



AfD-Wahlergebnisse und fremdenfeindliche Hate Crimes: Eine eventbasierte Panelanalyse deutscher Landkreise

Samuel T. Brotschi, Universität Zürich

Abstract: Diese Arbeit untersucht, ob Wahlerfolge der Alternative für Deutschland (AfD) mit einem kurzfristigen Anstieg fremdenfeindlicher Hate Crimes in Deutschland verbunden sind. Ausgangspunkt ist die theoretische Annahme eines Normalisierungseffekts, wonach politische Erfolge rechtsextremer Parteien die wahrgenommene gesellschaftliche Akzeptanz xenophober Positionen erhöhen und dadurch Hemmschwellen gegenüber fremdenfeindlichem Verhalten senken können. Die Analyse basiert auf einem monatlichen Paneldatensatz auf Kreisebene für den Zeitraum 2015 bis 2019, der geokodierte Daten zu fremdenfeindlichen Hate Crimes mit Wahlergebnissen der AfD kombiniert. Zur Untersuchung des Zusammenhangs werden eventbasierte Fixed-Effects-Modelle sowie Event-Study-Spezifikationen geschätzt, die kurzfristige Veränderungen innerhalb derselben Kreise über die Zeit analysieren. Zusätzlich werden alternative Operationalisierungen von Wahlerfolg sowie Robustheitsanalysen mit Poisson- und Negative-Binomial-Modellen durchgeführt. Die Ergebnisse liefern keine robuste Evidenz dafür, dass höhere AfD-Wahlergebnisse kurzfristig mit einem Anstieg fremdenfeindlicher Hate Crimes verbunden sind. Weder die eventbasierten Hauptmodelle noch die Event-Study-Analysen zeigen statistisch signifikante Effekte. Die Arbeit relativiert damit die Annahme unmittelbarer kurzfristiger Normalisierungseffekte rechtsextremer Wahlerfolge und verweist stattdessen auf möglicherweise langfristige oder stärker kontextabhängige Mechanismen.

Abgabedatum: 31.05.2026
Wortanzahl: 10'735

Studiengang: Politikwissenschaft und Geschichte der Neuzeit

Inhaltsverzeichnis

1.0 Einleitung	1
2.0 Literaturübersicht	2
2.1 <i>Determinanten Hate Crime</i>	2
2.1.1 Out-group threat	2
2.1.2 Ökonomische Faktoren	3
2.2 <i>Politische Faktoren</i>	3
2.3 <i>Mechanismen politischer Signalwirkung</i>	4
2.4 <i>Alternative Mechanismen</i>	4
2.5 <i>Beitrag dieser Arbeit</i>	5
3.0 Theorie	6
3.1 <i>Normalisierung</i>	6
3.2 <i>Wahrgenommene soziale Normen und soziale Kosten</i>	6
3.3 <i>Mechanismus</i>	8
3.4 <i>Hypothesen</i>	9
4.0 Methode	10
4.1 <i>Fallauswahl</i>	10
4.1.1 Bundesrepublik Deutschland	10
4.1.2 Die Alternative für Deutschland (AfD)	11
4.1.3 Die Jahre 2015 bis 2019	12
4.2 <i>Datenquellen</i>	12
4.2.1 Daten Hate Crime	12
4.2.2 Wahldaten	13
4.2.3 Struktur- und Kontrolldaten	13
4.3 <i>Variablen und Operationalisierung</i>	13
4.3.1 Abhängige Variable	13
4.3.2 Zentrale unabhängige Variablen	14
4.3.3 Operationalisierung der Wahlergebnisse	14
4.3.4 Kontrollvariablen	14
4.4 <i>Analysestrategie</i>	15
4.4.1 Hauptmodell: Eventbasiertes lineares Fixed-Effects-Modell	15
4.4.2 Identifikationslogik	16
4.4.3 Landtagswahlen und Bundestagswahlen	16
4.4.4 Erweiterung um Kontrollvariablen	17
4.4.5 Event-Study-Spezifikation	17
4.4.6 Bedingte Effekte bei niedrigem vorherigen AfD Niveau	18
4.4.7 Alternative Operationalisierung von Wahlerfolg	18
4.4.8 Robustheitsanalyse	19
5.0 Resultate	20
5.1 <i>Deskriptive Ergebnisse</i>	20
5.2 <i>Ergebnis Eventbasierte Fixed-Effects-Modelle</i>	21
5.2.1 Landtagswahlen	21
5.2.2 Bundestagswahlen	22
5.2.3 Niedriges vorheriges AfD-Niveau Landtagswahlen	23
5.3 <i>Dynamik der Effekte über mehrere Monate</i>	23

5.3.1 Landtagswahlen	23
5.3.2 Bundestagswahlen	24
5.4 <i>Alternative Operationalisierung von Wahlerfolg</i>	24
5.4.1 Zugewinne der AfD.....	24
5.5 <i>Robustheitsanalyse</i>	25
5.5.1 Poisson-Modelle	25
5.5.2 Negativ-Binomial-Modelle	25
5.6 <i>Fazit Analyse</i>	25
6.0 Diskussion	26
6.1 <i>Mögliche Erklärungen</i>	26
6.2 <i>Bedeutung für die Literatur</i>	28
6.3 <i>Ausblick für zukünftige Forschung</i>	30
7.0 Limitation	30
Literaturverzeichnis.....	34
Abbildungs- und Tabellenverzeichnis	37
Appendix.....	

1.0 Einleitung

In den letzten Jahren ist in Deutschland ein deutlicher Anstieg eingeleiteter Verfahren im Bereich der Hasskriminalität zu beobachten. Im Jahr 2022 wurden bundesweit rund 15'686 Verfahren registriert, 2023 stieg diese Zahl auf 19'557. Für das Jahr 2024 wurden bereits 30'529 Verfahren erfasst. Da aber für die Bundesländer Bayern, Baden-Württemberg und Mecklenburg-Vorpommern noch keine vollständigen Statistiken vorliegen, dürfte die tatsächliche Zahl noch höher liegen. In nur diesen drei Jahren entspricht das einem Anstieg von mindestens 94.6 Prozent (Höber und Sander 2026). Ein ähnliches Muster zeigt sich auch bei der politisch motivierten Kriminalität (PMK), die 2024 einen Höchststand erreichte, wobei insbesondere der Phänomenbereich „PMK rechts“ überproportional zunahm (BMI 2025).

Gleichzeitig gewinnen rechtsextreme Parteien in ganz Europa immer mehr an Zuwachs, so zum Beispiel die Alternative für Deutschland (AfD) in Deutschland (Rees u. a. 2019). Der zeitliche Zusammenhang zwischen der Zunahme rechtsextrem motivierter Hate Crime und den Wahlerfolgen rechtsextremer Parteien wirft die Frage auf, ob und in welchen Ausmass beide Entwicklungen miteinander verbunden sind.

Ein möglicher Erklärungsmechanismus ist die sogenannte Normalisierung rechtsextremer Positionen. Darunter wird verstanden, dass durch politische Erfolge rechtsextremer Parteien bestimmte Einstellungen gesellschaftlich als akzeptabler wahrgenommen werden, wodurch Hemmschwellen gegenüber gewalttätigem Verhalten sinken. Entscheidend ist dabei aber nicht die Veränderung des Diskurses an sich, sondern vielmehr die Signalwirkung von Wahlerfolgen.

Dieser Erklärungsmechanismus ist nicht unbegründet und wurde ähnlich schon in diversen Forschungen untersucht. So zum Beispiel beim Zusammenhang zwischen unerwartet hohen AfD-Erfolgen und dem Auftreten rechtsextremer Demonstrationen (Hagemeister 2022), positiven Zusammenhängen zwischen rechtsextremer Gewalt von Bewegungen und der Wahl rechtsextremer Parteien in der Türkei (Kumral 2017) oder Hate Crime in Italien im Kontext von Bürgermeister*innen-Wahlen (Romarri 2019).

Die vorliegende Arbeit greift diese Vermutung auf und untersucht konkret:

Führen Wahlerfolge rechtsextremer Parteien zu einem Anstieg von Hate Crime?

Die Analyse konzentriert sich auf Deutschland als Fall einer etablierten westlichen Demokratie mit kompetitivem Parteiensystem und, aufgrund geschichtlichen Hintergrunds, starkem Stigma gegenüber rechtsextremen Positionen und Parteien. Die Ergebnisse sind jedoch potenziell auch

für andere westeuropäische Kontexte relevant, in denen rechtsextreme Parteien an Dominanz zulegen (Rhein-Fischer und Wójcik 2023).

Die Arbeit trägt dazu bei, die Normalisierungstheorie zu politischer Gewalt empirisch für den deutschen Kontext zu prüfen.

Für die empirische Analyse wird ein monatlicher Paneldatensatz auf Kreisebene für Deutschland im Zeitraum 2015 bis 2019 verwendet, der geokodierte Daten zu fremdenfeindlichen Hate Crimes mit Wahlergebnissen der AfD kombiniert. Zur Analyse des Zusammenhangs werden eventbasierte Fixed-Effects-Modelle sowie Event-Study-Spezifikationen geschätzt, die kurzfristige Veränderungen innerhalb derselben Kreise über die Zeit analysieren.

Die Ergebnisse liefern keine robuste Evidenz dafür, dass höhere AfD-Wahlergebnisse kurzfristig mit einem Anstieg fremdenfeindlicher Hate Crimes verbunden sind. Weder die eventbasierten Hauptmodelle noch die Event-Study-Analysen zeigen statistisch signifikante Effekte. Die Arbeit relativiert damit die Annahme eines unmittelbaren kurzfristigen Normalisierungseffekts rechtsextremer Wahlerfolge und verweist stattdessen auf möglicherweise langfristige oder stärker kontextabhängige Mechanismen.

2.0 Literaturübersicht

2.1 Determinanten Hate Crime

2.1.1 Out-group threat

Ein zentraler Erklärungsansatz für das Auftreten von Hate Crime ist Out-group threat. Dieser geht davon aus, dass wahrgenommene Bedrohungen durch externe Gruppen negative Einstellungen gegenüber genau diesen Gruppen verstärken und in bestimmten Situationen auch in feindseliges oder gewalttätiges Verhalten umschlagen können. Bereits früh argumentierte Herbert Blumer, dass Vorurteile nicht primär auf individuellen Einstellungen beruhen, sondern auf einer kollektiven „sense of group position“. Also der wahrgenommenen Stellung dieser Gruppe im Verhältnis zu den anderen. Zentrale Bestandteile dieses Verständnisses sind unter anderem ein Gefühl der Überlegenheit, Abgrenzung sowie die Angst, dass andere Gruppen die eigene soziale Position bedrohen (Blumer 1958). Vor diesem Hintergrund erscheint Hate Crime als mögliche Reaktion auf wahrgenommene Bedrohungen dieser Gruppenposition.

