* 74.1, S. 193–200.
- Favilukis, J., P. Mabilie und S. van Nieuwerburgh (2023). “Affordable Housing and City Welfare”. In: *The Review of Economic Studies* 90.1, S. 293–330.
- Ferrara, L. und P. Guérin (2018). “What are the macroeconomic effects of high-frequency uncertainty shocks?” In: *Journal of Applied Econometrics* 33.5, S. 662–679.
- Fisher, J., D. Geltner und H. Pollakowski (2007). “A Quarterly Transactions-based Index of Institutional Real Estate Investment Performance and Movements in Supply and Demand”. In: *The Journal of Real Estate Finance and Economics* 34.1, S. 5–33.
- Francis, B. B., I. Hasan und Y. Zhu (2014). “Political uncertainty and bank loan contracting”. In: *Journal of Empirical Finance* 29, S. 281–286.
- Francke, M. K. und G. A. Vos (2004). “The Hierarchical Trend Model for Property Valuation and Local Price Indices”. In: *The Journal of Real Estate Finance and Economics* 28.2–3, S. 179–208.
- Friedman, J. und D. H. Weinberg (1981). “The Demand for Rental Housing: Evidence from the Housing Allowance Demand Experiment”. In: *Journal of Urban Economics* 9.3, S. 311–331.
- Fuess, R. und J. A. Koller (2016). “The Role of Spatial and Temporal Structure for Residential Rent Predictions”. In: *International Journal of Forecasting* 32.4, S. 1352–1368.
- Gabriel, S. A. und F. E. Nothaft (2001). “Rental Housing Markets, the Incidence and Duration of Vacancy, and the Natural Vacancy Rate”. In: *Journal of Urban Economics* 49.1, S. 121–149.
- Galvin, R. (2023). “Do housing rental and sales markets incentivise energy-efficient retrofitting of western Germany’s post-war apartments? Challenges for property owners, tenants, and policymakers”. In: *Energy Efficiency* 16.4, S. 25.
- Gamber, W., J. Graham und A. Yadav (2023). “Stuck at Home: Housing Demand During the COVID-19 Pandemic”. In: *Journal of Housing Economics* 59, S. 101898.
- Geltner, D., N. G. Miller, J. Clayton und P. Eichholtz (2007). *Commercial Real Estate Analysis and Investments*. 2nd. OnCourse Learning.
- Gissler, S., J. Oldfather und D. Ruffino (2016). “Lending on Hold: Regulatory Uncertainty and Bank Lending Standards”. In: *Journal of Monetary Economics* 81, S. 89–101.
- Glaeser, E. L. und E. F. P. Luttmer (2003). “The Misallocation of Housing Under Rent Control”. In: *American Economic Review* 93.4, S. 1027–1046.
- Glaeser, E. L. und J. Gyourko (2008). *Rethinking Federal Housing Policy: How to Make Housing Plentiful and Affordable*. Washington, D.C.: AEI Press.

- Gluszek, M. und S. Belniak (2020). “The COVID-19 Pandemic and Housing Markets in Selected European Countries: Lessons Learnt and Policy Implications”. In: *Zarządzanie Publiczne* 3(53)/2020, S. 48–59.
- Goodman, A. C. (1988). “An econometric model of housing price, permanent income, tenure choice, and housing demand”. In: *Journal of Urban Economics* 23.3, S. 327–353.
- Grösche, P. (2010). “Housing, energy cost, and the poor: Counteracting effects in Germany’s housing allowance program”. In: *Energy Policy* 38.1, S. 93–98.
- Gyourko, J. und R. Molloy (2015). “Regulation and Housing Supply”. In: *Handbook of Regional and Urban Economics* 5, S. 1289–1337.
- Hanushek, E. A. und J. M. Quigley (1980). “What Is the Price Elasticity of Housing Demand?” In: *The Review of Economics and Statistics* 62.3, S. 449–454.
- Hartzmark, S. M. und D. H. Solomon (2016). “The Dividend Month Premium”. In: *Journal of Financial Economics* 119.2, S. 452–475.
- Hastie, T. J. und R. J. Tibshirani (1990). *Generalized Additive Models*. Bd. 43. Monographs on Statistics and Applied Probability. London: Chapman & Hall.
- Hayek, F. A. von (1991). *The fatal conceit: The errors of socialism*. Reprint. Bd. Vol. 1. The collected works of Friedrich August Hayek / ed. by W. W. Bartley. Chicago, Ill.: University of Chicago Press.
- Helbich, M., W. Brunauer, E. Vaz und P. Nijkamp (2014). “Spatial Heterogeneity in Hedonic House Price Models: The Case of Austria”. In: *Urban Studies* 51.2, S. 390–411.
- Hilber, C. A. und W. Vermeulen (2016). “The Impact of Supply Constraints on House Prices in England”. In: *Economic Journal* 126.591, S. 358–405.
- Holm, A. (2011). “Kosten der Unterkunft als Segregationsmotor: Befunde aus Berlin und Oldenburg”. In: *Informationen zur Raumentwicklung* 9, S. 557–566.
- Hwang, M. und J. M. Quigley (2006). “Economic Fundamentals in Local Housing Markets: Evidence from U.S. Metropolitan Regions”. In: *Journal of Regional Science* 46.3, S. 425–453.
- Jacobs, T., M. Klupp und R. Waiblinger (2010). *Kosten der Unterkunft und die Wohnungsmärkte: Auswirkungen der Regelungen zur Übernahme der Kosten der Unterkunft auf Transferleistungsempfänger und Kommunen*. Techn. Ber. Forschungen Heft 142. Bundesinstitut für Bau-, Stadt- und Raumforschung.
- Johansen, S. (1991). “Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models”. In: *Econometrica* 59.6, S. 1551–1580.
- Julio, B. und Y. Yook (2012). “Political Uncertainty and Corporate Investment Cycles”. In: *The Journal of Finance* 67.1, S. 45–83.
- Kaas, L., G. Kocharkov, E. Preugschat und N. Siassi (2021). “Low Homeownership in Germany—a Quantitative Exploration”. In: *Journal of the European Economic Association* 19.1, S. 128–164.

- Kajuth, F., T. A. Knetsch und N. Pinkwart (2016). “Assessing house prices in Germany: evidence from a regional data set”. In: *Journal of European Real Estate Research* 9.3, S. 286–307.
- Kelejian, H. H. und I. R. Prucha (2007). “HAC Estimation in a Spatial Framework”. In: *Journal of Econometrics* 140.1, S. 131–154.
- Kholodilin, K. A. (2024). “Rent control effects through the lens of empirical research: An almost complete review of the literature”. In: *Journal of Housing Economics* 63, S. 101983.
- Kholodilin, K. A., A. Mense und C. Michelsen (2016). *Market Break or Simply Fake? Empirics on the Causal Effects of Rent Controls in Germany*. Discussion Papers 1584. DIW Berlin, German Institute for Economic Research.
- Kim, Y.-Y. (2018). “Does monetary policy affect the long-run expectations of non-stationary real interest rates?” In: *Applied Economics* 50.12, S. 1342–1361.
- Knoll, K., M. Schularick und T. Steger (2017). “No Price Like Home: Global House Prices, 1870–2012”. In: *American Economic Review* 107.2, S. 331–353.
- Kofner, S. (2014). “The German housing system: fundamentally resilient?” In: *Journal of Housing and the Built Environment* 29.2, S. 255–275.
- Kvålseth, T. O. (1985). “Cautionary Note about R²”. In: *The American Statistician* 39.4, S. 279–285.
- Lang, E., F. Mager und K. Hennig (2022). “Uncertainty and commercial real estate excess returns in European markets”. In: *Journal of Property Research* 39.4, S. 321–337.
- Lei, L. und Y. Luo (2023). “Political/Policy Uncertainty, Corporate Disclosure, and Information Asymmetry”. In: *Accounting Perspectives* 22.1, S. 87–110.
- LeSage, J. P. (2014). “What Regional Scientists Need to Know about Spatial Econometrics”. In: *The Review of Regional Studies* 44.1, S. 13–32.
- Ling, D. C. und A. Naranjo (2015). “Returns and Information Transmission Dynamics in Public and Private Real Estate Markets”. In: *Real Estate Economics* 43.1, S. 163–208.
- Ling, D. C., C. Wang und T. Zhou (2018). “Asset Pricing Dynamics in the REIT Market: The Role of Economic Uncertainty”. In: *Journal of Real Estate Finance and Economics* 57.4, S. 562–594.
- Loberto, M., A. Luciani und M. Pangallo (2020). “What Do Online Listings Tell Us About the Housing Market?” In: *International Journal of Central Banking* 16.5, S. 325–377.
- Luo, Y., J. Ma und Z. Xie (2021). “The Effects of Uncertainty on Housing Investment”. In: *Journal of Money, Credit and Banking* 53.4, S. 743–775.
- Mense, A., C. Michelsen und K. A. Kholodilin (2023). “Rent Control, Market Segmentation, and Misallocation: Causal Evidence from a Large-Scale Policy Intervention”. In: *Journal of Urban Economics* 134, S. 103513.
- Mérő, B., A. Borsos, Z. Hosszú, Z. Oláh und N. Vágó (2023). “A high-resolution, data-driven agent-based model of the housing market”. In: *Journal of Economic Dynamics and Control* 155, S. 104738.

- El-Montasser, G., A. N. Ajmi, T. Chang, B. D. Simo-Kengne, C. André und R. Gupta (2016). “Cross-Country Evidence on the Causal Relationship between Policy Uncertainty and Housing Prices”. In: *Journal of Housing Research* 25.2, S. 195–211.
- Moran, P. A. P. (1950). “Notes on Continuous Stochastic Phenomena”. In: *Biometrika* 37.1/2, S. 17–23.
- Ngai, L. R. und K. D. Sheedy (2020). “The Decision to Move House and Aggregate Housing-Market Dynamics”. In: *Journal of the European Economic Association* 18.5, S. 2487–2531.
- Ngai, L. R. und S. Tenreyro (2014). “Hot and Cold Seasons in the Housing Market”. In: *American Economic Review* 104.12, S. 3991–4026.
- Nguyen, V. und C. Vergara-Alert (2023). “Political uncertainty and housing markets”. In: *Journal of Housing Economics* 61, S. 101952.
- Otto, P. und W. Schmid (2018). “Spatiotemporal analysis of German real estate prices”. In: *The Annals of Regional Science* 60.1, S. 41–72.
- Pástor, Ľ. und P. Veronesi (2013). “Political uncertainty and risk premia”. In: *Journal of Financial Economics* 110.3, S. 520–545.
- Poterba, J. M. (1984). “Tax subsidies to owner-occupied housing: an asset-market approach”. In: *The Quarterly Journal of Economics* 99.4, S. 729–752.
- Qian, X., S. Qiu und G. Zhang (2021). “The impact of COVID-19 on housing price: Evidence from China”. In: *Finance Research Letters* 43, S. 101944.
- Rapach, D. E. und C. E. Weber (2004). “Are real interest rates really nonstationary? New evidence from tests with good size and power”. In: *Journal of Macroeconomics* 26.3, S. 409–430.
- Rehdanz, K. (2007). “Determinants of residential space heating expenditures in Germany”. In: *Energy Economics* 29.2, S. 167–182.
- Rieger, J., T. Schmidt und H. Müller (2023). “The Uncertainty Perception Index: Measuring and Tracking Subjective Uncertainty in the German Economy”. In: *Journal of Economic Behavior & Organization* 206, S. 638–657.
- Rosen, S. (1974). “Hedonic Prices and Implicit Markets”. In: *Journal of Political Economy* 82.1, S. 34–55.
- RWI und ImmobilienScout24 (2023). *Regional Real Estate Price Index for Germany - 2008-12/2022*.
- Shleifer, A. und R. Vishny (2011). “Fire Sales in Finance and Macroeconomics”. In: *Journal of Economic Perspectives* 25.1, S. 29–48.
- Sims, D. P. (2007). “Out of Control: What Can We Learn from the End of Massachusetts Rent Control?” In: *Journal of Urban Economics* 61.1, S. 129–151.
- Statistisches Bundesamt (2020). *Mikrozensus - Wohnen in Deutschland: Zusatzprogramm des Mikrozensus 2018*.

- Statistisches Bundesamt (2024a). *Leben in Deutschland: Ergebnisse des Mikrozensus 2023*. Fachserie 1, Reihe 4.1.1. Wiesbaden: Statistisches Bundesamt.
- Statistisches Bundesamt (2024b). *Regionaldatenbank: Baulandpreise (Durchschnittliche Baulandpreise) (61511-01-03-4)*. <https://www.regionalstatistik.de/genesis/online?operation=table&code=61511-01-03-4>.
- Statistisches Bundesamt (2024c). *Regionaldatenbank: Bevölkerungsstatistik (Themenbereich 12)*. <https://www.regionalstatistik.de/genesis/online?operation=themes&code=12>.
- Stawarz, N., N. Sander und H. Sulak (2021). “Internal migration and housing costs—A panel analysis for Germany”. In: *Population, Space and Place* 27.6, e2412.
- Thomschke, L. (2019). “Regional Impact of the German Rent Brake”. In: *German Economic Review* 20.4, e892–e912.
- Titman, S. (1985). “Urban Land Prices Under Uncertainty”. In: *American Economic Review* 75.3, S. 505–514.
- Verband Deutscher Pfandbriefbanken (2023). *Transaktionsdatenbank*.
- Voigtländer, M. (2009). “Why is the German Homeownership Rate so Low?” In: *Housing Studies* 24.3, S. 355–372.
- Waisman, M., P. Ye und Y. Zhu (2015). “The effect of political uncertainty on the cost of corporate debt”. In: *Journal of Financial Stability* 16, S. 106–117.
- Wang, H. und A. L. Boatwright (2019). “Political uncertainty and financial market reactions: A new test”. In: *International Economics* 160, S. 14–30.
- Wheaton, W. C. (1990). “Vacancy, search, and prices in a housing market matching model”. In: *Journal of Political Economy* 98.6, S. 1270–1292.
- White, H. (1980). “A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity”. In: *Econometrica* 48.4, S. 817.
- Wood, S. N. (2006). “Low-Rank Scale-Invariant Tensor Product Smooths for Generalized Additive Mixed Models”. In: *Biometrics* 62.4, S. 1025–1036.
- Wood, S. N. (2011). “Fast Stable Restricted Maximum Likelihood and Marginal Likelihood Estimation of Semiparametric Generalized Linear Models”. In: *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 73.1, S. 3–36.
- Zhang, B. und X. Wan (2024). “Credit Tightening and Housing Prices: Empirical Research on the Channel of the Housing Supply Side”. In: *The Journal of Real Estate Finance and Economics*.
- Zhang, L., T. Leonard und J. Bitzan (2023). “Impacts of the COVID-19 Pandemic on House Prices: Heterogeneous Impacts over Time and across the House Price Distribution”. In: *Journal of Real Estate Research* 45.1, S. 1–22.

Anhang

Anhangsverzeichnis

Anhang zu Kapitel A.1	112
I. Liste betrachteter Städte und deren Mietspiegel	112
II. Validität von Angebotsmietdaten	115
III. Datenbeschreibung Mietspiegelwerte	117
IV. Datenbeschreibung Angebotsmieten	117
V. Verteilung und deskriptive Statistiken der Angebotsmietdaten	119
VI. GAM Modell	120
VII. Harmonisierung von Angebots- und Mietspiegeldaten	120
VIII. Kontrollvariablen des räumlichen Panelmodells (SARAR)	124
IX. Validitätstests für das räumliche Panelmodell (SARAR)	125
X. Modellgüte und Erklärungsgehalt des SARAR-Modells	130
Anhang zu Kapitel A.2	135
I. Probabilistische Zuweisung der Mietstufen	135
II. Verteilung der Mietstufen in Deutschland	135
III. Kennzahlen der Mietstufen-Zuordnung und Monte Carlo Simulation	139
IV. Transferleistungen: KdU-Berechnungslogik und Strukturanalyse	140
V. GAM-Methodik zur Schätzung von Neuvertragsmieten	142
VI. Ökonometrische Details zum Nachfragemodell	148
VII. Ergänzende Analysen zu den Simulationsergebnissen	153
Anhang zu Kapitel B.1	162
I. UPI Dictionary	162
II. Testing for spatial Dependency	163
III. Normality of Residuals	165
IV. Heteroskedasticity Tests	169
V. Autocorrelation Tests	171

Anhang zu Kapitel A.1

I Liste betrachteter Städte und deren Mietspiegel

Die nachfolgende Tabelle zeigt die ursprünglich betrachteten Städte und kennzeichnet mit einem Häkchen die 73, die nach einer Filterung auf eine hinreichende Datenbasis pro Stadt in der finalen Regressionsstichprobe verbleiben. Aufgeführt werden zudem die Stadtkategorien (Top 6: sechs bevölkerungsreichste Städte; Großstadt: ab 100.000 EW exklusive Top 6; Mittelstadt: 50.000–99.999 EW) und die Mietspiegeltypen (q = qualifizierter Mietspiegel; e = einfacher Mietspiegel; – = kein Mietspiegel; ? = Mietspiegel vorhanden, aber Status (e/q) nicht zweifelsfrei; -/? = unklar, ob überhaupt ein Mietspiegel vorlag. Bei „–“ wurden bei dem FUB-Mietspiegelindex ggf. nicht amtliche Mietpreisübersichten verwendet.).

Tabelle An.1: Übersicht der Städte, Stadtkategorien und Mietspiegel

Stadt	Kategorie	Sample (N=73)	2014	2015	2016	2017	2018	2019	2020	2021	2022
Aachen	Großstadt	✓	e	e	e	e	e	e	q	q	q
Arnsberg	Mittelstadt		-/?	-/?	-/?	-/?	-/?	-/?	-/?	-/?	-/?
Augsburg	Großstadt	✓	-	-	-	q	q	q	q	q	q
Bad Kreuznach	Mittelstadt		e	e	e	e	e	e	e	e	e
Bad Oeynhausen	Mittelstadt		e	e	e	e	e	e	e	e	e
Bad Salzuflen	Mittelstadt		e	e	e	e	e	e	q	q	q
Baden-Baden	Mittelstadt	✓	q	q	q	q	q	q	q	q	q
Bamberg	Großstadt	✓	q	q	q	q	q	q	q	q	q
Bergisch Gladbach	Großstadt	✓	e	e	e	e	e	e	e	e	e
Berlin	Top 6	✓	q	q	q	q	q	q	q	q	q
Bielefeld	Großstadt	✓	q	q	q	q	q	q	q	q	q
Bochum	Großstadt	✓	q	q	q	q	q	q	q	q	q
Bonn	Großstadt	✓	e	e	q	q	q	q	q	q	q
Bottrop	Großstadt	✓	e	e	e	e	e	e	e	e	e
Braunschweig	Großstadt	✓	q	q	q	q	q	q	q	q	q
Bremerhaven	Großstadt		e	e	e	e	e	e	e	e	e
Chemnitz	Großstadt	✓	q	q	q	q	q	q	q	q	q

Fortsetzung auf der nächsten Seite

Tabelle An.1 – Fortsetzung

Stadt	Kategorie	Sample (N=73)	2014	2015	2016	2017	2018	2019	2020	2021	2022
Cuxhaven	Mittelstadt		-/?	-/?	e	e	e	e	e	e	e
Darmstadt	Großstadt	✓	q	q	q	q	q	q	q	q	q
Detmold	Mittelstadt		q	q	q	q	q	q	q	q	q
Dinslaken	Mittelstadt		e	e	e	e	e	e	e	e	e
Dresden	Großstadt	✓	q	q	q	q	q	q	q	q	q
Duisburg	Großstadt	✓	e	e	e	e	e	e	e	e	e
Erfurt	Großstadt	✓	e	e	e	e	e	e	e	e	e
Erlangen	Großstadt	✓	q	q	q	q	q	q	q	q	q
Eschweiler	Mittelstadt		e	e	e	e	e	e	e	e	e
Essen	Großstadt	✓	-/?	-/?	q	q	q	q	q	q	q
Esslingen am Neckar	Großstadt	✓	q	q	q	q	q	q	q	q	q
Euskirchen	Mittelstadt		e	e	e	e	e	e	e	e	e
Frankfurt (Oder)	Mittelstadt		?	?	?	?	q	q	q	q	q
Frankfurt am Main	Top 6	✓	q	q	q	q	q	q	q	q	q
Freiburg im Breisgau	Großstadt	✓	?	q	q	q	q	q	q	q	q
Fürth	Großstadt	✓	e	e	q	q	q	q	q	q	q
Gelsenkirchen	Großstadt	✓	e	e	e	e	e	e	e	e	e
Gera	Großstadt		q	q	q	q	q	q	q	e	e
Gevelsberg	Mittelstadt		e	e	e	e	e	e	e	e	e
Greifswald	Mittelstadt		e	e	e	e	e	e	e	e	e
Grevenbroich	Mittelstadt		e	e	e	e	e	e	e	e	e
Göppingen	Mittelstadt		q	q	q	q	q	e	e	e	e
Haan	Mittelstadt		e	e	e	e	e	e	e	e	e
Hagen	Großstadt	✓	q	q	q	q	q	q	q	q	q
Hamburg	Top 6	✓	q	q	q	q	q	q	q	q	q
Hamm	Großstadt		e	e	e	e	e	e	e	e	e
Hanau	Großstadt	✓	e	e	e	e	e	e	e	e	e
Hannover	Großstadt	✓	q	q	q	q	q	q	q	q	q
Hattingen	Mittelstadt		e	e	e	e	e	e	e	e	e
Heidelberg	Großstadt	✓	q	q	q	q	q	q	q	q	q
Heilbronn	Großstadt	✓	q	q	q	q	q	q	q	q	q
Herne	Großstadt	✓	e	e	e	e	e	e	e	e	e

Fortsetzung auf der nächsten Seite

Tabelle An.1 – Fortsetzung

Stadt	Kategorie	Sample (N=73)	2014	2015	2016	2017	2018	2019	2020	2021	2022
Herzogenrath	Mittelstadt		e	e	e	e	e	e	e	e	e
Hilden	Mittelstadt		e	e	e	e	e	e	e	e	e
Iserlohn	Mittelstadt	✓	e	e	e	e	e	e	e	e	e
Jena	Großstadt	✓	q	q	q	q	q	q	q	q	q
Karlsruhe	Großstadt	✓	q	q	q	q	q	q	q	q	q
Kempen	Mittelstadt		e	e	e	e	e	e	e	e	e
Kiel	Großstadt	✓	q	q	q	q	q	q	q	q	q
Kleve	Mittelstadt		e	e	e	e	e	e	e	e	e
Koblenz	Großstadt	✓	q	q	q	q	q	q	q	q	q
Konstanz	Großstadt	✓	-/?	q	q	q	q	q	q	q	q
Krefeld	Großstadt	✓	e	e	e	e	e	e	e	e	e
Köln	Top 6	✓	e	e	e	e	e	e	e	e	e
Landau in der Pfalz	Mittelstadt		-/?	-/?	-/?	q	q	q	q	q	q
Landshut	Mittelstadt		?	?	?	?	?	?	?	?	?
Leipzig	Großstadt	✓	e	e	q	q	q	q	q	q	q
Lemgo	Mittelstadt		e	e	e	e	e	e	e	e	e
Leverkusen	Großstadt	✓	e	e	e	q	q	q	q	q	q
Lippstadt	Mittelstadt		e	e	e	e	e	e	e	e	e
Ludwigsburg	Großstadt	✓	q	q	q	q	q	q	q	q	q
Ludwigshafen am Rhein	Großstadt	✓	-/?	q	q	q	q	q	q	q	q
Lübeck	Großstadt	✓	q	q	q	q	q	q	q	q	q
Lüdenscheid	Mittelstadt		e	e	e	e	e	e	e	e	e
Lünen	Mittelstadt		e	e	e	e	e	e	e	e	e
Mannheim	Großstadt	✓	q	q	q	q	q	q	q	q	q
Marl	Mittelstadt		e	e	e	e	e	e	e	e	e
Minden	Mittelstadt		-/?	-/?	q	q	q	q	q	q	q
Moers	Mittelstadt		e	e	e	e	e	e	e	e	e
Mülheim an der Ruhr	Großstadt	✓	e	e	q	q	q	q	q	q	q
München	Top 6	✓	q	q	q	q	q	q	q	q	q
Münster	Großstadt	✓	q	q	q	q	q	q	q	q	q
Naumburg (Saale)	Mittelstadt		-/?	-/?	e	e	-/?	e	-	-	