Des Weiteren zeigen Riaz et al. für Deutschland, dass öffentlich bekannt gewordene Straftaten, die Migrant:innen zugeschrieben werden, die tägliche Wahrscheinlichkeit fremdenfeindlicher Hate Crime im entsprechenden Landkreis in den darauffolgenden Tagen deutlich erhöhen (Riaz u. a. 2020). Während Riaz zeigt, dass konkrete Ereignisse kurzfristige Bedrohungswahrnehmungen aktivieren können, weisen andere darauf hin, dass insbesondere

soziale Medien als Verstärker solcher Wahrnehmungen wirken können. So zeigen Müller und Schwarz für Deutschland, dass antirefugee Inhalte auf Facebook mit einer erhöhten Wahrscheinlichkeit von Angriffen auf Geflüchtete einhergehen und somit bestehende Ressentiments in gewalttätiges Verhalten übersetzen können (Müller und Schwarz 2021).

2.1.2 Ökonomische Faktoren

Neben wahrgenommenen Bedrohungen durch Outgroups betont die Literatur auch die Rolle ökonomischer Faktoren als zentrale Determinanten von Hate Crime. So finden zum Beispiel Anderson et al. einen kausalen Mechanismus, der stärkere ökonomische Schocks mit einer Zunahme rassistischer Hate Crime gegen PoC und rassistischer Internetsuchen im Kontext der Weltwirtschaftskrise 2008 verbindet (Anderson u. a. 2020). Dieser Befund deutet darauf hin, dass ökonomische Unsicherheit gesellschaftliche Spannungen verstärken und zur Externalisierung von Frustration auf Minderheiten beitragen kann.

Ähnliche Zusammenhänge zeigen sich auch in anderen Kontexten. So argumentieren Bray et al., dass wirtschafts- und wohlfahrtsstaatliche Schocks Hate Crime erhöhen können und dies auch ohne unmittelbaren Parteierfolg. Dieses Ergebnis findet er im Kontext vom Vereinigten Königreich (Bray u. a. 2024).

Darüber hinaus weisen Studien darauf hin, dass spezifische ökonomische Indikatoren wie Arbeitslosigkeit mit Hate Crime zusammenhängen. Curthoys findet für die USA, dass insbesondere ein moderates Level an Arbeitslosigkeit einen positiv signifikanten Einfluss auf Hate Crime hat, während Low- und High-Levels einen negativen Einfluss aufweisen (Curthoys 2013). Dies deutet darauf hin, dass der Zusammenhang zwischen ökonomischer Lage und Hate Crime nicht linear ist.

Im Gegensatz dazu finden Falk et al. einen positiv signifikanten Zusammenhang zwischen rechter Gewalt und Arbeitslosigkeit. Dies testen sie im Kontextfall Deutschland und erklären die Unterschiede rechter Gewalt zwischen Ost- und Westdeutschen Bundesländern vor allem aufgrund der unterschiedlichen Anzahl an arbeitslosen Personen (Falk u. a. 2011).

2.2 Politische Faktoren

Die Frage, ob Wahlerfolge rechtsextremer Parteien mit einem Anstieg von Hate Crime zusammenhängen, ist in der bestehenden Literatur bereits teilweise untersucht worden. So zeigen Rees et al. In ihrer Studie zum „Climate of Hate“ für Deutschland, dass Unterstützung für die AfD und rechtsextreme Hate Crime räumlich stark zusammenfallen. Zudem sind beide Phänomene durch ähnliche sozio-strukturelle Faktoren geprägt, wie etwa Arbeitslosigkeit und der lokale Ausländer*innenanteil (Rees u. a. 2019). Diese Befunde deuten darauf hin, dass politischer Erfolg rechtsextremer Parteien und Hate Crime in einem gemeinsamen Kontext

auftreten können. Entsprechend bleibt aber offen, ob Wahlerfolge rechtsextremer Parteien lediglich ein Ausdruck bestehender gesellschaftlicher Spannungen sind oder ob sie darüber hinaus aktiv zur Veränderung von Verhalten beitragen. Andere Studien zeigen, dass die Stärke rechtsextremer Parteien auf lokaler Ebene mit einer höheren Wahrscheinlichkeit von Gewalt gegen Geflüchtete einhergeht (Jäckle und König 2017).

2.3 Mechanismen politischer Signalwirkung

Die bisherigen Befunde zeigen, dass Wahlen rechtsextremer Parteien und Hate Crime häufig gemeinsam auftreten. Es bleibt jedoch die Frage offen, ob und wie ein kausaler Zusammenhang zwischen den beiden Phänomenen besteht. Im Zentrum dabei steht die Frage, wie genau rechtsextreme Parteien das Verhalten von Individuen beeinflussen können.

Ein zentraler Ansatz argumentiert, dass Wahlerfolge rechtsextremer Parteien als soziale und politische Signale wirken. Sichtbare Wahlerfolge können die Wahrnehmung verändern, welche Positionen gesellschaftlich akzeptabel oder öffentlich artikulierbar erscheinen. Dadurch könnten insbesondere für Personen mit bereits vorhandenen xenophoben Einstellungen die wahrgenommenen sozialen Kosten offener Fremdenfeindlichkeit sinken.

Hagemeister zeigt für Deutschland, dass unerwartet starke AfD-Wahlergebnisse mit einer Zunahme rechtsextremer Demonstrationen verbunden sind. In seiner Analyse findet er, dass gerade in liberalen Gemeinden, in denen die AfD bei Wahlen unerwartet stark war, deutlich häufiger rechtsextreme Demonstrationen stattfinden. Er interpretiert diesen Zusammenhang als Informations- beziehungsweise Normalisierungseffekt: Wahlerfolge können den Eindruck verstärken, dass xenophobe Positionen gesellschaftlich stärker geteilt werden als zuvor angenommen (Hagemeister 2022). Wie Hagemeister finden auch zahlreiche andere Autor*innen einen Zusammenhang zwischen der Stärke von Rechtsaußenparteien und politischer Gewalt von rechts. So zum Beispiel im Zusammenhang mit Anschlägen auf Flüchtlingsheime in Deutschland oder Hate Crime in Italien im Kontext von Bürgermeister*innenwahlen (Jäckle und König 2017; Kleinfeld und Sedaca 2024; Kumral 2017; Romarri 2019; Whittington und Piatkowska 2025). Diese Arbeiten deuten darauf hin, dass politische Wahlerfolge nicht nur bestehende Einstellungen widerspiegeln, sondern potenziell auch Verhaltenshemmungen reduzieren können.

2.4 Alternative Mechanismen

Neben Mechanismen der Normalisierung und Legitimation weist die Literatur auch auf alternative Erklärungsansätze hin, die den Zusammenhang zwischen Wahlerfolgen rechtsextremer Parteien und Gewalt unterschiedlich interpretieren.

Ein zentraler Gegensatz argumentiert, dass politische Integration rechtsextremer Akteure Gewalt nicht verstärkt, sondern substituieren kann. Koopmans et al. zeigen, dass die Einbindung radikal

rechter Positionen in das Parteiensystem Gewalt reduzieren kann, da parlamentarische Kanäle alternative Ausdrucksformen für politische Unzufriedenheit bieten (Koopmans u. a. 2005, zit. nach Muis und Immerzeel 2017). Der Kerngedanke dieser Substitutionsthese lautet, dass Personen mit rechtsextremen oder migrationskritischen Einstellungen durch Wahlerfolge eine institutionelle Repräsentation erhalten und politische Partizipation dadurch verstärkt innerhalb formaler Kanäle stattfindet. Dies auf Kosten ausserparlamentarischer oder gewaltsamer Mobilisierung. Wahlerfolge rechtsextremer Parteien wären in dieser Theorie also nicht Auslöser von Gewalt, sondern im Gegenteil ein moderierender Faktor, der den Druck aus informellen Protestformen nimmt. Ravndal weist in eine ähnliche Richtung und zeigt für Westeuropa, dass der Zugang zu politischer Macht in einer Reihe von Ländern mit einem Rückgang rechtsextremer Gewalt zusammenzufallen scheint (Ravndal 2016). Muis und Immerzeel schlussfolgern entsprechend, dass der Wahlkanal gewaltsame Strassenaktivität effektiv ersetzen kann (Muis und Immerzeel 2017).

Andere Ansätze betonen die Bedeutung politischer Opportunitätsstrukturen und situativer Kontexte. Caiani und Borri argumentieren, dass rechtsextreme Gewalt als strategische Handlungsoption innerhalb eines breiteren Repertoires verstanden werden muss und insbesondere dann wahrscheinlicher wird, wenn politische Kontexte als geschlossen wahrgenommen werden (Caiani und Borri 2012). Della Porta hebt zudem hervor, dass staatliche Repression zur Radikalisierung beitragen kann, indem moderatere Akteure verdrängt und radikalere Positionen gestärkt werden (della Porta 2014).

Insgesamt zeigen diese Ansätze, dass der Zusammenhang zwischen rechtsextremen Parteien und Gewalt nicht eindeutig ist, sondern je nach Kontext sowohl verstärkende als auch abschwächende Effekte möglich sind.

2.5 Beitrag dieser Arbeit

Zusammenfassend zeigt die bestehende Literatur, dass Hate Crime durch eine Vielzahl struktureller, situativer und politischer Faktoren beeinflusst wird. Während einige Studien auf einen Zusammenhang zwischen der Stärke rechtsextremer Parteien und Gewalt hinweisen, bleibt unklar, ob Wahlerfolge selbst einen eigenständigen Effekt auf Hate Crime haben oder primär bestehende gesellschaftliche Spannungen widerspiegeln.

Zudem ist bislang nur begrenzt untersucht, in welchem Ausmass kurzfristige Veränderungen im politischen Kontext, wie Wahlerfolge, tatsächlich zu messbaren Veränderungen in Hate Crime führen. Insbesondere fehlt es an Analysen, die diesen Zusammenhang systematisch über Zeit und zwischen Regionen hinweg untersuchen.

An diese Lücke knüpft die vorliegende Arbeit an, indem sie für den Fall Deutschland analysiert, ob und in welchem Ausmass Wahlerfolge rechtsextremer Parteien mit Veränderungen in Hate Crime einhergehen.

3.0 Theorie

Aufbauend auf den bisherigen Befunden entwickelt dieser Abschnitt einen theoretischen Mechanismus, der erklärt, wie Wahlerfolge rechtsextremer Parteien individuelles Verhalten beeinflussen.

3.1 Normalisierung

Soziale Normen sind wandelbar, wenn sich der wahrgenommene gesellschaftliche Kontext verändert. Wahlergebnisse können dabei als öffentlich sichtbares Signal darüber wirken, welche Positionen in einer Gesellschaft als anschlussfähig gelten. Im Kontext dieser Arbeit wird Normalisierung als eine Veränderung der Wahrnehmung sozialer Akzeptanz verstanden. Dadurch steigt die Bereitschaft von Personen, Meinungen zu vertreten oder Verhaltensweisen zu zeigen, die bislang als stigmatisiert wahrgenommen wurden. Zugleich nimmt auch die negative Bewertung von anderen, die dies tun, ab (Bursztyn u. a. 2020).

Normalisierung zeigt sich dabei darin, dass rechtsextreme Positionen, Begrifflichkeiten und Deutungsmuster schrittweise als zunehmend legitime Beiträge zum politischen Diskurs erscheinen. Rechtsextreme Politiker*innen brechen die komplexen Sachverhalte auf eingängige Narrative herunter und appellieren an den vermeintlich gesunden Menschenverstand, wie auch die Intuition des Wählenden und knüpfen an Vorurteile und rassistische Ressentiments sowie einen „anti-intellectualism“ an (Wodak 2021, 4).

Auf dieser Grundlage untersucht die vorliegende Arbeit, inwiefern Wahlergebnisse als Signale mit Veränderungen in Hate Crime einhergehen und damit indirekt auf Prozesse der Normalisierung rechtsextremer Positionen hindeuten.

3.2 Wahrgenommene soziale Normen und soziale Kosten

Wahlerfolge rechtsextremer Parteien senden ein Signal darüber, welche Positionen in der Öffentlichkeit als anschlussfähig gelten. Ein unerwartet hoher Stimmenanteil der AfD kann von Personen mit xenophoben Einstellungen so interpretiert werden, dass ihre Einstellungen von vielen anderen geteilt werden und diese nicht eine randständige Minderheitsmeinung darstellt (Hagemeister 2022; Wodak 2021).

Wahlergebnisse besitzen dabei eine besondere politische und symbolische Bedeutung, da sie als demokratisch legitimer Ausdruck gesellschaftlicher Präferenzen wahrgenommen werden. Im Unterschied zu randständigen Protestgruppen oder vereinzelt extremen Akteur*innen

signalisieren parlamentarische Wahlerfolge, dass entsprechende Positionen von einem relevanten Teil der Bevölkerung unterstützt werden. Dadurch können rechtsextreme Einstellungen nicht nur sichtbarer, sondern auch gesellschaftlich und institutionell legitimer erscheinen (Apffelstaedt u. a. 2022; Valentim 2021).

Diese Form demokratischer Sichtbarkeit kann wiederum beeinflussen, welche Positionen Individuen als gesellschaftlich akzeptabel oder öffentlich artikulierbar wahrnehmen. Wenn rechtsextreme Parteien sichtbare Erfolge erzielen und ihre Positionen in Medien und parlamentarischen Arenen präsent sind, sinkt für Sympathisant*innen die erwartete Gefahr, für offene rassistische Äusserungen sanktioniert zu werden (Bursztyn u. a. 2020).

Dabei ist weniger entscheidend, ob sich gesellschaftliche Einstellungen tatsächlich verändern, sondern vielmehr, wie Individuen die gesellschaftliche Akzeptanz bestimmter Positionen wahrnehmen. Politische Wahlerfolge können deshalb insbesondere die subjektive Wahrnehmung sozialer Normen beeinflussen. Personen orientieren ihr Verhalten häufig nicht nur an privaten Überzeugungen, sondern auch an ihrer Einschätzung darüber, welche Positionen gesellschaftlich toleriert oder unterstützt werden (Tankard und Paluck 2016).

Die Erwartung sozialer Sanktionen spielt dabei eine zentrale Rolle, da Individuen normabweichende Einstellungen häufig nur dann offen artikulieren, wenn sie keine starken negativen sozialen Konsequenzen erwarten müssen. Individuen passen also ihr Verhalten an wahrgenommene soziale Normen an (Bursztyn u. a. 2020). Ähnlich findet auch Noelle-Neumann, dass Individuen ihre Bereitschaft, Meinungen öffentlich zu äussern, stark davon abhängig machen, ob sie diese als mehrheitsfähig wahrnehmen. Die Angst vor sozialer Isolation führt dazu, dass abweichende Positionen häufiger nicht geäußert werden (Noelle-Neumann 1974). Diese Logik ist für xenophobe Einstellungen besonders relevant. In etablierten Demokratien wie Deutschland sind offen rechtsextreme und rassistische Positionen historisch und gesellschaftlich stark stigmatisiert. Dieses Stigma erzeugt soziale Kosten: Wer solche Einstellungen offen zeigt, muss mit Ablehnung, Kritik oder sozialer Isolation rechnen.

Wenn Wahlerfolge rechtsextremer Parteien jedoch als Signal interpretiert werden, dass entsprechende Einstellungen gesellschaftlich verbreitet sind, reduziert sich somit diese wahrgenommene Gefahr der Isolation. Dadurch sinkt die Hemmung, solche Positionen offen zu äussern oder in Handlung umzusetzen. Unter diesen Bedingungen erscheint es für bereits xenophobe Personen naheliegender, diese Haltung nicht nur verbal zu äussern, sondern in konfrontative Handlungen zu übersetzen (Hagemeister 2022). Der theoretische Mechanismus geht dabei nicht davon aus, dass Wahlerfolge neue xenophobe Einstellungen erzeugen. Vielmehr wird angenommen, dass bereits vorhandene Einstellungen sichtbarer artikuliert und unter bestimmten Bedingungen offener ausgelebt werden. Wahlerfolge rechtsextremer Parteien wirken

in diesem Verständnis primär als Signal veränderter gesellschaftlicher Akzeptanz und reduzierter sozialer Kosten.

Normverschiebungen allein erklären jedoch nicht, warum sich Einstellungen in gewaltsame Handlungen übersetzen. Studien zu rechtsextremen Parteien und xenophoben Einstellungen zeigen, dass offen gelebte Fremdenfeindlichkeit für bereits xenophobe Individuen selbst einen Nutzen stiften kann. Offene Xenophobie bietet einfache Schuldzuschreibungen für komplexe Sachverhalte und kann erlebte Frustration, Angst oder Ausgeschlossenheit psychologisch entlasten (Rydgren 2003).

Wenn Wahlerfolge von rechtsextremen Parteien xenophobe Ideologie zusätzlich normalisieren und sanktionierende Stimmen in der Gesellschaft leiser werden, verschiebt sich die Grenze, von was als legitimer Ausdruck dieser Haltung gilt. Und dies bis hin zu einschüchternden Praktiken und gewaltsamen Übergriffen (Pascale 2019).

Gleichzeitig ist aber auch ein gegenteiliger Effekt denkbar, bei dem Wahlerfolge rechtsextremer Parteien für Sympatisant*innen eine Form politischer Befriedigung darstellen und damit die Notwendigkeit gewaltsamen Handelns reduzieren (Koopmans u. a. 2005; Ravndal 2016; Muis und Immerzeel 2017).

3.3 Mechanismus

Der theoretische Mechanismus dieser Arbeit lässt sich in drei Schritten zusammenfassen.

Erstens erzeugt ein Wahlerfolg der AfD ein öffentlich sichtbares politisches Signal. Je höher der Stimmenanteil ausfällt, desto stärker ist dieses Signal. Ein hoher AfD-Stimmenanteil zeigt, dass rechtsextreme oder xenophobe Positionen in einem bestimmten lokalen Kontext politisch anschlussfähig sind.

Zweitens verändert dieses Signal die Wahrnehmung sozialer Normen. Personen mit bereits vorhandenen xenophoben Einstellungen können daraus schliessen, dass ihre Einstellungen stärker verbreitet und gesellschaftlich akzeptierter sind als zuvor angenommen.

Drittens können durch diese veränderte Wahrnehmung die erwarteten sozialen Kosten offener Fremdenfeindlichkeit sinken. Wenn Personen weniger Ablehnung, Isolation oder Sanktionierung erwarten, steigt die Wahrscheinlichkeit, dass sie xenophobe Einstellungen offen äussern oder in konfrontatives Verhalten übersetzen. Im Extremfall kann dies auch fremdenfeindliche Hate Crimes begünstigen.

Der theoretische Mechanismus geht dabei von kurzfristigen Veränderungen in der Wahrnehmung sozialer Normen aus. Da Wahlergebnisse öffentlich stark sichtbare Ereignisse sind und unmittelbar mediale Aufmerksamkeit erhalten, können sie relativ schnell beeinflussen, welche Positionen als gesellschaftlich akzeptabel wahrgenommen werden und dadurch die öffentliche Artikulation bereits vorhandener xenophober Einstellungen begünstigen

Der Mechanismus lautet damit:




Abbildung 1: Theoretischer Mechanismus (eigene Grafik)

3.4 Hypothesen

Aus dem Mechanismus der signalbasierten Normalisierung lassen sich folgende Hypothesen ableiten:

- H1 =** Hate Crime steigt in den Monaten nach einer Wahl stärker in Kreisen mit höherem AfD-Stimmenanteil
- H2 =** Dieser Zusammenhang ist stärker ausgeprägt in Landkreisen mit niedrigem Ausgangsniveau an AfD-Unterstützung, gemessen am AfD-Stimmenanteil in vorheriger Wahl.

Die erste Hypothese folgt direkt aus der Annahme, dass ein höherer AfD-Stimmenanteil ein stärkeres Signal gesellschaftlicher Akzeptanz sendet. Wenn dieses Signal die erwarteten sozialen Kosten offener Fremdenfeindlichkeit senkt, sollte Hate Crime nach Wahlen besonders dort zunehmen, wo die AfD hohe Stimmenanteile erzielt.

Die zweite Hypothese beruht auf der Annahme, dass Signalwirkungen besonders stark sind, wenn rechtsextreme Unterstützung zuvor weniger sichtbar oder weniger etabliert war. In Kreisen mit niedrigem vorherigem AfD-Niveau kann ein hoher oder stark sichtbarer Wahlerfolg überraschender wirken und die Wahrnehmung sozialer Akzeptanz stärker verändern. In Kreisen, in denen AfD-Unterstützung bereits etabliert ist, dürfte das zusätzliche Signal eines Wahlerfolgs dagegen schwächer ausfallen.

4.0 Methode

Diese Arbeit verwendet ein quantitatives Forschungsdesign und analysiert ein Panel auf Kreisebene für Deutschland im Zeitraum 2015 bis 2019. Die ursprünglichen tagesgenauen Daten werden hierfür auf Monatsebene aggregiert, wodurch ein Panel mit rund 400 Kreisen und mehreren tausend Beobachtungen entsteht.

Zur Untersuchung des Zusammenhangs zwischen Wahlerfolgen der AfD und rechtsextremer Hate Crime wird ein eventbasierter Paneldatensatz verwendet. Dabei wird untersucht, ob sich die Anzahl rechtsextremer Delikte in den Monaten nach einer Wahl systematisch in Abhängigkeit vom AfD-Stimmenanteil verändert.