Fortsetzung auf der nächsten Seite

Tabelle An.1 – Fortsetzung

Stadt	Kategorie	Sample (N=73)	2014	2015	2016	2017	2018	2019	2020	2021	2022
Neumünster	Mittelstadt		e	e	e	e	e	e	e	e	e
Neuss	Großstadt	✓	e	e	e	e	e	e	e	e	e
Nürnberg	Großstadt	✓	e	e	q	q	q	q	q	q	q
Oberhausen	Großstadt	✓	e	e	e	e	e	e	e	e	e
Offenbach am Main	Großstadt	✓	e	e	e	e	e	e	e	e	e
Osnabrück	Großstadt	✓	e	e	e	e	e	e	e	e	e
Paderborn	Großstadt		-/?	-/?	-/?	-/?	-/?	-/?	-/?	q	q
Pforzheim	Großstadt	✓	q	q	q	q	q	q	q	q	q
Potsdam	Großstadt		q	q	q	q	q	q	q	q	q
Recklinghausen	Großstadt		e	e	e	e	e	e	e	e	e
Regensburg	Großstadt	✓	q	q	q	q	q	q	q	q	q
Remscheid	Großstadt		-	-	q	q	q	q	q	q	q
Rheine	Mittelstadt		e	e	e	e	e	e	e	e	e
Schweinfurt	Mittelstadt		e	e	e	e	e	e	e	e	e
Schwerte	Mittelstadt		e	e	e	e	e	e	e	e	e
Schwäbisch Gmünd	Mittelstadt		q	q	q	q	q	q	q	q	q
Solingen	Großstadt	✓	e	e	e	e	e	e	e	e	?
Speyer	Mittelstadt		-/?	-/?	-/?	-/?	-/?	-/?	q	q	q
Stolberg (Rhld.)	Mittelstadt		e	e	e	e	e	e	e	e	e
Stuttgart	Top 6	✓	q	q	q	q	q	q	q	q	q
Trier	Großstadt	✓	-/?	-/?	q	q	q	q	q	q	q
Tübingen	Großstadt	✓	?	q	q	q	q	q	q	q	q
Ulm	Großstadt	✓	e	q	q	q	q	q	q	q	q
Unna	Mittelstadt		e	e	e	e	e	e	e	e	e
Velbert	Mittelstadt		e	e	e	e	e	e	e	e	e
Viersen	Mittelstadt		e	e	e	e	e	e	e	e	e
Villingen-Schwenningen	Großstadt	✓	q	q	q	q	q	q	q	q	q

II Validität von Angebotsmietdaten

Die vorliegende Analyse basiert auf Angebotsmietdaten, deren Verwendung als Proxy für tatsächlich vereinbarte Neuvertragsmieten einer kritischen Würdigung bedarf. Die internationale empirische Evidenz zeigt konsistent, dass Angebotsmieten systematisch von realisierten

Transaktionsmieten abweichen können, wobei das Ausmaß dieser Divergenz marktspezifisch variiert.

Boeing et al. (2020) dokumentieren für angespannte US-amerikanische Wohnungsmärkte eine signifikante Divergenz zwischen Listing- und allgemeinen Marktmieten, wobei die Angebotsmieten insbesondere in Hochpreissegmenten um bis zu 8% über den vergleichbaren Marktdurchschnitten liegen. Diese Befunde werden durch Loberto et al. (2020) für den italienischen Markt bestätigt, die zeigen, dass Online-Angebotspreise zwar als valide Frühindikatoren für Marktentwicklungen und Wohnungspreise fungieren, jedoch strukturell um durchschnittlich rund 12% über den Transaktionspreisen liegen.

Die zeitliche Dimension dieser Divergenz analysieren Allen et al. (2009) anhand des Dallas-Fort Worth Marktes. Sie weisen nach, dass überhöhte Angebotsmieten zu verlängerten Vermarktungszeiten führen und letztlich in Transaktionsmieten resultieren, die sogar unter dem ursprünglich angemessenen Marktniveau liegen können. Dieser “overpricing penalty” beträgt im Durchschnitt 2-3% für jede 10% initiale Überpreisung.

Für den deutschen Markt zeigen Kholodilin et al. (2016), dass Angebotsmietdaten verlässliche Preistrends liefern und für die Analyse von Mietentwicklungen gut geeignet sind. In angespannten Wohnungsmärkten ist zudem davon auszugehen, dass der Abstand zwischen Angebots- und Vertragsmieten gering ist, da der Verhandlungsspielraum der Mieter bei hoher Nachfrage typischerweise stark eingeschränkt ist. Diese Einschätzung lässt sich ökonomisch durch Befunde aus den Eigentumsmärkten stützen: Anenberg und Bayer (2013) zeigen, dass in angespannten Märkten Preisabschläge auf Angebotspreise systematisch schrumpfen, weil Anbieter ihre Verhandlungsmacht aus steigender Nachfrage ziehen. Ein analoger Mechanismus ist auf Mietmärkten plausibel, da Wohnungssuchende in nachfrageüberlasteten Segmenten nur geringe Möglichkeiten zur Preisverhandlung haben. Gleichwohl ist zu erwarten, dass Angebotsmieten die realisierten Neuvertragsmieten tendenziell leicht überschätzen.

Trotz dieser dokumentierten Limitationen sind Angebotsmietdaten für die vorliegende Analyse aus mehreren Gründen geeignet: Erstens untersuchen wir primär relative Veränderungen und Differenzen zwischen Städten, wodurch systematische Niveau-Unterschiede zwischen Angebots- und tatsächlichen Neuvertragsmieten weniger gravierend sind, solange diese über Städte hinweg konsistent auftreten. Zweitens verwenden wir robuste Schätzmethoden (GAM-Funktionen oder Medianbildung, Ausreißerbereinigung), die extreme Angebotspreise reduzieren und damit die systematische Verzerrung minimieren. Drittens kontrollieren wir für Unterschiede nach Vermietertyp. Da die öffentlich zugänglichen Portale hauptsächlich Anzeigen gewinnorientierter Vermieter zeigen, berücksichtigen wir in unserer Analyse explizit die Anteile nicht rein gewinnorientierter Vermieter im Wohnungsbestand.

III Datenbeschreibung Mietspiegelwerte

Mit dem FUB-Mietspiegelindex führt die FUB IGES Wohnen+Immobilien+Umwelt GmbH regelmäßig eine Auswertung amtlicher Daten über das Mietenniveau und die Mietentrends in den Städten und Gemeinden in Deutschland durch.

Die FUB-Mietspiegeldatenbank wurde in langjähriger Forschungsarbeit aufgebaut und wird kontinuierlich aktualisiert. Sie ist die Grundlage für eine vergleichende Auswertung aller in Deutschland erstellten Mietspiegel. Die Datenbank dokumentiert damit auch die Verbreitung von Mietspiegeln in Deutschlands Städten und Gemeinden. Der FUB-Mietspiegelindex ist ein deutschlandweit vorliegendes, flächendeckendes Informationssystem über das Niveau und die Entwicklung der ortsüblichen Vergleichsmieten. Die Erhebung erfasst alle zum Jahresende des Vorjahres gültigen Mietspiegel (31.12.).

Der Mietspiegelindex ermöglicht, differenziert nach Wohnungsteilmarktgruppen, eine Einschätzung des regionalen Mietenniveaus für Städte, die über einen Mietspiegel verfügen. Die Mietspiegeldaten basieren dabei immer auf derselben Musterwohnung: 65 m² groß, 3 Zimmer, Standard-Grundausrüstung (WC, Bad/Dusche, Sammelheizung), mittlerer energetischer Gebäudezustand und mittlere Wohnlage. Für diese Musterwohnung wird die durchschnittliche ortsübliche Nettokaltmiete pro m² für 9 verschiedene Baujahre erhoben: 1905, 1925, 1955, 1965, 1975, 1985, 1995, 2005 und 2015.

IV Datenbeschreibung Angebotsmieten

Die FUB IGES Wohnen+Immobilien+Umwelt GmbH wertet seit Jahren regelmäßig und deutschlandweit Neuvermietungs- und Kaufangebote für Wohn- und Gewerbeimmobilien aus, die regional und überregional inseriert, also öffentlich angeboten werden. Die Aufbereitung der Angebotsdaten erfolgt nach einem standardisierten wissenschaftlichen Verfahren. Die Angebotsdaten werden mit einer Dublettenidentifizierung auf Objektebene verdichtet, um eine verzerrende Vervielfachung identischer Objekte, die mehrfach inseriert werden, zu vermeiden. Die Daten werden um nicht plausible Angaben und Scheinangebote bereinigt sowie einer Extremwertprüfung unterzogen. FUB IGES prüft die Angaben zur Objektlage und nimmt eine Geocodierung der adressbezogenen Informationen vor.

Für die vorliegende Untersuchung wurde eine Vorauswahl getroffen: Bereitgestellt wurden ca. 11 Millionen Objekte zur Anmietung, darunter Wohnungen in Mehrfamilienhäusern (10.503.775), freistehende Ein- und Zweifamilienhäuser (427.247) und Zimmer in Einzervermietung (33.288), die im Zeitraum 2014 bis 2022 letztmalig inseriert wurden. Zur Verortung der Objekte weisen die vorgefilterten Datenbankeinträge einen Amtlichen Gemeindeschlüssel

(AGS) auf (Gebietsstand 2022).


Die Datenbank wurde zum Zeitpunkt der Datenbereitstellung aus ca. 700 Quellen generiert, ursprünglich entfallen 43,4% der bereitgestellten Angaben auf das Portal Immobilien-Scout24, 22,0% stammen aus der Plattform ebay-Kleinanzeigen, 13,4% aus dem Portal Immonet, 11,6% aus dem Portal Immo-Welt und 1,2% aus dem Portal Kalaydo. In 8,4% der Fälle wurde jeweils eine andere Quelle (einschließlich Print-Inserate) benannt.

Tabelle An.2: Variablenliste Angebotsmietdaten

Variable	Y/N	Typ	Beschreibung
ID	N	NUMBER(10,0)	Eindeutige ID
ADV_DATE	N	DATE	Anzeigendatum
ADV_FIRST	N	DATE	Datum der ersten Anzeige
ADV_COUNT	N	NUMBER(4,0)	Anzahl der Anzeigen
SOURCE_ID	N	NUMBER(10,0)	Quellen-ID
RSTTYPE	N	NUMBER(2,0)	Immobilientyp
SUBTYPE	Y	NUMBER(2,0)	Subtyp
REGION	N	VARCHAR2(16)	Region (AGS)
STREET	Y	NVARCHAR2(80)	Straße
HOUSENO	Y	NVARCHAR2(20)	Hausnummer
ZIP	Y	VARCHAR2(6)	Postleitzahl
COUNTRY	Y	CHAR(2)	Land
AGENT_ID	Y	NUMBER(10,0)	Anbieter-ID
PRICE	Y	NUMBER(10,0)	Kauf-/Mietpreis
PRICE_MIN	Y	NUMBER(10,0)	Kleinster Preis
PRICE_MAX	Y	NUMBER(10,0)	Höchster Preis
EXTRA_COST	Y	NUMBER(10,0)	Nebenkosten
CURRENCY	N	CHAR(3)	Währung
NEWBUILDING	N	NUMBER(1,0)	Neubau (0=Nein, 1=Ja)
BUILD_YEAR	Y	NUMBER(4,0)	Baujahr
RENOV_YEAR	Y	NUMBER(4,0)	Renovierungsjahr
ROOM_CNT	Y	NUMBER(2,0)	Anzahl der Zimmer
FL_SPC	Y	NUMBER(6,0)	Wohnfläche in m ²
TOT_SPC	Y	NUMBER(6,0)	Gesamtfläche in m ²
TO_RENT	N	NUMBER(1,0)	0 = Kauf, 1 = Miete, etc.
ENERGY	Y	NUMBER(5,0)	Energiebedarf
LATITUDE	Y	NUMBER(9,6)	Breitengrad
LONGITUDE	Y	NUMBER(9,6)	Längengrad


V Verteilung und deskriptive Statistiken der Angebotsmietdaten

Abbildung An.1: Verteilung der Angebotsmietdaten der Stadtkategorien im Zeitverlauf



Eigene Berechnung und Darstellung.