Zur Schätzung werden lineare Panelmodelle mit Fixed Effects für Kreise und Monate eingesetzt. Die Identifikation basiert dabei auf kurzfristigen Veränderungen innerhalb von Kreisen über die Zeit und nutzt somit ausschliesslich Variation innerhalb von Einheiten.

4.1 Fallauswahl

4.1.1 Bundesrepublik Deutschland

Deutschland wird in dieser Arbeit als Fallstudie zur Untersuchung der Forschungsfrage herangezogen. Deutschland weist mehrere Merkmale auf, die es besonders geeignet machen. Zum einen ist Deutschland ein Beispiel für ein Land mit einer historisch starken gesellschaftlichen und institutionellen Stigmatisierung rechtsextremer Parteien und Ideologien. Zugleich gibt es aber auch seit 2013 mit der AfD eine Partei, die diese Tradition durchbricht (Decker und Miliopoulos 2009; Caramani und Manucci 2019). Diese Umstände sind daher besonders wichtig, da Normalisierungs- oder Legitimitätseffekte insbesondere dort erwartet werden können, wo zuvor starke gesellschaftliche Sanktionen gegenüber rechtsextremen Positionen bestanden (Hagemeister 2022).

Darüber hinaus eignet sich Deutschland aufgrund der verfügbaren Daten zu Hate Crime auf Kreisebene, die eine räumlich und zeitlich differenzierte Analyse ermöglichen. Diese Daten erlauben es, Veränderungen rechtsextremer Delikte über die Zeit hinweg sowie zwischen verschiedenen Regionen systematisch zu untersuchen.

Hinzu kommt, dass Deutschland als föderaler Staat mit 16 Bundesländern Unterschiede in politischer Kultur, Parteiensystem, sozioökonomischen Strukturen, ehemals Ost- und Westdeutschland und rechter Gewalt aufweist, was Vergleiche desselben Mechanismus in unterschiedlichen Kontexten innerhalb eines Landes erlaubt. Schliesslich gilt die BRD seit Jahrzehnten als konsolidierte Demokratie mit starken rechtsstaatlichen und erinnerungspolitischen Institutionen, sodass der jüngere Anstieg rechter Gewalt und der Erfolg

rechtsextremer Parteien besonders aufschlussreich für Debatten über die Widerstandsfähigkeit etablierter Demokratien ist (Rhein-Fischer und Wójcik 2023).

4.1.2 Die Alternative für Deutschland (AfD)

Das Phänomen der Parteien, mit denen sich diese Arbeit befasst, wird in der Literatur unter verschiedenen Bezeichnungen diskutiert. So gibt es zahlreiche Terminologien wie zum Beispiel rechtspopulistisch, rechtsradikal, rechtsextrem, rechtsextremistisch, neonazistisch oder faschistisch. In dieser Arbeit wird der Begriff „rechtsextrem“ verwendet, da er im deutschsprachigen Kontext am treffendsten erscheint und zentrale Merkmale dieser Parteienfamilie wie Autoritarismus, Nationalismus und die Ablehnung der liberalen Demokratie explizit benennt, während andere Begriffe diese Dimensionen eher entschärfen oder historisch konnotiert sind (Salzborn 2018).

Die AfD wurde 2013 als eine eurokritische Partei in Reaktion auf die Rettungspakete für Griechenland gegründet. Im Jahr 2013 hatte die Partei rund 10'000 Mitglieder. Die meisten dieser frühen Mitglieder traten von der CDU oder FDP zur AfD über (Decker und Bundeszentrale für politische Bildung 2022). Zu Beginn war die ideologische Ausrichtung der Partei liberal-konservativ, marktwirtschaftlich orientiert und anti-Euro. Ab März 2015, nach der Erfurter Resolution, ein rechtsextremes Manifest der Parteibasis, verschob sich ihr Profil aber zunehmend nach rechts mit verstärkt xenophober Haltung. Wenige Monate später wurde die vorherige Parteiführung abgesetzt und trat dann anschliessend aus der Partei aus (Arzheimer und Berning 2019). Die Position der Partei hat sich ab der verstärkten Zuwanderung von Schutzsuchenden im Jahr 2015 endgültig von einer euroskeptischen Partei zu einer rechtsextremen-, nationalistischen- und anti-migrations Partei gewandelt (Franz u. a. 2017). 2017 zog die AfD als stärkste Oppositionsfraktion in den Bundestag ein. Ab 2018 gewannen die völkisch-rechtsextremen Kräfte zunehmend an Einfluss bis dann 2022 Jörg Meuthen, der letzte prominente Vertreter des „moderaten“ Flügels, die Partei verliess (Decker und Bundeszentrale für politische Bildung 2022). Die AfD eignet sich aus mehreren Gründen gut, um in dieser Arbeit den Mechanismus der diskursiven Normalisierung zu untersuchen. Erstens verbindet sie ein rechtsextremes Profil mit einer Verankerung im parlamentarischen System und bringt somit ein vormals randständiges Profil in den politischen Mainstream und kann damit gesellschaftliche Normen verschieben. Zweitens weist die AfD eine regionale Heterogenität auf zwischen den einzelnen Bundesländern sowie Ost/West (Franz u. a. 2017). Drittens ist die AfD im deutschen Kontext stark mit Debatten über rechtsextreme Einstellungen und Gewalt verknüpft.

4.1.3 Die Jahre 2015 bis 2019

Der Analysezeitraum umfasst die Jahre 2015 bis 2019. Diese Periode deckt die Phase ab, in der die AfD immer mehr an Relevanz gewann und in mehreren Bundesländern wie auch auf Bundesebene signifikante Resultate erzielte. Dadurch eignet sich der Zeitraum, um die Signalwirkung von Wahlergebnissen auf rechtsextreme Gewalt zu untersuchen.

Gleichzeitig ermöglicht die gewählte Zeitspanne die Analyse mehrerer Wahlereignisse in unterschiedlichen regionalen Kontexten, wodurch Variation sowohl über die Zeit als auch zwischen Kreisen entsteht. Diese Variation ist zentral für die Identifikation des Zusammenhangs zwischen AfD-Wahlerfolgen und Veränderungen rechtsextremer Delikte.

Der Analysezeitraum ist zudem durch die Verfügbarkeit der zugrundeliegenden Daten begrenzt.

4.2 Datenquellen

4.2.1 Daten Hate Crime

Die abhängige Variable dieser Arbeit basiert auf einem fein aufgelösten Datensatz zu fremdenfeindlichen Hate Crime in Deutschland. Die Daten stammen aus der Studie von Riaz et al., die detaillierte, geokodierte Informationen zu über 9.400 xenophoben Hate Crime-Ereignissen im Zeitraum von Januar 2015 bis März 2019 zusammenstellt. Die Erhebung dieser Daten erfolgt nicht über standardisierte Polizeistatistiken, sondern über parlamentarische Anfragen der Partei Die Linke an die Bundesregierung. Auf dieser Grundlage werden durch staatliche Stellen umfassende Listen einzelner Vorfälle bereitgestellt, die Informationen zu Datum, Ort und Art des Delikts enthalte. Der Datensatz erfasst damit alle offiziell registrierten Hate Crime-Vorfälle auf Ereignisebene und erlaubt eine präzise Zuordnung zu spezifischen Orten und Zeitpunkten. Inhaltlich umfasst die Variable ein breites Spektrum an Delikten, darunter Hassrede, Sachbeschädigung, Körperverletzung sowie schwerere Gewalttaten bis hin zu Tötungsdelikten. Ein zentraler Vorteil dieser Daten liegt in ihrer hohen zeitlichen und räumlichen Granularität, die es ermöglicht, kurzfristige Dynamiken und lokale Reaktionen auf politische oder gesellschaftliche Ereignisse zu analysieren. Gleichzeitig ist zu berücksichtigen, dass die Daten auf offiziell klassifizierten Hate Crimes beruhen und somit potenziell von Untererfassung betroffen sind. Die tatsächliche Anzahl von Hate Crimes dürfte daher höher liegen als in den vorliegenden Daten abgebildet wird. Zur Validierung der Datenqualität zeigen Riaz et al. (2020), dass die erfassten Ereignisse stark mit alternativen Datensätzen aus zivilgesellschaftlichen Quellen korrelieren, was auf eine hohe Reliabilität der Messung hindeutet (Riaz u. a. 2020).

4.2.2 Wahldaten

Die Wahldaten stammen aus amtlichen Ergebnissen von Bundestags- und Landtagswahlen und liegen auf Kreisebene vor. Für jede Wahl werden sowohl die Stimmenanteile der Parteien als auch deren Veränderung gegenüber der vorherigen Wahl erfasst. Im Datensatz sind diese Wahlergebnisse als zeitvariable Grössen integriert, die sich ausschliesslich in Wahlmonaten verändern und zwischen den Wahlen konstant bleiben. Dadurch entsteht eine stufenförmige Zeitstruktur, in der Wahlereignisse indirekt über Veränderungen im Stimmenanteil identifiziert werden können.

Im Zentrum der Analyse steht der Stimmenanteil der Alternative für Deutschland (AfD), der sowohl auf Kreis- als auch auf Landesebene vorliegt. Diese Variablen werden nicht direkt als kontinuierliche Zeitreihe interpretiert, sondern dienen zur Identifikation von Wahlzeitpunkten sowie zur Messung der politischen Signalstärke. Konkret wird ein Wahlereignis dann definiert, wenn sich der AfD-Stimmenanteil im Vergleich zum Vormonat verändert. Auf dieser Basis wird eine Event-Variable konstruiert, die den Zeitpunkt einer Wahl markiert. Zusätzlich wird eine verzögerte Post-Wahl-Variable gebildet, die den Monat nach einer Wahl identifiziert und den theoretisch relevanten Zeitraum für mögliche Effekte auf Hate Crime darstellt.

Diese Operationalisierung erlaubt es, Wahlen als exogene politische Ereignisse zu interpretieren und kurzfristige Veränderungen im Anschluss an Wahlergebnisse empirisch zu untersuchen.

4.2.3 Struktur- und Kontrolldaten

Zusätzlich werden sozioökonomische Strukturindikatoren auf Kreisebene in die Analyse einbezogen. Diese umfassen insbesondere die Arbeitslosenquote, den Anteil der ausländischen Bevölkerung, den Anteil von Personen im SGB-II-Bezug sowie das durchschnittliche Haushaltseinkommen. Die Daten stammen aus amtlichen statistischen Quellen und werden auf Kreisebene erhoben. Diese Variablen dienen der Kontrolle zentraler alternativer Erklärungsansätze, insbesondere ökonomischer Unsicherheit und demografischer Struktur, die in der Literatur als wichtige Determinanten von Hate Crime identifiziert werden.

4.3 Variablen und Operationalisierung

4.3.1 Abhängige Variable

Die abhängige Variable misst das Ausmass fremdenfeindlicher Hate Crime auf Kreisebene. Ausgangspunkt sind ereignisbasierte Daten zu einzelnen Delikten, die auf Monatsebene aggregiert werden. Für jeden Kreis und Monat wird die Gesamtzahl der registrierten Hate Crimes berechnet. Um Unterschiede in der Bevölkerungsgrösse zu berücksichtigen, wird zusätzlich eine Rate pro 100'000 Einwohner*innen gebildet. Die Verwendung einer Rate reduziert Verzerrung

durch unterschiedliche Bevölkerungsgrößen und erlaubt eine Interpretation der Ergebnisse in relativen statt absoluten Größen.

4.3.2 Zentrale unabhängige Variablen

Die zentrale unabhängige Variable ist der Stimmenanteil der AfD auf Kreisebene. Dieser wird aus amtlichen Wahlergebnissen abgeleitet und liegt im Datensatz als Zeitvariable Grösse vor, die sich ausschliesslich im Wahlmonat verändert und zwischen Wahlen konstant bleibt. Der Stimmenanteil wird dabei als Mass für die Stärke des politischen Signals interpretiert, das durch Wahlergebnisse erzeugt wird.

4.3.3 Operationalisierung der Wahlergebnisse

Wahlereignisse werden indirekt über Veränderungen im AfD-Stimmenanteil identifiziert. Eine Wahl liegt genau dann vor, wenn sich der Stimmenanteil im Vergleich zum Vormonat verändert. Auf dieser Grundlage wird eine binäre Event-Variable konstruiert, die den Zeitpunkt einer Wahl markiert. Zusätzlich wird eine verzögerte Post-Wahl-Variable definiert, die den Monat nach einer Wahl identifiziert und den zentralen Zeitraum für potenzielle Effekte auf Hate Crime abbildet. Zur Analyse der Signalwirkung von Wahlergebnissen wird der AfD-Stimmenanteil mit der Post-Wahl-Variable interagiert. Diese Interaktion ermöglicht es, zu untersuchen, ob sich mögliche Effekte in Abhängigkeit von der Stärke des Wahlergebnisses unterscheiden. Diese Spezifikation entspricht der theoretischen Annahme, dass Wahlergebnisse als soziale Signale wirken, deren Effekte nicht unmittelbar, sondern mit zeitlicher Verzögerung auftreten.

4.3.4 Kontrollvariablen

Zur Kontrolle alternativer Erklärungsfaktoren werden mehrere sozioökonomische Variablen in die Analyse einbezogen. Diese umfassen insbesondere die Arbeitslosenquote, den Anteil der ausländischen Bevölkerung, den Anteil von Personen im SGB-II-Bezug sowie das durchschnittliche Haushaltseinkommen.

Die Variablen liegen auf Kreisebene vor und werden an die monatliche Struktur des Paneldatensatzes angepasst. Die Aggregation erfolgt konsistent zur Bildung der monatlichen Panelstruktur, indem kontinuierliche Variablen als Durchschnitt innerhalb eines Monats berechnet werden. Dadurch wird für jede Beobachtung (Kreis x Monat) ein konsistenter Satz an Kontrollvariablen gebildet.

Die Einbeziehung dieser Variablen ermöglicht es, den geschätzten Effekt von Wahlergebnissen von parallelen sozioökonomischen Entwicklungen zu trennen und reduziert das Risiko von omitted variable bias.

4.4 Analysestrategie

Die empirische Analyse untersucht, ob Wahlerfolge der AfD mit kurzfristigen Veränderungen fremdenfeindlicher Hate Crime auf Kreisebene einhergehen. Dafür wird ein eventbasiertes Paneldesign verwendet. Dieses Design ist besonders geeignet, da die theoretische Argumentation nicht primär ein dauerhaft höheres Hate Crime-Level in AfD-starken Kreisen erwartet, sondern eine kurzfristige Veränderung im Anschluss an ein politisch sichtbares Ereignis. Im Zentrum steht daher die Frage, ob sich Hate Crime nach Wahlen verändert und ob diese Veränderung systematisch mit der Stärke der AfD-Wahlergebnissen zusammenhängt.

Die Analyse basiert auf einem monatlichen Panel auf Kreisebene. Die ursprünglichen Tagesdaten werden auf Monatsebene aggregiert, weil der theoretisch erwartete Mechanismus nicht auf tagesgenaue Reaktionen, sondern auf kurzfristige politische Signalwirkungen nach Wahlergebnissen abzielt. Diese Aggregation reduziert zugleich die hohe Zahl an Nullbeobachtungen auf Tagesebene und macht die Schätzung stabiler. In der vorbereiteten Analyse wurde entsprechend ein Panel mit 400 Landkreisen und 50 Monaten konstruiert, wobei Hate Crimes monatliche aufsummiert und anschliessend als Rate pro 100'000 Einwohner*innen operationalisiert werden. Die Konstruktion der Post-Wahl-Variable erfolgt über Veränderung im AfD-Stimmenanteil, da sich die Wahldaten zwischen Wahlen konstant verhalten und nur bei neuen Wahlergebnissen aktualisiert werden.

4.4.1 Hauptmodell: Eventbasiertes lineares Fixed-Effects-Modell

Das zentrale Modell der Arbeit ist ein lineares Fixed-Effects-Panelmodell mit Kreis- und Monats-Fixed-Effects. Als abhängige Variable wird die Hate Crime-Rate pro 100'000 Einwohner*innen verwendet. Das Modell schätzt, ob sich die Hate Crime-Rate im Monat nach einer Wahl verändert und ob diese Veränderung vom AfD-Stimmenanteil im jeweiligen Kreis abhängt.

Das Modell sieht wie folgt aus:

$$Y_{it} = \beta_1 \text{Post}_{it} + \beta_2 \text{AfDShare}_{it} + \beta_3 (\text{Post}_{it} \times \text{AfDShare}_{it}) + \alpha_i + \lambda_t + \varepsilon_{it}$$

Dabei bezeichnet Y_{it} die Hate Crime-Rate im Kreis i im Monat t . Post_{it} ist eine Dummy-Variable, die den Monat nach einer Wahl markiert. AfDShare_{it} bezeichnet den AfD-Stimmenanteil im jeweiligen Kreis. Der Interaktionsterm $\text{Post}_{it} \times \text{AfDShare}_{it}$ misst, ob sich Hate Crime nach einer Wahl abhängig von der Stärke des AfD-Ergebnisses verändert. α_i steht für Kreis-Fixed-Effects, λ_t für Monats-Fixed-Effects und ε_{it} für den Fehlerterm.

Der Zentrale Parameter ist β_3 . Ein positiver und statistisch signifikanter Wert würde darauf hindeuten, dass Hate Crime im Monat nach einer Wahl insbesondere dort zunimmt, wo die AfD stärker abschneidet. Dies wäre mit der theoretischen Erwartung vereinbar, dass Wahlergebnisse

als politisches Signal wirken und die Hemmschwelle für fremdenfeindliche Handlungen senken. Ein nicht-signifikanter Interaktionseffekt würde dagegen bedeuten, dass sich Hate Crime nach Wahlen nicht systematisch in Abhängigkeit von AfD-Ergebnis verändert.

Die Wahl dieses Modells folgt zwei Überlegungen. Erstens entspricht es der theoretischen Hypothese, weil es den kurzfristigen Post-Wahl-Effekt in Abhängigkeit von der Signalstärke des AfD-Ergebnisses modelliert. Zweitens trifft das lineare FE Modell im Vergleich zu nichtlinearen Zählmodellen weniger starke Verteilungsannahmen und ist daher als Hauptmodell transparent interpretierbar. Alternative Modelle werden nicht als Ersatz, sondern als Robustheitsprüfung verwendet.

4.4.2 Identifikationslogik

Die Identifikation beruht auf Variation innerhalb von Kreisen über die Zeit. Kreis-Fixed-Effects kontrollieren für alle zeitinvarianten Unterschiede zwischen Kreisen. Dazu gehören zum Beispiel langfristige politische Kultur, historische Unterschiede zwischen Ost- und Westdeutschland, stabile regionale Gewaltmilieus, Urbanität oder langfristige demografische Strukturen. Monats-Fixed-Effects kontrollieren zusätzlich für zeitliche Schocks, die alle Kreise gleichzeitig betreffen wie zum Beispiel bundesweite politische Ereignisse, mediale Aufmerksamkeit oder saisonale Muster von Hate Crime.

Damit vergleicht das Modell nicht einfach AfD-starke mit AfD -schwachen Kreisen, sondern untersucht, ob sich innerhalb desselben Kreises nach einer Wahl eine Veränderung zeigt, die systematisch mit dem AfD-Ergebnis zusammenhängt. Diese ist insofern wichtig, da AfD-starke Kreise sich strukturell von anderen Kreisen unterscheiden können. Durch die FE-Struktur werden solche stabilen Unterschiede aus der Schätzung herausgerechnet.

Die Interpretation bleibt jedoch vorsichtig, denn das Modell identifiziert keinen voll kausalen Effekt im strengen experimentellen Sinne. Es reduziert jedoch zentrale Formen unbeobachteter Heterogenität und nähert sich der theoretischen Frage an, ob Wahlergebnisse kurzfristige Veränderungen in Hate Crime auslösen. Entscheidend ist deshalb nicht nur die statistische Signifikanz einzelner Koeffizienten, sondern auch deren Stabilität über unterschiedliche Spezifikationen hinweg.

4.4.3 Landtagswahlen und Bundestagswahlen

Die Analyse unterscheidet zwischen Landtagswahlen und Bundestagswahlen. Diese Unterscheidung ist methodisch relevant, weil beide Wahltypen unterschiedliche Formen politischer Signalwirkung erzeugen.

Landtagswahlen finden nicht gleichzeitig in allen Bundesländern statt. Dadurch entsteht zeitliche Variation zwischen den Kreisen. Für die Identifikation ist dies vorteilhaft, weil unterschiedliche

Kreise zu unterschiedliche Zeitpunkten Wahlereignisse erleben. Die Landtagswahlmodelle bilden deshalb den wichtigsten Teil der eventbasierten Analyse.

Bundestagswahlen sind dagegen nationale Ereignisse und finden für alle Kreise gleichzeitig statt. Dadurch wird der allgemeine Post-Wahl-Effekt bei gleichzeitiger Aufnahme von Monats-Fixed-Effects teilweise oder vollständig durch diese Zeit-Fixed-Effects absorbiert. Für Bundestagswahlen kann daher nicht der allgemeine Effekt der Wahl selbst identifiziert werden, sondern vor allem die heterogene Wirkung in Abhängigkeit vom AfD-Stimmenanteil.

Diese Unterscheidung wird auch in der Interpretation berücksichtigt. Landtagswahlen dienen als primärer Test des eventbasierten Mechanismus, während Bundestagswahlen ergänzend analysiert werden, um zu prüfen, ob sich ähnliche Muster bei einem national sichtbaren Wahlsignal zeigen.