Abbildung An.2: Angebotsmietdaten Städte innerhalb der Stadtkategorien im Zeitverlauf




Eigene Berechnung und Darstellung.

Tabelle An.3: Bevölkerungsgewichtete Angebotsmietentwicklung 2014-2022; Datengrundlage: Regressionsanalyse mit 73 Städten

Jahr	Ø Miete (€/qm)	Min (€/qm)	Max (€/qm)	SD	CV	Wachstum (%)
2014	7.97	4.72	13.91	1.70	0.250	–
2015	8.27	4.72	14.55	1.82	0.260	3.7
2016	8.71	4.76	15.74	1.98	0.270	5.3
2017	9.10	4.89	16.88	2.12	0.280	4.5
2018	9.59	5.05	17.55	2.26	0.280	5.3
2019	9.92	5.09	18.14	2.35	0.280	3.5
2020	10.20	5.19	18.69	2.45	0.290	2.9
2021	10.48	5.31	18.63	2.46	0.280	2.8
2022	11.15	5.41	19.16	2.49	0.270	6.4

VI GAM Modell

Abbildung An.3: GAM-Funktionen am Beispiel Berlin



Eigene Berechnung und Darstellung.

VII Harmonisierung von Angebots- und Mietspiegeldaten (Sicherstellung der Vergleichbarkeit)

i Ausgangslage und Herausforderung

Die Mietspiegeldaten basieren auf einer standardisierten Musterwohnung mit folgenden Eigenschaften:

- Wohnfläche: 65 m²

- Zimmeranzahl: 3
- Ausstattung: Standard (WC, Bad/Dusche, Sammelheizung)
- Energetischer Zustand: mittel
- Wohnlage: mittel

Die Angebotsdaten hingegen umfassen heterogene Wohnungsinserate mit variierenden Eigenschaften bezüglich Größe, Ausstattung, Lage und Baujahr.

ii Harmonisierungsmaßnahmen

Stufe 1: Datenfilterung und -selektion

Tabelle An.4: Filterkriterien für die Datenauswahl

Filterkriterium	Ausschluss	Zweck
Wohnfläche	$<45 \text{ m}^2$ oder $>85 \text{ m}^2$	Reduzierung der Größenheterogenität um 65 m^2 Musterwohnung ($\pm 30\%$)
Mietpreis	$<2 \text{ €/m}^2$ oder $>40 \text{ €/m}^2$	Elimination unplausibler Extremwerte
Baujahr	vor 1880 oder nach 2022	Fokus auf vergleichbaren Gebäudebestand
Wohnungstyp	Betreutes/gefördertes Wohnen, Erbpacht	Ausschluss von Sonderwohnformen

Stufe 2: Statistische Adjustierung (GAM-Modell)

Für jede Stadt wird ein separates GAM-Modell geschätzt:

- **Kontrollvariable 1:** Wohnfläche (nichtlineare Glättungsfunktion f_1)
- **Kontrollvariable 2:** Baujahr (nichtlineare Glättungsfunktion f_2)
- **Zeiteffekte:** Jahres-Dummies zur Erfassung der Mietentwicklung
- **Ergebnis:** Geschätzte Miete für exakt 65 m^2 bei gegebenem Baujahr

Stufe 3: Baujahresstandardisierung

Beide Datensätze werden identisch nach der tatsächlichen Baujahresverteilung gewichtet:

- **Datenbasis:** Zensus 2011 und 2022 (GWZ)

- **Methode:** Lineare Interpolation zwischen Zensusjahren
- **Effekt:** Elimination von Kompositionsunterschieden zwischen den Datensätzen

Stufe 4: Relative Betrachtung

Verwendung relativer statt absoluter Differenzen:

- **Formel:** (Angebotsmiete - Mietspiegelmiete) / Mietspiegelmiete
- **Effekt:** Kontrolle zeitkonstanter unbeobachtbarer Heterogenität

iii Wirkungsweise der Harmonisierung

Tabelle An.5: Harmonisierungsmaßnahmen und verbleibende Unsicherheiten

Potenzielle quelle	Verzerrungs-	Harmonisierungsmaßnahme	Verbleibende heit	Unsicher-
Unterschiedliche größen	Wohnungs-	Filterung 45–85 m ² + GAM- Kontrolle	Qualitätsunterschiede inner- halb der Größenklasse	
Verschiedene Baujahre		GAM-Kontrolle + Zensusge- wichtung	–	
Heterogene Ausstattung		Filterung Sonderwohnformen	Variation in Standardaus- stattung	
Unterschiedliche Lagen		–	Mikrolage nicht kontrolliert	
Modernisierungszustand		–	Nicht beobachtbar	

Validitätsbewertung

Die Kombination der vier Harmonisierungsstufen gewährleistet:

1. **Strukturelle Vergleichbarkeit:** Beide Datensätze repräsentieren ähnliche Wohnungstypen (45–85 m², keine Sonderwohnformen). Zudem basieren die Analysen gleichermaßen auf Nettokaltmieten pro m² dieser ähnlichen Wohnungstypen.
2. **Statistische Bereinigung:** Hauptpreistreiber (Fläche, Baujahr) sind kontrolliert
3. **Kompositionsgleichheit:** Identische Baujahresverteilung eliminiert Struktureffekte
4. **Methodische Konsistenz:** Eventuelle Restverzerrungen betreffen beide Datensätze gleichermaßen

iv Verbleibende Limitationen

Trotz umfangreicher Harmonisierung verbleiben Limitationen, die mit konventionellen Daten in einem Panel von 107 Städten über 9 Jahre nicht kontrollierbar sind:

- **Modernisierungszustand:** Informationen über durchgeführte Modernisierungen (§ 555b BGB) sind in Angebotsdaten nicht systematisch erfasst
- **Exakte Mikrolage:** Innerhalb der mittleren Wohnlage existieren erhebliche Qualitätsunterschiede, die ohne Georeferenzierung nicht kontrollierbar sind
- **Vormiete:** Ausnahmetatbestand der Mietpreisbremse (§ 556e BGB) kann ohne Zugang zu Vormietverträgen nicht berücksichtigt werden
- **Ausstattungsqualität:** Variation innerhalb der Standardausstattung (z.B. Einbauküche, Balkon) ist in aggregierten Daten nicht vollständig erfassbar

Diese Limitationen sind inhärent in der Verwendung der verfügbarer Angebotsdaten und würden nur durch Zugang zu vollständigen Transaktionsdaten mit detaillierten Objektmerkmalen überwunden werden können – Daten, die für ein Panel dieser Größenordnung nicht verfügbar sind. Die berechneten relativen Differenzen sind daher als Schätzung zu interpretieren, wobei sehr hohe Differenzen ($>20\%$) trotz dieser Limitationen auf strukturelle Marktungleichgewichte hindeuten.

VIII Kontrollvariablen des räumlichen Panelmodells (SARAR)

Tabelle An.6: Übersicht der Kontrollvariablen, ihrer Repräsentation und Datenquellen

Variable	Indikator / Repräsentation	Datenquelle
Arbeitslosigkeit	Arbeitslosenquote	Agentur für Arbeit
Regionale, wirtschaftliche Stärke	Bruttolohn je Erwerbstätigem	Statistisches Bundesamt
Bevölkerungsdichte	Dichte pro m ²	Statistisches Bundesamt
Bevölkerungswachstum	Wachstumsrate Bevölkerung	Statistisches Bundesamt
Altersstruktur	Durchschnittsalter	Statistisches Bundesamt
Wohnraumangebot	Baufertigstellungen an der Gesamtwohnfläche	Statistisches Bundesamt
Vermieterstruktur	Anteil nicht rein gewinnorientierter Vermieter im Wohnungsbestand	Zensus 2011 und 2022
Mietpreisbremse	Dummy für Vorliegen =1	Eigene Erhebung (amtliche Dokumente)
Mietspiegel Qualität	Dummy für qualifizierte Mietspiegel =1	Eigene Erhebung (amtliche Dokumente)
Zinsen	Euribor, Bauzinsen, 10y Bundesanleihe, Spreads	Deutsche Bundesbank

IX Validitätstests für die räumliche Panelregression (SARAR)

i Deskriptive Statistik der Modellvariablen

Die folgende Tabelle zeigt die deskriptiven Statistiken aller im SARAR-Modell verwendeten Variablen. Die substantielle Variation sowohl in der Querschnitts- als auch in der Zeitdimension ermöglicht eine robuste Identifikation der Modellparameter.

Tabelle An.7: Deskriptive Statistik der SARAR-Modellvariablen

Variable	N	Mittelw.	Std.Abw.	Min	Median	Max
Relative Mietpreisdifferenz	657	0.183	0.150	-0.163	0.175	0.930
Mietpreisbremse	657	0.327	0.470	0.000	0.000	1.000
Einwohner pro km ²	657	1661.714	828.325	379.000	1496.000	4868.000
Baufertigstellungen/Fläche	657	0.005	0.003	0.000	0.005	0.018
Bruttolohn (€)	657	36538.298	5244.113	24127.000	35737.000	55171.000
Durchschnittsalter	657	43.642	1.805	40.200	43.500	49.200
Arbeitslosenquote (%)	657	0.041	0.012	0.018	0.040	0.077
Nicht-gewinnorientiert (%)	657	0.126	0.085	0.005	0.115	0.360

Anmerkungen: Die Mietpreisbremse ist eine binäre Variable (0/1), die anzeigt, ob eine Stadt der Regulierung unterliegt. Die relative Mietpreisdifferenz misst die prozentuale Abweichung zwischen Angebots- und Mietspiegelmieten.

Die abhängige Variable zeigt mit einem Mittelwert von 18,3% eine substantielle positive Differenz zwischen Angebots- und Mietspiegelmieten, bei einer Standardabweichung von 15 Prozentpunkten.

ii Hauptvaliditätstests

Die Tabelle [An.8](#) fasst alle wesentlichen Validitätstests zusammen, die für die Beurteilung der statistischen Inferenz des SARAR-Modells relevant sind.

Tabelle An.8: Umfassende Validitätstests für das SARAR-Modell

Testgruppe	Test	Statistik	p-Wert	Interpretation
<i>Modellspezifikation</i>				
	Hausman (FE vs RE)	9,86	0,1967	FE und RE beide akzeptabel
<i>Heteroskedastizität</i>				
	Breusch-Pagan	60,75	< 0,0001	Heteroskedastizität***
<i>Normalität der Residuen</i>				
	Jarque-Bera	296,16	< 0,0001	Nicht-normal***
	Shapiro-Wilk	0,962	< 0,0001	Nicht-normal***
<i>Räumliche Abhängigkeit</i>				
	Moran's I (Residuen)	-0,504	0,6927	Keine räumliche Autokorrelation
<i>Querschnittsabhängigkeit</i>				
	Pesaran CD	-1,491	0,1360	Nicht vorhanden
<i>Multikollinearität</i>				
	Max. VIF	2,194	–	Unproblematisch

Anmerkungen: *** indiziert statistische Signifikanz auf dem 1%-Niveau.

Basierend auf n = 657 Beobachtungen (73 Städte, 2014–2022).

VIF = Variance Inflation Factor; Werte < 5 gelten als unproblematisch.

iii Zusätzliche Spezifikationstests

Um die zeitliche Struktur der Daten umfassend zu evaluieren, wurden zusätzliche Tests auf Stationarität und serielle Korrelation durchgeführt.