4.4.4 Erweiterung um Kontrollvariablen

Das Basismodell wird schrittweise um sozioökonomische Kontrollvariablen erweitert. Dazu gehören Arbeitslosenquote, Ausländer*innenanteil und SGB-II-Quote. Diese Variablen erfassen alternative Erklärungsfaktoren, die in der Literatur mit Hate Crime in Verbindung gebracht werden. Die Arbeitslosenquote und die SGB-II-Quote erfassen ökonomische Unsicherheit. Der Ausländer*innenanteil kontrolliert für demografische Zusammensetzung und potenziellen Kontakt- oder Konfliktstrukturen zwischen Gruppen.

Die entsprechende Erweiterung der Gleichung lautet:

$$Y_{\{it\}} = \beta_1 \text{Post}_{\{it\}} + \beta_2 \text{AfDShare}_{\{it\}} + \beta_3 (\text{Post}_{\{it\}} \times \text{AfDShare}_{\{it\}}) + \gamma X_{\{it\}} + \alpha_i + \lambda_t + \varepsilon_{\{it\}}$$

$X_{\{it\}}$ bezeichnet dabei den Vektor zeitvariierender Kontrollvariablen. Der Parameter γ erfasst deren Zusammenhang mit Hate Crime.

4.4.5 Event-Study-Spezifikation

Neben dem Hauptmodell wird eine Event-Study-Spezifikation geschätzt. Diese erweitert das Design, indem nicht nur der Monat nach der Wahl betrachtet wird, sondern zwei Monate vor und drei Monate nach der Wahl. Dadurch kann überprüft werden, ob sich Hate Crime vor der Wahl systematisch verändert oder ob mögliche Effekte erst nach dem Wahlergebnis auftreten. Die Analyse verwendet also *pre2*, *pre1*, *post1*, *post2* und *post3* als relative Zeitindikatoren.

Die Event-Study-Spezifikation lautet:

$$Y_{it} = \sum_{k \neq 0} \beta_k \text{EventTime}_{it}^k + \sum_{k \neq 0} \delta_k (\text{EventTime}_{it}^k \times \text{AfDShare}_{it}) + \alpha_i + \lambda_t + \epsilon_{it}$$

Dabei bezeichnet EventTime_{it}^k die relative Position eines Monats zur Wahl. Der Wahlmonat selbst dient als Referenzkategorie. Die Koeffizienten δ_k zeigen, ob sich Hate Crime in den jeweiligen Monaten vor oder nach der Wahl abhängig vom AfD-Stimmenanteil verändert.

Diese Spezifikation erfüllt zwei Funktionen. Erstens dient sie als Test auf Pre-Trends. Wenn bereits vor der Wahl systematische Unterschiede auftreten, spricht dies gegen eine klare kausale Interpretation eines Post-Wahl-Effekts. Zweitens zeigt sie, ob ein möglicher Effekt nur unmittelbar nach der Wahl auftritt oder über mehrere Monate anhält.

4.4.6 Bedingte Effekte bei niedrigem vorherigem AfD Niveau

Zur Prüfung von H2 wird zusätzlich ein erweitertes Fixed-Effects-Modell geschätzt, das mögliche Unterschiede zwischen Kreisen mit niedrigem und höherem vorherigem AfD-Stimmenanteil berücksichtigt. Hintergrund dieser Spezifikation ist die theoretische Annahme, dass mögliche Normalisierungseffekte insbesondere dort auftreten könnten, wo rechtsextreme Parteien zuvor weniger etabliert waren und Wahlerfolge deshalb eine stärkere Signalwirkung entfalten.

Dafür wird zunächst für jeden Kreis der erste positive AfD-Stimmenanteil bei Landtagswahlen als Ausgangsniveau bestimmt. Anschliessend werden die Kreise anhand eines Median-Splits in Kreise mit niedrigem und höherem vorherigem AfD-Niveau eingeteilt. Auf dieser Grundlage wird ein erweitertes Modell mit einem Dreifach-Interaktionsterm zwischen Post-Wahl-Periode, AfD-Stimmenanteil und niedrigem Ausgangsniveau geschätzt.

Die entsprechende Spezifikation lautet:

$$\begin{aligned} Y_{it} = & \beta_1 \text{Post}_{it} + \beta_2 \text{AfDShare}_{it} + \beta_3 (\text{Post}_{it} \times \text{AfDShare}_{it}) \\ & + \beta_4 (\text{Post}_{it} \times \text{LowBaseline}_i) + \beta_5 (\text{AfDShare}_{it} \times \text{LowBaseline}_i) \\ & + \beta_6 (\text{Post}_{it} \times \text{AfDShare}_{it} \times \text{LowBaseline}_i) + \gamma X_{it} + \alpha_i + \lambda_t + \epsilon_{it} \end{aligned}$$

Der zentrale Parameter ist dabei der Dreifach-Interaktionsterm β_6 . Ein positiver und statistisch signifikanter Koeffizient würde darauf hindeuten, dass der Zusammenhang zwischen AfD-Wahlerfolgen und Hate Crime insbesondere in Kreisen mit niedrigem vorherigem AfD-Niveau stärker ausgeprägt ist.

4.4.7 Alternative Operationalisierung von Wahlerfolg

Zusätzlich wird Wahlerfolg nicht nur über den AfD-Stimmenanteil, sondern auch über die Veränderung des AfD-Ergebnisses gegenüber der vorherigen Wahl operationalisiert. Diese Spezifikation ist theoretisch besonders relevant, weil der Mechanismus der Signalwirkung nicht

nur vom Niveau der Unterstützung abhängen könnte, sondern auch von Zugewinnen. Ein starker Stimmenzuwachs kann als überraschendes oder besonders sichtbares Signal interpretiert werden.

Die entsprechende Spezifikation ersetzt $AfDShare_{it}$ durch $AfDDiff_{it}$

$$Y_{it} = \beta_1 Post_{it} + \beta_2 AfDDiff_{it} + \beta_3 (Post_{it} \times AfDDiff_{it}) + \gamma X_{it} + \alpha_i + \lambda_t + \epsilon_{it}$$

Da die Veränderung des Wahlergebnisses in der FE-Struktur teilweise absorbiert werden kann, liegt auch hier der Fokus auf dem Interaktionsterm mit der Post-Wahl—Variable. Diese Spezifikation prüft, ob Hate Crime nach einer Wahl stärker zunimmt, wenn die AfD im jeweiligen Kreis besonders stark hinzugewonnen hat.

4.4.8 Robustheitsanalyse

Da Hate Crime ein seltenes Ereignis ist und es deshalb zu Zero-Inflation kommt, werden zusätzlich alternative Modelltypen geschätzt. Dies ist methodisch wichtig, weil lineare Modelle zwar leichter interpretierbar sind, aber die Zähldatenstruktur der abhängigen Variable nur begrenzt abbilden.

Erstens werden Fixed-Effects-Poisson-Modelle geschätzt. Diese verwenden die absolute Anzahl der Hate Crime-Ereignisse als abhängige Variable und berücksichtigen Unterschiede in der Bevölkerungsgröße über einen Offset der logarithmierten Bevölkerung. Dadurch wird effektiv eine Ereignisrate modelliert, ohne die Zähldatenstruktur aufzugeben. Die Poisson-Spezifikation eignet sich daher als zentrale Robustheitsprüfung für die linearen Modelle.

Zweitens werden Negative-Binomial-Modelle geschätzt. Diese sind flexibler als Poisson-Modelle, weil sie Overdispersion zulassen, also den Fall, dass die Varianz der abhängigen Variable grösser ist als ihr Erwartungswert. Dies ist bei Hate Crime-Daten plausibel, da einzelne Kreise oder Monate deutlich mehr Ereignisse aufweisen können als andere. Gleichzeitig sind Fixed-Effects-Negative-Binomial-Modelle bei kurzer Zeitdimension und vielen Einheiten methodisch anspruchsvoll, weshalb ihre Ergebnisse als Sensitivitätsprüfung und nicht als Hauptmodell interpretiert werden.

5.0 Resultate

5.1 Deskriptive Ergebnisse

Tabelle 1 zeigt die deskriptiven Statistiken der zentralen Variablen. Die durchschnittliche Anzahl fremdenfeindlicher Hate Crimes pro Kreis-Monat liegt bei 0.46 Ereignissen, wobei die Werte zwischen 0 und 61 Delikten variieren. Auch die Hate Crime-Rate pro 100'000 Einwohner*innen weist eine hohe Streuung auf. Der durchschnittliche AfD-Stimmenanteil bei Landtagswahlen liegt bei rund 6 Prozent, erreicht in einzelnen Kreisen jedoch Werte von fast 30 Prozent.

Variable	Mean	SD	Min	Max
hatecrimes	0.46	1.38	0.00	61.00
hatecrime_rate	0.24	0.62	0.00	21.62
afd_share_ltw	5.96	6.76	0.00	29.44
arbeitslosenquote	5.45	2.53	1.29	15.12
auslaenderanteil	9.81	5.12	1.87	36.56
sgb2_quote	7.91	4.42	1.09	24.88

Tabelle 1: Deskriptive Statistiken der zentralen Variablen

Ein zentrales Merkmal des Datensatzes ist die hohe Anzahl an Nullwerten. Wie Tabelle 2 zeigt, enthalten rund 74 Prozent aller Kreis-Monate kein registriertes Hate Crime-Ereignis. Dies deutet auf eine starke Konzentration von Nullwerten hin.

Anteil_Nullwerte	Beobachtungen
0.743	20400

Tabelle 2: Anteil der Kreis-Monate ohne Hate Crime-Ereignis

Abbildung 2 zeigt zusätzlich die aggregierte monatliche Entwicklung fremdenfeindlicher Hate Crimes zwischen 2015 und 2019. Besonders auffällig ist ein starker Anstieg der registrierten Delikte Anfang 2016, nachdem bereits im Verlauf des Jahres 2015 eine deutliche Zunahme sichtbar wird. In den darauffolgenden Jahren gehen die Fallzahlen wieder zurück, verbleiben jedoch über dem Niveau zu Beginn des Untersuchungszeitraums. Insgesamt verdeutlicht die Abbildung, dass fremdenfeindliche Hate Crimes im Untersuchungszeitraum erheblichen zeitlichen Schwankungen unterliegen und nicht konstant über die Zeit verteilt sind. Ein möglicher Erklärungsfaktor für den starken Anstieg der Fallzahlen in den Jahren 2015 und 2016 ist die sogenannte Flüchtlingskrise sowie die damit verbundene gesellschaftliche und politische Polarisierung.