Tabelle An.9: Zusätzliche Validitätstests: Stationarität und Serielle Korrelation

Testgruppe	Test	Statistik	P-Wert	Ergebnis
Stationarität	Levin-Lin-Chu (Dep. Var.)	-5.874	0.0000	Stationär***
Stationarität	Levin-Lin-Chu (Einwohner/km ²)	-6.912	0.0000	Stationär***
Stationarität	Levin-Lin-Chu (Bruttolohn)	5.751	1.0000	Nicht-stationär
Serielle Korr.	Wooldridge Test	168.881	0.0000	Serielle Korr.***

Anmerkungen: *** indiziert statistische Signifikanz auf dem 1%-Niveau.

H für Unit-Root-Tests: Serie hat eine Einheitswurzel (nicht-stationär).

H für Wooldridge-Test: Keine serielle Korrelation erster Ordnung.

Der hochsignifikante Wooldridge-Test ($F = 168.88$, $p < 0.001$) weist auf das Vorliegen serieller Korrelation hin, was die Verwendung geclusterter Standardfehler auf Stadtebene rechtfertigt.

iv Multikollinearitätsdiagnostik

Die Variance Inflation Factors (VIF) zeigen, dass keine problematische Multikollinearität zwischen den Regressoren vorliegt.

Tabelle An.10: Variance Inflation Factors (VIF) - Multikollinearitätstest

Variable	VIF-Wert	Bewertung
Mietpreisbremse	1,742	Unproblematisch
Einwohner pro km ²	1,963	Unproblematisch
Baufertigstellungen/Fläche	1,696	Unproblematisch
Bruttolohn	2,194	Unproblematisch
Durchschnittsalter	1,925	Unproblematisch
Arbeitslosenquote	1,833	Unproblematisch
Nicht-gewinnorientiert	1,299	Unproblematisch

Faustregel: VIF < 5: unproblematisch; VIF 5-10: grenzwertig; VIF > 10: problematisch

Alle VIF-Werte liegen deutlich unter dem kritischen Schwellenwert von 5, was darauf hindeutet, dass Multikollinearität keine problematische Verzerrung der Standardfehler verursacht.

v Charakteristika der Modellresiduen

Die detaillierte Analyse der Residuen offenbart Abweichungen von der Normalverteilung, insbesondere in Form erhöhter Kurtosis.

Tabelle An.11: Charakteristika der Modellresiduen

Statistik	Wert
Mittelwert	0,0000
Standardabweichung	0,0451
Minimum	-0,2240
1. Quartil	-0,0262
Median	-0,0043
3. Quartil	0,0272
Maximum	0,2226
Schiefe	0,178
Kurtosis	6,270

Anmerkung: Schiefe = 0 und Kurtosis = 3 entsprechen einer Normalverteilung.

Die erhöhte Kurtosis (6,27 > 3) indiziert schwere Verteilungsenden (heavy tails).

vi Validität der Modellspezifikation

Trotz der identifizierten Verletzungen klassischer Regressionsannahmen gewährleistet das implementierte SARAR-Modell aus folgenden Gründen valide statistische Inferenz:


Behandlung der Heteroskedastizität

Der hochsignifikante Breusch-Pagan-Test ($BP = 60.75, p < 0.001$) weist eindeutig auf das Vorliegen von Heteroskedastizität hin. Dies wurde durch die Implementierung heteroskedastizitäts-robuster Standardfehler nach dem Sandwich-Verfahren adressiert:

$$\text{Cov}_{\text{robust}}(\hat{\beta}) = (X'X)^{-1}X'\Omega X(X'X)^{-1}$$

wobei $\Omega = \text{diag}(\hat{e}_i^2)$ die geschätzten quadrierten Residuen enthält. Diese Methodik liefert konsistente Standardfehler auch bei unbekannter Form der Heteroskedastizität.

Abbildung An.4: Residuen vs. Angepasste Werte und Skalierungs-Lokations-Diagramm




Eigene Berechnung und Darstellung.

Umgang mit Nicht-Normalität

Die deutliche Ablehnung der Normalitätshypothese (Jarque-Bera: $\chi^2 = 296.16, p < 0.001$; Shapiro-Wilk: $W = 0.962, p < 0.001$) ist bei der vorliegenden Stichprobengröße ($n = 657$) unkritisch:

- Der zentrale Grenzwertsatz garantiert die asymptotische Normalität der Schätzer: $\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} \mathcal{N}(0, \Sigma)$.
- Die robusten Standardfehler sind auch bei Nicht-Normalität valide.
- Die Konsistenz der Maximum-Likelihood-Schätzer hängt nicht von der Normalitätsannahme ab.

Abbildung An.5: Q-Q-Diagramm (links) und Histogramm der Residuen (rechts)



Eigene Berechnung und Darstellung.

Kontrolle räumlicher Abhängigkeiten

Die SARAR-Spezifikation berücksichtigt räumliche Effekte über zwei Parameter. Der räumliche Lag-Parameter ($\lambda = 0,477$, $p = 0,102$) ist zunächst leicht signifikant und bei Anwendung robuster Standardfehler hochsignifikant, was auf Spillover-Effekte bei der abhängigen Variable hindeutet. Der räumliche Fehlerparameter ($\rho = 0,163$, $p = 0,665$) ist hingegen statistisch insignifikant. Der nach der Schätzung durchgeführte Moran's I-Test der Residuen ($I = -0,504$, $p = 0,693$, vgl. Tabelle An.8) bestätigt, dass das Modell die räumliche Autokorrelation erfolgreich erfasst hat und keine signifikante verbleibende räumliche Struktur in den Residuen vorhanden ist.

Behandlung serieller Korrelation

Der Wooldridge-Test zeigt signifikante serielle Korrelation ($F = 168.88$, $p < 0.001$). Dies wurde durch Clusterung der Standardfehler auf Stadtebene adressiert, wodurch sowohl Heteroskedastizität als auch serielle Korrelation innerhalb der Städte über die Zeit berücksichtigt werden. Diese Kombination robuster Methoden wurde von Cameron und Miller (2015) als besonders effektiv für Paneelanwendungen identifiziert.

Kontrolle unbeobachteter Heterogenität

Die Two-way Fixed Effects ("Entity" und "Time") kontrollieren sowohl für:

- Zeitinvariante stadtspezifische Charakteristika (zum Beispiel geografische Lage, historische Entwicklung).

- Gemeinsame Zeittrends (zum Beispiel makroökonomische Schocks, bundesweite Politikänderungen).

Dies reduziert das Risiko von Verzerrungen durch ausgelassene Variablen erheblich und stärkt die kausale Interpretierbarkeit der Koeffizienten.

X Modellgüte und Erklärungsgehalt des SARAR-Modells

i Methodische Grundlagen der Gütebewertung

Die Bewertung räumlicher Panelmodelle erfordert spezielle Ansätze, da klassische Gütemaße durch die Panelstruktur und räumliche Abhängigkeiten verzerrt werden. Unser im Haupttext (vgl. Gleichungen A.4 und A.5) spezifiziertes SARAR-Modell (Spatial Autoregressive with Autoregressive Residuals) mit Fixed Effects (Stadt μ_i und Zeit γ_t) kombiniert räumliche Lag- (λ) und Error-Komponenten (ρ):

$$y_{it} = \lambda \sum_{j=1}^N w_{ij} y_{jt} + X_{it} \beta + \mu_i + \gamma_t + u_{it} \quad (1)$$

$$u_{it} = \rho \sum_{j=1}^N w_{ij} u_{jt} + \varepsilon_{it} \quad (2)$$

Hierbei bezeichnet y_{it} die abhängige Variable (relative Mietpreisdifferenz), X_{it} die Matrix der exogenen Variablen, $W = [w_{ij}]$ die räumliche Gewichtungsmatrix, λ den räumlichen Lag-Parameter, ρ den räumlichen Fehlerparameter, μ_i und γ_t die Fixed Effects, und ε_{it} den idiosynkratischen Fehlerterm. Diese Spezifikation mit 82 Fixed Effects (73 Stadt-FE μ_i , 9 Zeit-FE γ_t) erfordert angepasste Gütemaße, die im Folgenden systematisch dargestellt werden.

ii Vorhersagegüte: Klassische Fehlermaße

Root Mean Squared Error (RMSE)

Der RMSE misst die durchschnittliche Abweichung zwischen beobachteten (y_i) und vorhergesagten ($\hat{y}_i$) Werten in den Origineleinheiten:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} = 0,0451 \quad (3)$$

Interpretation: Der RMSE von 0,0451 bedeutet, dass die vorhergesagten relativen Mietpreisdifferenzen im Durchschnitt um 4,5 Prozentpunkte von den beobachteten Werten abweichen. Bei einer Standardabweichung der abhängigen Variable von 15 Prozentpunkten

entspricht dies einem Variationskoeffizienten von 30% – ein guter Wert für hedonische Mietpreismodelle.

Mean Absolute Error (MAE)

Der MAE ist robuster gegenüber Ausreißern als der RMSE:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| = 0,0332 \quad (4)$$

Interpretation: Die mittlere absolute Abweichung von 3,3 Prozentpunkten zeigt, dass die Mehrheit der Vorhersagen näher am wahren Wert liegt als der RMSE suggeriert. Die Differenz zwischen RMSE und MAE (0,0451 vs. 0,0332) deutet auf einige größere Vorhersagefehler hin, die den RMSE stärker beeinflussen.

Mean Absolute Percentage Error (MAPE)

Der MAPE drückt Fehler als Prozentsatz aus, ist jedoch bei Werten nahe Null problematisch:

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| = 79,86\% \quad (5)$$

Vorsicht bei der Interpretation: Der hohe MAPE-Wert ist irreführend, da unsere abhängige Variable (relative Mietpreisdifferenzen) Werte nahe Null enthält. Bei kleinen Nennern steigt der MAPE mathematisch stark an. Für unsere Analyse sind RMSE und MAE aussagekräftiger.

iii Pseudo-R²-Maße für Panelmodelle

Problematik des klassischen R²

In Panelmodellen mit Fixed Effects ist das klassische R² nicht sinnvoll interpretierbar, da:

- Die Fixed Effects bereits den Großteil der Variation absorbieren
- Die Transformation zur Entfernung der Fixed Effects die Gesamtvarianz reduziert
- Räumliche Abhängigkeiten die Residualvarianz beeinflussen

Daher nutzen wir verschiedene Pseudo-R²-Maße:

Within-R²

Das Within-R² misst die Erklärungskraft nach Entfernung der Fixed Effects:

$$R_{\text{within}}^2 = 1 - \frac{\sum_{i,t} (y_{it} - \bar{y}_i - \bar{y}_t + \bar{y} - \hat{y}_{it})^2}{\sum_{i,t} (y_{it} - \bar{y}_i - \bar{y}_t + \bar{y})^2} = 0,089 \quad (6)$$

Interpretation: Das scheinbar niedrige Within- R^2 von 8,9% ist typisch für Panelmodelle mit umfangreichen Fixed Effects. Es zeigt, dass unsere sieben Kontrollvariablen und räumlichen Komponenten 8,9% der *verbleibenden* Variation erklären, nachdem stadt- und zeitspezifische Effekte herausgerechnet wurden. Dies ist kein Zeichen mangelnder Modellgüte, sondern reflektiert die Dominanz unbeobachteter Heterogenität in Mietpreisdaten.

Overall- R^2 (mit Fixed Effects)

Das Overall- R^2 inkludiert die Erklärungskraft aller Fixed Effects:

$$R_{\text{overall}}^2 = \text{Cor}^2(y, \hat{y}) = 0,827 \quad (7)$$

Interpretation: Die hohe Korrelation von 82,7% zwischen beobachteten und geschätzten Werten zeigt die Gesamtgüte des Modells. Allerdings ist dieser Wert durch die 82 Fixed Effects aufgebläht und eignet sich nicht für Modellvergleiche.