Abbildung 2: Monatliche Entwicklung fremdenfeindlicher Hate Crimes

5.2 Ergebnis Eventbasierte Fixed-Effects-Modelle

5.2.1 Landtagswahlen

Tabelle 3 zeigt die Ergebnisse der eventbasierten Fixed-Effects-Modelle für Landtagswahlen. Im Zentrum der Analyse steht der Interaktionsterm zwischen der Post-Wahl-Variable und dem AfD-Stimmenanteil. Dieser misst, ob sich fremdenfeindliche Hate Crimes im Monat nach einer Wahl systematisch in Abhängigkeit von der Stärke des AfD-Ergebnisses verändern.

Die Ergebnisse zeigen keinen statistisch signifikanten positiven Zusammenhang zwischen dem AfD-Stimmenanteil und der Hate Crime-Rate im Zeitraum nach Landtagswahlen. Der Interaktionsterm bleibt über die verschiedenen Spezifikationen hinweg klein und statistisch insignifikant. Dies deutet darauf hin, dass Kreise mit höheren AfD-Ergebnissen nach Landtagswahlen keine systematisch stärkere Zunahme fremdenfeindlicher Hate Crimes aufweisen als Kreise mit niedrigeren AfD-Ergebnissen.

Auch die Kontrollvariablen verändern die Ergebnisse nur geringfügig. Die Koeffizienten bleiben in ihrer Richtung und Größenordnung weitgehend stabil, was darauf hindeutet, dass die Resultate nicht primär durch parallele sozioökonomische Entwicklungen erklärt werden. Insgesamt liefern die Modelle damit keine starke Evidenz für die Hypothese, dass Wahlerfolge der AfD kurzfristig zu einem Anstieg fremdenfeindlicher Hate Crimes auf Kreisebene führen. Auffällig ist dabei der konsistent negative Haupteffekt der Post-Wahl-Variable, der jedoch statistisch insignifikant bleibt.

Eventbasierte Fixed-Effects-Modelle fuer Landtagswahlen				
	Modell 1	Modell 2	Modell 3	Modell 4
Post-Wahl	-0.068 (0.066)	-0.065 (0.066)	-0.062 (0.066)	-0.061 (0.066)
AfD-Stimmenanteil	0.000 (0.001)	0.000 (0.001)	0.000 (0.001)	0.000 (0.001)
Post x AfD	0.005 (0.007)	0.005 (0.007)	0.005 (0.007)	0.004 (0.007)
Arbeitslosenquote		-0.035 (0.019)	-0.043* (0.019)	-0.058 (0.030)
Auslaenderanteil			0.042** (0.015)	0.038** (0.014)
SGB-II-Quote				0.016 (0.023)
Num. obs.	20000	20000	20000	20000
Num. groups: county_id	400	400	400	400
Num. groups: month	50	50	50	50
R ² (full model)	0.208	0.209	0.209	0.209
R ² (proj model)	0.000	0.000	0.001	0.001

*** p < 0.001; ** p < 0.01; * p < 0.05

Tabelle 3: Eventbasierte Fixed-Effects-Modelle für Landtagswahlen

5.2.2 Bundestagswahlen

Tabelle 4 zeigt die Ergebnisse der eventbasierten Fixed-Effects-Modelle für Bundestagswahlen. Im Unterschied zu Landtagswahlen finden Bundestagswahlen zeitgleich in allen Kreisen statt. Dadurch wird der allgemeine Post-Wahl-Effekt weitgehend durch die Monats-Fixed-Effects absorbiert, weshalb die Interpretation primär auf dem Interaktionsterm zwischen Post-Wahl-Periode und AfD-Stimmenanteil basiert.

Die Ergebnisse zeigen auch für Bundestagswahlen keinen robusten statistisch signifikanten Zusammenhang zwischen AfD-Wahlergebnissen und einer kurzfristigen Veränderung fremdenfeindlicher Hate Crimes. Zwar weisen einzelne Spezifikationen teilweise positive Koeffizienten auf, diese bleiben jedoch statistisch insignifikant und zeigen keine konsistente Stabilität über verschiedene Modellspezifikationen hinweg.

Auch nach Einbezug der Kontrollvariablen verändert sich das Muster der Ergebnisse nur geringfügig. Insgesamt liefern die Modelle damit keine starke Evidenz dafür, dass höhere AfD-Ergebnisse bei Bundestagswahlen kurzfristig mit einem Anstieg fremdenfeindlicher Hate Crimes auf Kreisebene verbunden sind.

Eventbasierte Fixed-Effects-Modelle fuer Bundestagswahlen				
	Modell 1	Modell 2	Modell 3	Modell 4
AfD-Stimmenanteil	-0.003 (0.003)	-0.006* (0.003)	-0.006* (0.003)	-0.006 (0.003)
Post x AfD	-0.004 (0.006)	-0.003 (0.005)	-0.003 (0.006)	-0.003 (0.006)
Arbeitslosenquote		-0.054** (0.020)	-0.061** (0.020)	-0.065* (0.030)
Auslaenderanteil			0.041** (0.015)	0.040** (0.014)
SGB-II-Quote				0.005 (0.023)
Num. obs.	20000	20000	20000	20000
Num. groups: county_id	400	400	400	400
Num. groups: month	50	50	50	50
R ² (full model)	0.208	0.209	0.210	0.210
R ² (proj model)	0.000	0.001	0.002	0.002

*** p < 0.001; ** p < 0.01; * p < 0.05

Tabelle 4: Eventbasierte Fixed-Effects-Modelle für Bundestagswahlen

5.2.3 Niedriges vorheriges AfD-Niveau Landtagswahlen

Die Ergebnisse zur Prüfung von H2 zeigen keinen statistisch signifikanten Dreifach-Interaktions-Effekt zwischen Post-Wahl-Periode, AfD-Stimmenanteil und niedrigem vorherigen AfD-Niveau. Damit findet sich keine Evidenz dafür, dass mögliche Effekte von AfD-Wahlerfolgen in Kreisen mit niedrigem vorherigem AfD-Stimmenanteil stärker ausfallen.

5.3 Dynamik der Effekte über mehrere Monate

5.3.1 Landtagswahlen

Tabelle 6 zeigt die Ergebnisse der Event-Study-Spezifikation für Landtagswahlen. Die Interaktionseffekte zwischen den relativen Wahlperioden und dem AfD-Stimmenanteil bleiben über alle Zeitperioden hinweg klein und statistisch insignifikant. Weder vor noch nach der Wahl zeigt sich somit ein systematischer Zusammenhang zwischen höheren AfD-Ergebnissen und Veränderungen der Hate Crime-Rate.

Auch Hinweise auf ausgeprägte Pre-Trends finden sich nicht. Die Interaktionseffekte in den Monaten vor der Wahl unterscheiden sich nicht signifikant von null. Dies spricht dagegen, dass sich Kreise mit hohen AfD-Ergebnissen bereits vor der Wahl systematisch anders entwickeln als andere Kreise.

Insgesamt liefern die Event-Study-Modelle damit keine Evidenz für einen kurzfristigen Anstieg fremdenfeindlicher Hate Crimes nach Landtagswahlen in Kreisen mit höheren AfD-Stimmenanteilen. Zudem zeigen die Ergebnisse keine Hinweise darauf, dass mögliche Effekte mit zeitlicher Verzögerung auftreten oder über mehrere Monate bestehen bleiben.

Event-Study-Modell fuer Landtagswahlen	
	Event-Study LTW
2 Monate vor Wahl	-0.071 (0.044)
AfD-Stimmenanteil	-0.002 (0.002)
1 Monat vor Wahl	-0.124** (0.042)
1 Monat nach Wahl	-0.065 (0.066)
2 Monate nach Wahl	-0.130 (0.113)
3 Monate nach Wahl	-0.117* (0.059)
2 Monate vor Wahl x AfD	-0.018 (0.016)
1 Monat vor Wahl x AfD	0.017 (0.013)
1 Monat nach Wahl x AfD	0.005 (0.007)
2 Monate nach Wahl x AfD	0.012 (0.012)
3 Monate nach Wahl x AfD	0.009 (0.006)
Num. obs.	18400
Num. groups: county_id	400
Num. groups: month	46
R ² (full model)	0.213
R ² (proj model)	0.001

*** p < 0.001; ** p < 0.01; * p < 0.05

Event-Study-Modell fuer Bundestagswahlen	
	Bundestagswahlen
AfD-Stimmenanteil	-0.001 (0.003)
2 Monate vor Wahl x AfD	-0.017 (0.021)
1 Monat vor Wahl x AfD	0.044 (0.032)
1 Monat nach Wahl x AfD	-0.006 (0.006)
2 Monate nach Wahl x AfD	-0.013** (0.005)
3 Monate nach Wahl x AfD	-0.004 (0.005)
Num. obs.	18400
Num. groups: county_id	400
Num. groups: month	46
R ² (full model)	0.213
R ² (proj model)	0.001

*** p < 0.001; ** p < 0.01; * p < 0.05

Tabelle 5: Event-Study-Modell für Bundestagswahlen

Tabelle 6: Event-Study-Modell für Landtagswahlen

5.3.2 Bundestagswahlen

Tabelle 5 zeigt die Ergebnisse der Event-Study-Spezifikation für Bundestagswahlen. Auch hier bleiben die Interaktionseffekte zwischen den relativen Wahlperioden und dem AfD-Stimmenanteil über alle Zeitpunkte hinweg statistisch insignifikant. Es zeigen sich somit keine Hinweise darauf, dass Kreise mit höheren AfD-Ergebnissen nach Bundestagswahlen einen systematischen Anstieg fremdenfeindlicher Hate Crimes aufweisen.

Ebenso finden sich keine konsistenten Hinweise auf Pre-Trends vor der Wahl. Insgesamt bestätigen die Ergebnisse damit die Befunde der vorherigen Modelle und liefern keine Evidenz für einen kurzfristigen Normalisierungseffekt von AfD-Wahlergebnissen auf Hate Crime.

5.4 Alternative Operationalisierung von Wahlerfolg

5.4.1 Zugewinne der AfD

Zusätzlich wird Wahlerfolg nicht nur über den absoluten AfD-Stimmenanteil, sondern auch über die Veränderung des Wahlergebnisses gegenüber der vorherigen Wahl operationalisiert. Diese Spezifikation untersucht, ob insbesondere starke Zugewinne der AfD mit Veränderungen fremdenfeindlicher Hate Crimes verbunden sind.

Die alternative Operationalisierung ist theoretisch relevant, da nicht nur das Niveau der Unterstützung, sondern auch unerwartete oder besonders starke Wahlerfolge als politisches Signal wirken könnten. Entsprechend wird geprüft, ob sich Hate Crime im Zeitraum nach Wahlen systematisch in Abhängigkeit von den Zugewinnen der AfD verändert.

Auch bei dieser Operationalisierung zeigt sich kein statistisch signifikanter Zusammenhang mit fremdenfeindlichen Hate Crimes. Der Interaktionseffekt zwischen Post-Wahl-Periode und Veränderung des AfD-Stimmenanteils bleibt klein und statistisch insignifikant.