Pseudo- R^2 nach Kvalseth

Kvålseth (1985) schlägt eine Adjustierung für die Modellkomplexität vor:

$$R_{\text{Kvalseth}}^2 = 1 - \frac{(n-1)}{(n-k)} \cdot \frac{\text{SSE}}{\text{SST}} = 0,910 \quad (8)$$

wobei $n = 657$ Beobachtungen und $k = 91$ Parameter (7 Koeffizienten + 82 Fixed Effects + $\lambda + \rho$).

Interpretation: Das adjustierte Pseudo- R^2 von 91% bestätigt die sehr gute Modellanpassung unter Berücksichtigung der Modellkomplexität.

iv Räumliche Gütemaße

Spatial R^2 nach Anselin

Anselin (1988) weist ein R^2 speziell für räumliche Modelle aus:

$$R_{\text{spatial}}^2 = 1 - |\text{Moran's I der Residuen}| = 0,504 \quad (9)$$

Interpretation: Das Spatial R^2 von 50,4% zeigt, dass unser Modell etwa die Hälfte der räumlichen Abhängigkeiten in den Daten erfasst – ein guter Wert für räumliche Mietpreismodelle. Die verbleibenden räumlichen Muster könnten auf komplexere Spillover-Mechanismen hindeuten, die über unsere Spezifikation hinausgehen.

Räumliche Parameter

Die geschätzten räumlichen Parameter quantifizieren die Interdependenz:

- $\lambda = 0,477$ ($p = 0,102$): Signifikanter Spatial-Lag-Effekt (insbesondere unter Anwendung robuster Standardfehler)
- $\rho = 0,163$ ($p = 0,665$): Nicht-signifikanter Spatial-Error-Effekt

Interpretation: Die marginale Signifikanz des Lag-Parameters (λ) bei gleichzeitiger Insignifikanz des Error-Parameters (ρ) deutet darauf hin, dass die räumlichen Abhängigkeiten in den Daten primär durch direkte Spillover-Effekte zwischen den Städten bei der abhängigen Variable (Spatial Lag) und weniger durch räumlich korrelierte unbeobachtete Faktoren (Spatial Error) getrieben werden.

v Effekt-Dekomposition: Direkte und indirekte Effekte

In räumlichen Modellen unterscheiden sich der geschätzte Koeffizient β und der tatsächliche Effekt durch räumliche Multiplikatoren (LeSage, 2014):

$$\text{Direkter Effekt} = \frac{\beta}{1 - \lambda} \quad (10)$$

$$\text{Indirekter Effekt} = \frac{\lambda \cdot \beta}{(1 - \lambda)^2} \quad (11)$$

$$\text{Gesamteffekt} = \text{Direkter} + \text{Indirekter Effekt} \quad (12)$$

Tabelle An.12: Effekt-Dekomposition am Beispiel der Mietpreisbremse

Effekt-Typ	Wert	Anteil
Koeffizient β (MPB)	-0,0037	–
Direkter Effekt	-0,0071	52,6%
Indirekter Effekt (Spillover)	-0,0064	47,4%
Gesamteffekt	-0,0135	100%

Interpretation: Die Mietpreisbremse reduziert die relativen Differenzen direkt um etwa 0,71 Prozentpunkte in regulierten Städten. Zusätzlich entstehen signifikante indirekte Effekte (Spillovers) von etwa 0,64 Prozentpunkten, die sich auf benachbarte Städte auswirken oder als Feedback-Effekte in die eigene Stadt zurückwirken. Der Spillover-Anteil von rund 47% am Gesamteffekt unterstreicht die starke räumliche Interdependenz der Mietmärkte und die Bedeutung der räumlichen Modellierung.

vi Modellvergleich und Verbesserungen

Interpretation: Die SARAR-Spezifikation verbessert die Vorhersagegüte um etwa 0,9% gegenüber dem nicht-räumlichen Fixed-Effects-Modell. Diese scheinbar kleine Verbesserung

Tabelle An.13: Vergleich SARAR mit alternativen Spezifikationen

Kriterium	SARAR	Nicht-räumlich FE	Verbesserung
RMSE	0,0451	0,0455	0,9%
MAE	0,0332	0,0335	0,9%
SSE	1,336	1,361	1,86%
Log-Likelihood	1245,3	1239,1	–
LR-Test (χ^2)	12,32 (p = 0,002)		–

ist bei $n = 657$ Beobachtungen statistisch hochsignifikant (LR-Test: $\chi^2 = 12,32$, $p = 0,002$) und ökonomisch relevant, da sie systematische räumliche Verzerrungen eliminiert.

vii Zusammenfassende Bewertung

Die Gütemaße bestätigen, dass das SARAR-Modell die komplexen räumlichen und zeitlichen Dynamiken der deutschen Mietmärkte angemessen modelliert:


1. **Vorhersagegüte:** RMSE von 4,5 Prozentpunkten bei einer Standardabweichung von 15 Prozentpunkten zeigt gute Vorhersageleistung.
2. **Erklärungsgehalt:** Within- R^2 von 8,9% ist typisch und akzeptabel für FE-Panelmodelle. Die tatsächliche Erklärungskraft liegt in der Kontrolle unbeobachteter Heterogenität durch Fixed Effects.
3. **Räumliche Modellierung:** Der signifikante Spatial-Lag-Parameter bestätigt die Relevanz direkter Spillover-Effekte und die Notwendigkeit der räumlichen Modellierung. Der Spatial R^2 von 50,4% zeigt zudem, dass das Modell etwa die Hälfte der räumlichen Struktur in den Daten erklärt.
4. **Spillover-Effekte:** Fast die Hälfte (ca. 47%) der geschätzten Gesamtwirkung der Mietpreisbremse entfällt auf indirekte Effekte (Spillovers und Feedback-Loops) – ein substantieller Anteil, der die starke Vernetzung der Märkte zeigt und in nicht-räumlichen Modellen ignoriert würde.
5. **Statistische Signifikanz:** Die räumliche Spezifikation verbessert das Modell signifikant ($p = 0,002$) und eliminiert räumliche Autokorrelation in den Residuen.

Fazit: Trotz des niedrigen Within- R^2 – das für Panelmodelle mit umfangreichen Fixed Effects üblich ist – zeigt die Kombination aller Gütemaße eine robuste und valide Modellspezifikation.

Anhang zu Kapitel A.2

I Probabilistische Zuweisung der Mietstufen

Abbildung An.6: Methodik Zuweisung der Mietstufen mit Beispiel



Beispiele bedingter Wahrscheinlichkeitsverteilungen

Bundesland	Gemeindegröße	MS I	MS II	MS III	MS IV	MS V	MS VI
Bayern	20.000 - 100.000	7.3%	25.8%	26.5%	15.8%	4.0%	20.7%
Berlin	alle Größen	-	-	-	100.0%	-	-
Hamburg	alle Größen	-	-	-	-	-	100.0%
Niedersachsen	< 5.000	81.2%	5.7%	6.8%	6.3%	-	-
Baden-Württemberg	100.000 - 500.000	-	-	-	53.5%	31.2%	15.3%

Eigene Berechnung und Darstellung.

II Verteilung der Mietstufen in Deutschland

Tabelle An.14: Verteilung der Mietstufen in Deutschland nach Bundesland und Gemeindegrößenklasse

Bundesland	Gemeindegrößenklasse	I	II	III	IV	V	VI
Baden-Württemberg	unter 5.000	25.1%	40.2%	25.1%	9.7%	0%	0%
	5.000 bis unter 20.000	8.7%	30.4%	29.1%	24.1%	6.6%	1.2%
	20.000 bis unter 100.000	0%	9.5%	34.4%	22.5%	23.4%	10.3%
	100.000 bis unter 500.000	0%	0%	0%	53.5%	31.2%	15.3%
	500.000 und mehr	0%	0%	0%	0%	0%	100.0%
Bayern	unter 5.000	62.2%	19.7%	6.5%	7.3%	2.7%	1.5%
	5.000 bis unter 20.000	39.0%	24.7%	10.9%	10.0%	5.5%	9.9%
	20.000 bis unter 100.000	7.3%	25.8%	26.5%	15.8%	4.0%	20.7%
	100.000 bis unter 500.000	0%	0%	27.8%	56.2%	16.0%	0%
	500.000 und mehr	0%	0%	0%	26.1%	0%	73.9%
Berlin	500.000 und mehr	0%	0%	0%	100.0%	0%	0%
Brandenburg	unter 5.000	45.6%	54.4%	0%	0%	0%	0%
	5.000 bis unter 20.000	16.0%	57.8%	10.9%	11.0%	4.3%	0%
	20.000 bis unter 500.000	0%	33.3%	32.4%	28.3%	6.0%	0%
Bremen	100.000 bis unter 500.000	0%	0%	16.6%	83.4%	0%	0%
Hamburg	500.000 und mehr	0%	0%	0%	0%	0%	100.0%
Hessen	unter 20.000	36.6%	26.9%	13.8%	12.4%	7.7%	2.7%
	20.000 bis unter 100.000	0%	15.0%	10.5%	23.6%	35.6%	15.4%
	100.000 bis unter 500.000	0%	0%	26.3%	0%	0%	73.7%

Fortsetzung auf der nächsten Seite

Tabelle An.14 – Fortsetzung

Bundesland	Gemeindegrößenklasse	I	II	III	IV	V	VI
	500.000 und mehr	0%	0%	0%	0%	0%	100.0%
Mecklenburg-Vorpommern	unter 20.000	1.0%	79.6%	18.2%	1.2%	0%	0%
	20.000 bis unter 500.000	0%	8.2%	47.2%	44.6%	0%	0%
Niedersachsen	unter 5.000	81.2%	5.7%	6.8%	6.3%	0%	0%
	5.000 bis unter 20.000	66.2%	23.5%	6.4%	3.4%	0.4%	0%
	20.000 bis unter 100.000	18.6%	37.5%	26.9%	8.2%	7.4%	1.4%
	100.000 bis unter 500.000	0%	0%	36.0%	64.0%	0%	0%
	500.000 und mehr	0%	0%	0%	100.0%	0%	0%
Nordrhein-Westfalen	unter 20.000	31.9%	44.7%	20.3%	3.0%	0%	0%
	20.000 bis unter 100.000	5.2%	29.8%	41.6%	17.0%	6.4%	0%
	100.000 bis unter 500.000	0%	13.9%	54.5%	20.6%	11.0%	0%
	500.000 und mehr	0%	0%	20.4%	20.3%	0%	59.3%
Rheinland-Pfalz	unter 5.000	70.4%	22.3%	7.2%	0%	0%	0%
	5.000 bis unter 20.000	36.7%	33.9%	24.8%	4.6%	0%	0%
	20.000 bis unter 100.000	13.4%	32.1%	51.2%	0%	3.2%	0%
	100.000 bis unter 500.000	0%	0%	36.8%	27.8%	0%	35.4%
Saarland	5.000 bis unter 20.000	50.3%	49.7%	0%	0%	0%	0%
	20.000 bis unter 500.000	9.8%	44.9%	45.3%	0%	0%	0%
Sachsen	unter 5.000	68.2%	31.8%	0%	0%	0%	0%
	5.000 bis unter 20.000	40.7%	53.6%	5.8%	0%	0%	0%


Fortsetzung auf der nächsten Seite

Tabelle An.14 – Fortsetzung

Bundesland	Gemeindegrößenklasse	I	II	III	IV	V	VI
	20.000 bis unter 500.000	20.5%	68.0%	11.6%	0%	0%	0%
	500.000 und mehr	0%	51.4%	48.6%	0%	0%	0%
Sachsen-Anhalt	unter 20.000	58.0%	42.0%	0%	0%	0%	0%
	20.000 bis unter 100.000	3.1%	86.8%	10.1%	0%	0%	0%
	100.000 bis unter 500.000	0%	0%	100.0%	0%	0%	0%
Schleswig-Holstein	unter 5.000	22.7%	34.0%	29.1%	14.3%	0%	0%
	5.000 bis unter 20.000	7.0%	17.7%	22.2%	35.4%	9.9%	7.8%
	20.000 bis unter 100.000	0%	0%	41.9%	33.8%	3.9%	20.4%
	100.000 bis unter 500.000	0%	0%	0%	46.7%	53.3%	0%
Thüringen	unter 5.000	70.2%	29.8%	0%	0%	0%	0%
	5.000 bis unter 20.000	48.5%	51.5%	0%	0%	0%	0%
	20.000 bis unter 500.000	4.6%	48.5%	34.8%	12.1%	0%	0%
<i>Anmerkung:</i> Daten basieren auf der Zuordnung der Gemeinden zu den Mietstufen, gesammelt von den statistischen Landesämtern.							

III Kennzahlen der Mietstufen-Zuordnung und Monte Carlo Simulation


Abbildung An.7: Kennzahlen der Mietstufen-Zuordnung



Eigene Berechnung und Darstellung.

Stabilitätsanalyse der probabilistischen Mietstufen-Zuweisung Zur Validierung der stochastischen Mietstufen-Zuweisung wurde eine Monte Carlo Simulation mit $n = 50$ Iterationen durchgeführt. In jeder Iteration i erfolgte die Zuweisung der Mietstufen $MS_{h,i}$ für alle Haushalte h gemäß den bedingten Wahrscheinlichkeitsverteilungen $P(MS|BL, GGK)$ mit unterschiedlichen Random Seeds. Die Stabilität wurde anhand des Variationskoeffizienten $CV = \frac{\sigma}{\mu}$ über alle Iterationen gemessen. Die Ergebnisse zeigen nahezu vollständige Robustheit: Die Mietstufen-Verteilungen weisen maximale Variationskoeffizienten von $CV_{MS} < 1,02\%$ auf. Kritisch für die Modellvalidität ist die Stabilität der Sozialleistungen: Die Empfängerzahlen für Wohngeld und KdU bleiben über alle Iterationen konstant ($CV = 0,00\%$). Die Transferzahlungsvolumina zeigen minimale Variation ($CV_{WG} = 0,217\%$, $CV_{KdU} = 0,029\%$). Diese Stabilitätsmetriken bestätigen, dass die probabilistische Zuordnung keine Unsicherheit in die Modellergebnisse einführt und die aggregierten Effekte robust gegenüber der stochastischen Komponente sind.

Abbildung An.8: Stabilitätsmetriken




Eigene Berechnung und Darstellung.

IV Transferleistungen: KdU-Berechnungslogik und Strukturanalyse

Die Modellierung staatlicher Transferleistungen erfordert ein detailliertes Verständnis der Berechnungslogik. Das folgende Flussdiagramm operationalisiert die Schritte von der Ermittlung des Gesamtregelbedarfs über die Einkommensprüfung bis zur finalen Transferhöhe.

Abbildung An.9: KdU-Berechnung: Methodik und Beispiele


KdU-Berechnungslogik mit Gesamtregelbedarf



Eigene Berechnung. Die Beispiele illustrieren typische Fälle: Vollempfänger, Aufstocker und Grenzfälle zum Wohngeld.

Aufbauend auf dieser Berechnungslogik zeigt die folgende Strukturanalyse einen zentralen Mechanismus der deutschen Grundsicherung: die systematische Variation des Wohnkostenanteils am Gesamtregelbedarf.

Abbildung An.10: Struktur des Gesamtregelbedarfs nach Haushaltsgröße



Eigene Berechnung und Darstellung. Der Gesamtregelbedarf setzt sich aus Regelbedarf für Lebenshaltung (farbige Balken) und angemessenen Wohnkosten zusammen. Die rote Linie zeigt den sinkenden Anteil der Wohnkosten mit steigender Haushaltsgröße.

Während der absolute Regelbedarf mit der Haushaltsgröße steigt (von 52,9% bei Alleinstehenden auf 70,4% bei 7-Personen-Haushalten), sinkt der relative Mietanteil von etwa 47% auf 30%. Dies reflektiert Skaleneffekte beim Wohnen – größere Haushalte benötigen nicht proportional mehr Wohnfläche. Diese Systematik beeinflusst direkt die KdU-Berechtigungsschwellen und damit die fiskalischen Effekte von Mietpreisänderungen unterschiedlich je nach Haushaltsstruktur.

V GAM-Methodik zur Schätzung von Neuvertragsmieten

i Modellspezifikation und Datengrundlage


Die Schätzung individueller Neuvertragsmieten erfolgt mittels eines Generalisierten Additiven Modells (GAM) mit Tensorprodukt-Interaktionen. Die Trainingsdaten umfassen 19.635 Haushalte, die 2017-2018 eingezogen sind. Nach 1%-Tail-Filterung verbleiben 16.300 Beobachtungen.

Das finale Tensorprodukt-Modell spezifiziert:

$$\begin{aligned} \ln(\text{Miete}_i) = & \beta_0 + te(\text{Fläche}_i, \ln(\text{Einkommen}_i)) + \sum_j \gamma_j \text{Bundesland}_{ij} \\ & + \sum_k \delta_k \text{Gemeindegröße}_{ik} + \sum_l \theta_l \text{Heizungstyp}_{il} + \varepsilon_i \end{aligned} \quad (13)$$

Der Tensorprodukt-Term $te(\cdot, \cdot)$ ermöglicht vollständige Interaktionen zwischen Wohnfläche und Haushaltseinkommen mit 47,83 effektiven Freiheitsgraden. Die dreidimensionale Interaktionsoberfläche (Abbildung An.11) visualisiert die nicht-additive Beziehung:

Abbildung An.11: Tensorprodukt-Interaktionsoberfläche




Eigene Berechnung und Darstellung.

Die 3D-Visualisierung (a) zeigt die nicht-lineare Beziehung zwischen Wohnfläche, Einkommen und Miete. Die Oberfläche krümmt sich stärker bei höheren Einkommen, was die zunehmende Zahlungsbereitschaft für zusätzliche Fläche indiziert. Der Konturplot (b) mit Isolinien konstanter Miete demonstriert die Substitutionsbeziehung zwischen Fläche und Einkommen.

ii Diagnostische Tests und Methodische Lösungen

Die initiale additive Spezifikation wies einige Validitätsprobleme auf (Abbildung An.12):

Abbildung An.12: Diagnostische Analyse des Basis-GAM



Eigene Berechnung und Darstellung.

Die vier Panels zeigen: (a) Heteroskedastizität mit trichterförmigem Residuenmuster, (b) Q-Q-Plot mit schweren Verteilungsenden, (c) Scale-Location Plot mit nicht-konstanter Varianz, (d) Einflussreiche Beobachtungen.


Tabelle An.15: Validitätsprobleme des Basis-GAMs

Problem / Diagnostik (Basis-GAM)	Teststatistik (Basis-GAM)	Lösung / Ansatz (Finales Modell)
Heteroskedastizität	Breusch-Pagan: $\chi^2 = 976,64^{***}$	HC3-Standardfehler (SE +38-44%)
Nicht-Additivität	RESET: $F = 19,77^{***}$	Tensorprodukt-Interaktion
Nicht-Normalität der Residuen	Jarque-Bera $= 15.907^{***}$	Robuste Inferenz mittels Bootstrap (1.999 Rep.)
Unbeobachtete (räuml.) Heterogenität	Moran's I (Residuen) $= 0,183^{***}$	Kontrolle für Bundesland, Gemeindegröße, Heizungstyp

iii Adressierung der Heteroskedastizität

Die Heteroskedastizität wurde durch HC3-Standardfehler nach Davidson und MacKinnon (1993) adressiert. Abbildung An.13 demonstriert die Verbesserung:

Abbildung An.13: Heteroskedastizität-Stabilisierung durch Tensorprodukt und HC-Standardfehler




Eigene Berechnung und Darstellung.

Die obere Reihe zeigt das Basismodell mit deutlicher Heteroskedastizität ($BP \chi^2 = 976,64$): Der Residuen-Plot zeigt ein expandierendes Muster, die Scale-Location bestätigt zunehmende Varianz mit steigenden Anpassungswerten. Die untere Reihe zeigt das Tensorprodukt-Modell mit HC3-Korrektur: Während die Heteroskedastizität strukturell persistiert, ermöglichen die robusten Standardfehler ($SE +38-44\%$) valide Inferenz. Die Residuenverteilung verbessert sich von rechtsschief (rot) zu annähernd symmetrisch (grün).

iv Tensorprodukt-Interaktion und ökonomische Interpretation

Die Tensorprodukt-Spezifikation erfasst die einkommensabhängige Bewertung von Wohnfläche durch partielle Ableitungen zweiter Ordnung ungleich null: $\frac{\partial^2 \log(\text{Miete})}{\partial \text{Fläche} \partial \log(\text{Einkommen})} \neq 0$. Die Dekomposition in Abbildung An.14 zeigt die separaten und interaktiven Komponenten:

Abbildung An.14: Tensorprodukt-Dekomposition und partielle Effekte



Eigene Berechnung und Darstellung.

Die partiellen Effekte von Fläche und Einkommen (obere Panels) zeigen nicht-lineare Beziehungen mit effektiven Freiheitsgraden von 8,76 beziehungsweise 7,35. Die Interaktionsoberfläche (Mitte oben) visualisiert die gemeinsame Variation. Die marginalen Effekte bei verschiedenen Einkommensniveaus (rechts unten) bestätigen die ökonomische Hypothese differenzierter Zahlungsbereitschaft.

Tabelle An.16: Einkommensabhängige Flächenelastizitäten

Haushaltseinkommen	Flächenelastizität	Marginaler Effekt (€/m ² pro 10m ²)	Relative Bewertung
1.200 €/Monat	0,39	0,28	Referenz
3.000 €/Monat	0,56	0,41	+46%
5.500 €/Monat	0,73	0,53	+89%

v Modellgüte und Kreuzvalidierung

Tabelle An.17: Modellvergleich: Additiv vs. Tensorprodukt

Kriterium	Basis-Additiv	Tensorprodukt	Verbesserung
R^2	0,4318	0,4461	+3,3%
RMSE (€/m ²)	2,53	2,47	-2,4%
AIC	33.386	32.932	-454
Likelihood-Ratio	–	$\chi^2 = 487,3^{***}$	–
95% PI-Abdeckung	92,1%	94,8%	+2,7 pp

vi Methodische Einschränkungen

Trotz robuster Methodik verbleiben Datenlimitationen:

- Räumliche Auflösung auf 9 Gemeindegrößenklassen und 16 Bundesländer begrenzt
- Unbeobachtete Heterogenität (Baualter, Ausstattung, exakte Lage)
- Heteroskedastizität persistiert ($\chi^2 = 1010,76$, $p < 0,001$), aber durch HC3 adressiert

VI Ökonometrische Details zum Nachfragemodell

i Ökonometrische Validität

Tabelle An.18: Ökonometrische Validitätsübersicht

Test/Metrik	Wert	Schwellenwert	Status	Maßnahme
<i>Multikollinearität</i>				
VIF (max)	528,48	< 10	Verletzt*	Polynomialterme*
Konditionsindex	13,0	< 30	OK	Akzeptabel
<i>Heteroskedastizität</i>				
Breusch-Pagan	179,50	$p > 0,05$	Verletzt	Robuste SE (HC1)**
White Test	1145,65	$p > 0,05$	Verletzt	Robuste SE (HC1)**
<i>Modellgüte</i>				
R^2	0,456	$> 0,3$	OK	Gut für Querschnitt
Beobachtungen	100366	–	–	–


* Multikollinearität zwischen Polynomtermen ist inhärent und unproblematisch.

** HC1 = Heteroskedastizitäts-konsistente Standardfehler nach White (1980).

Eigene Berechnung und Darstellung.

ii Multikollinearität-Analyse

Abbildung An.15: Multikollinearität-Diagnostik




Eigene Berechnung und Darstellung.

Die hohen VIF-Werte (Panel a) resultieren aus der erwarteten Korrelation zwischen Polynomtermen (0,99 in Panel b). Dies beeinflusst nur die Präzision einzelner Koeffizienten, nicht die Gesamtvorhersage. Der moderate Konditionsindex von 13 (Panel d) zeigt, dass die Multikollinearität auf die Polynomterme beschränkt bleibt.

iii Heteroskedastizität-Diagnose


Abbildung An.16: Heteroskedastizität-Tests



Das Trichtermuster (Panel a) und die statistischen Tests (Panels c-d) bestätigen Heteroskedastizität. Diese ist ökonomisch plausibel: Größere Wohnungen zeigen heterogenere Anpassungsmöglichkeiten. HC1-robuste Standardfehler adressieren dies.

iv Normalität der Residuen

Abbildung An.17: Normalitäts-Tests




Eigene Berechnung und Darstellung.

Die Residuen sind nahezu normalverteilt (Panel b: Schiefe = -0,013). Leichte Abweichungen in den Rändern (Panel a) sind bei $n = 100.366$ durch den zentralen Grenzwertsatz unproblematisch.

v Residuenanalyse

Abbildung An.18: Residuen-Diagnostik



Eigene Berechnung und Darstellung.

Die Residuenanalyse zeigt keine systematischen Muster jenseits der bereits identifizierten Heteroskedastizität.

vi Robuste Inferenz

Zur Berücksichtigung der Heteroskedastizität verwenden wir HC1-robuste Standardfehler. Diese sind durchschnittlich 6-28% größer als OLS-Standardfehler, ändern aber weder Koeffizienten noch Prognosen. Das Modell erreicht ein R^2 von 0,456 und impliziert:

- **Einkommenselastizität:** ca. 0,25 (1% höheres Einkommen → 0,25% mehr Wohnfläche)

- **Preiselastizität:** Im Mittel -0,12 (nicht-linear durch Polynom)
- **Haushaltsgrößeneffekt:** ca. 4-5% zusätzliche Nachfrage pro Person

vii Fazit

Die identifizierten ökonometrischen Herausforderungen (Heteroskedastizität, Multikollinearität der Polynomterme) sind typisch für diese Modellklasse und werden durch robuste Methoden adressiert. Das Modell eignet sich für aggregierte Gleichgewichtsanalysen mit einem Erklärungsgehalt R^2 45,6% erklärter Varianz.


VII Ergänzende Analysen zu den Simulationsergebnissen

i Soziodemographische Detailanalysen

Einkommensstrukturen


Abbildung An.19 zeigt die absolute Einkommenssteigerung mit der Haushaltsgröße. Während Einpersonen-Haushalte im Durchschnitt über 1.600€ verfügen, steigt das Haushaltseinkommen auf etwa 3.700€ bei Vier-Personen-Haushalten. Das Pro-Kopf-Einkommen (Abbildung An.20) sinkt jedoch von 1.600€ bei Alleinstehenden auf 700€ bei Fünf-Personen-Haushalten, was auf Skaleneffekte und die Präsenz von Kindern zurückzuführen ist.

Abbildung An.19: Haushaltseinkommen nach Haushaltsgröße



Eigene Berechnung und Darstellung.


Abbildung An.20: Pro-Kopf-Einkommen nach Haushaltsgröße



Eigene Berechnung und Darstellung.

Die regionale Einkommensverteilung (Abbildung An.21) zeigt ein deutliches West-Ost-Gefälle: Während westdeutsche Flächenländer Medianeinkommen um 2.000€ aufweisen, liegen ostdeutsche Länder bei etwa 1.500€. Hamburg und Bayern zeigen die höchsten Medianwerte.

Abbildung An.21: Einkommensverteilung nach Bundesland




Eigene Berechnung und Darstellung.

Wohnflächenverteilung

Die durchschnittliche Wohnfläche variiert regional erheblich (Abbildung An.22). Baden-Württemberg, Rheinland-Pfalz und Niedersachsen weisen mit über 72m² die größten Durch-

schnittsflächen auf, während Stadtstaaten und ostdeutsche Länder bei etwa 65m² liegen.

Abbildung An.22: Durchschnittliche Wohnfläche nach Bundesland




Eigene Berechnung und Darstellung.

ii Anpassungsreaktionen

Konvergenzprozess

Der iterative Gleichgewichtsprozess zeigt eine schnelle Konvergenz innerhalb von zwei Iterationen. Abbildung An.23 visualisiert die Entwicklung der Durchschnittswerte über den Anpassungsprozess. Die Quadratmetermiete steigt initial von 6,48€ auf 7,39€, stabilisiert sich dann bei 7,33€. Die durchschnittliche Wohnfläche fällt von 68,6m² auf 63,5m², während die Gesamtmiete nach initialem Anstieg auf 491€ im Gleichgewicht bei 455€ konvergiert. Der Leerstand springt auf 7,4% nach der ersten Nachfrageanpassung und stabilisiert sich dann.

Abbildung An.23: Gleichgewichtskonvergenz - Durchschnittswerte




Eigene Berechnung und Darstellung.

Wohnflächenanpassung

Die Verteilung der individuellen Wohnflächenanpassungen (Abbildung An.24) zeigt eine linksschiefe Verteilung mit einem Median von $-7,1\text{m}^2$. Während die Mehrheit der Haushalte moderate Reduktionen zwischen 0 und 20m^2 vornimmt, zeigen etwa 15% keine Anpassung.

Abbildung An.24: Verteilung der Wohnflächenanpassung




Eigene Berechnung und Darstellung.

iii Regionale Heterogenität

Mietentwicklung und Belastung nach Mietstufe

Abbildung An.25 zeigt die heterogene regionale Entwicklung. Die Mietbelastung im Gleichgewicht variiert zwischen 19% (Mietstufe I) und 23% (Mietstufe VI). Die Wohnflächenreduktion ist in höheren Mietstufen stärker ausgeprägt (11,8% in Stufe VI vs. 3,7% in Stufe I).

Abbildung An.25: Regionale Mietentwicklung nach Mietstufe




Eigene Berechnung und Darstellung.

Transferleistungsintensität

Die Heatmap (Abbildung An.26) visualisiert die Transferintensität nach Mietstufe und Szenario. KdU-Quoten sind in höheren Mietstufen erwartungsgemäß höher (bis 19% in Stufe V-VI), während Wohngeldquoten in mittleren Mietstufen dominieren.

Abbildung An.26: Transferleistungsintensität nach Mietstufe




Eigene Berechnung und Darstellung.

iv Transferleistungsanalyse

Bundeslandspezifische Transferquoten

Abbildung An.27 zeigt erhebliche Länderunterschiede: Mecklenburg-Vorpommern und Berlin weisen die höchsten kombinierten Transferquoten auf (über 20%), während Bayern und Baden-Württemberg unter 10% liegen. Der Ost-West-Vergleich zeigt systematisch höhere KdU-Quoten in Ostdeutschland.

Abbildung An.27: Transferleistungen nach Bundesland




Eigene Berechnung und Darstellung.

Verteilung der Transferbeträge

Die Verteilungen der monatlichen Transferbeträge (Abbildung An.28) zeigen charakteristische Muster: Wohngeld konzentriert sich um 45-50€ mit rechtschiefer Verteilung, während KdU bimodal verteilt ist mit Peaks bei 190€ (Teilempfänger) und 400-600€ (Vollempfänger).

Abbildung An.28: Verteilung der monatlichen Transferbeträge



Eigene Berechnung und Darstellung.

Anhang zu Kapitel B.1

I UPI Dictionary

The UPI index is based on a corpus of three leading nation-wide German newspapers: “Sueddeutsche Zeitung” (center left), “Die Welt” (center right) and “Handelsblatt” (business). Following a number of preprocessing steps, an issue-specific analysis corpus is produced by applying a rather open query “uncertainty” OR “uncertain” OR “uncertainties” to the subcategories that are defined through specific words. Matches that count towards the uncertainty index are articles that both contain an uncertainty-word and a category-specific word while meeting safeguards. The category-specific words are dynamically obtained through clustering and are adjusted every quarter (Rieger et al., 2023). The following table presents an example of the top 30 words in 2021Q1:

Table An.19: UPI German Politics: Dictionary Example for 2021Q1

Words	Words (continued)	Words (continued)
federal government	merkel	kretschmann
federation	cdu	mistake
companies	chancellor	votes
business	laschet	easter rest
worker	merz	friedrich
schools	spd	party
employees	dreyer	angela
subsidies	union	roettgen
home office	soeder	prime minister
rapid test	prime ministers	gruenen
tests	malu	armin
spahn	fdp	federal parliament
law	habeck	chancellery
heil	federal chancellor	coalition
affected	merkels	csu
trade union	critics	additional
regulation	steel	relaxations
altmaier	incidence	coworker
opening	measures	staff

Note: This table presents the top 30 words applied to construct the UPI index in 2021Q1. These words represent the most cited terms referring to the political environment in Germany. The words were translated into English as they were originally recorded in German. Some of the listed words correspond to names of politicians, ministries, or political parties. For details on the construction of the UPI index, see Rieger et al. (2023).

II Testing for spatial Dependency


Table An.20: Moran's I Test Statistics for Transaction Prices

Quarter	(House Prices)	(Apartment Prices)
2013Q2	29.8625***	17.8688***
2013Q3	29.3458***	22.3868***
2013Q4	29.7262***	21.1091***
2014Q1	26.2963***	19.3714***
2014Q2	29.3760***	20.0418***
2014Q3	34.3999***	23.1655***
2014Q4	33.6439***	23.4442***
2015Q1	32.3567***	20.8979***
2015Q2	31.1530***	22.9666***
2015Q3	29.9520***	20.5148***
2015Q4	30.0597***	22.0858***
2016Q1	37.2093***	21.2695***
2016Q2	34.5000***	20.7549***
2016Q3	33.6619***	22.7749***
2016Q4	32.0204***	20.1865***
2017Q1	32.5533***	20.7324***
2017Q2	33.7658***	21.4744***
2017Q3	32.2547***	23.7140***
2017Q4	33.4172***	21.7603***
2018Q1	35.3577***	21.1411***
2018Q2	30.1494***	19.5894***
2018Q3	32.6997***	21.7918***
2018Q4	36.0511***	23.7758***
2019Q1	32.9722***	22.2392***
2019Q2	33.3483***	21.9526***
2019Q3	34.4006***	22.9917***
2019Q4	34.3672***	23.0578***
2020Q1	34.7579***	23.2211***
2020Q2	35.7641***	22.9806***
2020Q3	36.4477***	23.7616***
2020Q4	35.1603***	23.7154***
2021Q1	33.3808***	21.5115***
2021Q2	34.8515***	23.1942***
2021Q3	35.0476***	23.2839***
2021Q4	34.5137***	22.7861***
2022Q1	35.3621***	24.1517***

Note: This table presents the results of Moran's I test Moran1950 applied to house prices (€/m²) and apartment prices (€/m²). A distance-based neighborhood matrix is used; see Section 4.2 for details on the neighborhood specification. Significance levels: *** $p < 0.01$, ** $p < 0.05$, * $p < 0.10$.


III Normality of Residuals

Figure An.29: Q-Q Plot Model 2 – House Prices




Own calculations and illustration. *Note:* This figure illustrates the Q-Q plot to check for normality of residuals.

Figure An.30: Q-Q Plot Model 8 – Apartment Prices




Own calculations and illustration. *Note:* This figure illustrates the Q-Q plot to check for normality of residuals.

Figure An.31: Residual Distribution Model 2 – House Prices



Own calculations and illustration. *Note:* This figure illustrates the residual distribution to check for normality of residuals.


Figure An.32: Residual Distribution Model 8 – Apartment Prices



Own calculations and illustration. *Note:* This figure illustrates the residual distribution to check for normality of residuals.


IV Heteroskedasticity Tests

Figure An.33: Residual vs. Fitted Values Model 2 – House Prices



Own calculations and illustration. *Note:* This figure illustrates the residual and fitted values to check for heteroskedasticity issues.


Figure An.34: Residual vs. Fitted Values Model 8 – Apartment Prices



Own calculations and illustration. *Note:* This figure illustrates the residual and fitted values to check for heteroskedasticity issues.


V Autocorrelation Tests

Figure An.35: Autocorrelation Function Model 2 – House Prices



Own calculations and illustration. *Note:* This figure illustrates the autocorrelation function to check for autocorrelation issues.

Figure An.36: Autocorrelation Function Model 8 – Apartment Prices



Own calculations and illustration. *Note:* This figure illustrates the autocorrelation function to check for autocorrelation issues.