5.5 Robustheitsanalyse

5.5.1 Poisson-Modelle

Zur Überprüfung der Robustheit der Ergebnisse werden zusätzlich Fixed-Effects-Poisson-Modelle geschätzt. Diese berücksichtigen die Zählstruktur der abhängigen Variable und eignen sich insbesondere für seltene Ereignisse wie Hate Crime.

Die Ergebnisse der Poisson-Modelle bestätigen die bisherigen Befunde weitgehend. Weder für Landtags- noch für Bundestagswahlen zeigt sich ein statistisch signifikanter Interaktionseffekt zwischen der Post-Wahl-Periode und dem AfD-Stimmenanteil. Damit liefern auch die Poisson-Spezifikationen keine Evidenz dafür, dass höhere AfD-Wahlergebnisse mit einer kurzfristigen Zunahme fremdenfeindlicher Hate Crimes verbunden sind.

5.5.2 Negativ-Binomial-Modelle

Zusätzlich werden Negative-Binomial-Modelle geschätzt, um mögliche Overdispersion in den Hate Crime-Daten zu berücksichtigen. Die Ergebnisse für Landtagswahlen bestätigen erneut die bisherigen Befunde. Der Interaktionseffekt zwischen Post-Wahl-Periode und AfD-Stimmenanteil bleibt positiv, erreicht jedoch keine statistische Signifikanz.

Für Bundestagswahlen treten dagegen Konvergenzprobleme und Hinweise auf Kollinearität auf, weshalb die entsprechenden Koeffizienten nicht zuverlässig interpretierbar sind. Die Ergebnisse der Negative-Binomial-Modelle für Bundestagswahlen werden daher nur eingeschränkt berücksichtigt. Insgesamt liefern jedoch auch die Negative-Binomial-Spezifikationen keine robuste Evidenz für einen kurzfristigen Zusammenhang zwischen AfD-Wahlerfolgen und fremdenfeindlichen Hate Crimes.

5.6 Fazit Analyse

Insgesamt liefern die verschiedenen Modellspezifikationen keine robuste Evidenz dafür, dass Wahlerfolge der AfD kurzfristig mit einer Zunahme fremdenfeindlicher Hate Crimes auf Kreisebene verbunden sind. Weder die eventbasierten Fixed-Effects-Modelle noch die Event-

Study-Spezifikationen zeigen statistisch signifikante Interaktionseffekte zwischen AfD-Wahlergebnissen und der Entwicklung von Hate Crime nach Wahlen.

Dieses Muster bleibt auch bei alternativen Operationalisierungen von Wahlerfolg sowie in den Robustheitsanalysen mit Poisson- und Negative-Binomial-Modellen weitgehend stabil. Die Ergebnisse sprechen damit insgesamt gegen die Hypothese eines kurzfristigen Normalisierungseffekts von AfD-Wahlerfolgen auf fremdenfeindliche Hate Crimes im untersuchten Zeitraum.

6.0 Diskussion

Die Arbeit untersuchte, ob Wahlerfolge der AfD mit einer kurzfristigen Zunahme fremdenfeindlicher Hate Crimes auf Kreisebene verbunden sind. Über die verschiedenen Modellspezifikationen hinweg zeigt sich jedoch keine robuste Evidenz für einen solchen Zusammenhang. Weder die eventbasierten Fixed-Effects-Modelle noch die Event-Study-Spezifikationen liefern statistisch signifikante Hinweise darauf, dass höhere AfD-Wahlergebnisse mit einem kurzfristigen Anstieg fremdenfeindlicher Hate Crimes einhergehen. Auch die zusätzlichen Analysen zu möglichen bedingten Effekten bei niedrigem vorherigem AfD-Niveau zeigen keine signifikanten Ergebnisse. Damit finden sich keine Hinweise darauf, dass mögliche Normalisierungseffekte insbesondere in Kreisen auftreten, in denen rechtsextreme Parteien zuvor weniger etabliert waren.

Die Ergebnisse sprechen somit insgesamt gegen die Annahme eines unmittelbaren kurzfristigen Mobilisierungs- oder Normalisierungseffekts von AfD-Wahlerfolgen auf fremdenfeindliche Hate Crimes im untersuchten Zeitraum. Gleichzeitig bedeutet das Ausbleiben signifikanter Effekte jedoch nicht zwangsläufig, dass politische Wahlerfolge keinen Einfluss auf gesellschaftliche Einstellungen oder Formen gruppenbezogener Menschenfeindlichkeit haben. Vielmehr deuten die Ergebnisse darauf hin, dass mögliche Zusammenhänge komplexer, langfristiger oder stärker kontextabhängig sein könnten als ursprünglich angenommen.

6.1 Mögliche Erklärungen

Eine mögliche Erklärung für die ausbleibenden Effekte liegt in der zeitlichen Dimension des theoretischen Mechanismus. Die vorliegende Arbeit untersucht primär kurzfristige Veränderungen nach Wahlen. Prozesse der politischen und gesellschaftlichen Normalisierung könnten jedoch deutlich langsamer verlaufen und sich nicht unmittelbar innerhalb weniger Monate in registrierten Hate Crimes niederschlagen. Wahlerfolge rechtsextremer Parteien könnten gesellschaftliche Einstellungen, öffentliche Diskurse oder Wahrnehmungen sozialer Akzeptanz schrittweise verändern, ohne dass dies unmittelbar zu einem messbaren Anstieg

fremdenfeindlicher Gewalt führt. Möglich ist daher, dass Normalisierungseffekte eher langfristig wirken und sich erst über längere Zeiträume in Einstellungen, Sprache oder politischen Milieus manifestieren.

Die Ergebnisse dieser Arbeit sprechen somit nicht grundsätzlich gegen die Existenz von Normalisierungseffekten, sondern eher gegen die Annahme eines unmittelbaren kurzfristigen Zusammenhangs zwischen Wahlerfolgen der AfD und Hate Crime auf Kreisebene.

Zudem ist zu berücksichtigen, dass der Untersuchungszeitraum 2015–2019 eine Phase abdeckt, in der die AfD bei Landtagswahlen noch vergleichsweise schwach verankert war. Es ist daher möglich, dass die politischen Signale von AfD-Wahlerfolgen in dieser frühen Phase noch nicht stark genug waren, um messbare kurzfristige Effekte auf Hate Crime auszulösen. Angesichts der seither deutlich gestiegenen Stimmenanteile der AfD, wäre es denkbar, dass Normalisierungseffekte erst ab einem bestimmten Schwellenwert politischer Sichtbarkeit wirksam werden. Eine Untersuchung eines aktuelleren Zeitraums könnte daher zu anderen Ergebnissen führen und bleibt ein wichtiger Ansatzpunkt für zukünftige Forschung.

Ein weiterer Aspekt betrifft die Messung der abhängigen Variable. Die verwendeten Daten erfassen ausschliesslich polizeilich registrierte Hate Crimes und könnten damit systematisch genau jene Verhaltensweisen untererfassen, die durch Normalisierungseffekte am ehesten ausgelöst werden. Wenn Wahlerfolge rechtsextremer Parteien primär niedrigschwelliges Verhalten begünstigen, etwa verbale Fremdenfeindlichkeit, Einschüchterung oder diskriminierende Alltagshandlungen, dann wäre zu erwarten, dass genau diese Delikte besonders selten angezeigt und registriert werden. Das Nullresultat könnte daher zumindest teilweise ein Artefakt der Datenbeschränkung sein. Nicht weil keine Effekte existieren, sondern weil die verwendeten Daten systematisch jene Formen fremdenfeindlichen Verhaltens nicht erfassen, auf die der theoretische Mechanismus am stärksten abzielt. Zukünftige Studien könnten diesem Problem begegnen, indem sie zusätzlich zivilgesellschaftliche Datenquellen oder Umfragedaten zu erlebter Diskriminierung einbeziehen.

Eine weitere mögliche Erklärung besteht darin, dass Wahlerfolge der AfD und fremdenfeindliche Hate Crimes weniger in einem direkten kausalen Verhältnis stehen, sondern vielmehr Ausdruck gemeinsamer gesellschaftlicher und struktureller Entwicklungen sind. Faktoren wie gesellschaftliche Polarisierung, migrationsbezogene Konflikte, wirtschaftliche Unsicherheit oder bestehende rechtsextreme Milieus könnten sowohl höhere AfD-Wahlergebnisse als auch erhöhte Hate Crime-Raten begünstigen. In diesem Fall wären Wahlerfolge der AfD nicht primär Auslöser fremdenfeindlicher Gewalt, sondern vielmehr ein politischer Ausdruck bereits bestehender gesellschaftlicher Spannungen. Dies würde auch erklären, weshalb sich trotz räumlicher

Korrelationen zwischen AfD-Unterstützung und Hate Crime keine klaren kurzfristigen Effekte nach einzelnen Wahlen identifizieren lassen.

Zudem ist möglich, dass potenzielle Effekte von AfD-Wahlerfolgen stark kontextabhängig sind und deshalb im aggregierten Kreisvergleich nur begrenzt sichtbar werden. Mögliche Zusammenhänge könnten sich insbesondere auf bestimmte Regionen, lokale Konfliktsituationen oder spezifische Tätergruppen beschränken. Durch die Aggregation auf Kreisebene werden solche lokalen Dynamiken jedoch teilweise geglättet. Ebenso ist denkbar, dass mögliche Normalisierungseffekte nur unter bestimmten gesellschaftlichen Bedingungen auftreten, etwa bei hoher medialer Aufmerksamkeit, lokalen Mobilisierungsprozessen oder bestehenden rechtsextremen Netzwerken. Die fehlenden durchschnittlichen Effekte im Gesamtsample schliessen daher nicht aus, dass unter spezifischen lokalen Bedingungen durchaus Zusammenhänge zwischen Wahlerfolgen der AfD und Hate Crime bestehen können

Eine weitere mögliche Erklärung besteht darin, dass Wahlerfolge der AfD nicht zwangsläufig zu einer Mobilisierung ausserparlamentarischer Gewalt führen, sondern teilweise auch eine institutionelle Kanalisierung politischer Unzufriedenheit darstellen könnten (Ravndal 2016; Muis und Immerzeel 2017; Koopmans u. a. 2005). Personen mit migrationskritischen oder rechtsextremen Einstellungen erhalten durch Wahlerfolge der AfD eine parlamentarische Repräsentation ihrer Positionen, wodurch politische Partizipation verstärkt innerhalb institutioneller Kanäle statt ausserhalb dieser stattfinden könnte. In diesem Fall würden Wahlerfolge der AfD nicht notwendigerweise die Hemmschwelle für Gewalt senken, sondern könnten unter bestimmten Bedingungen sogar zur Verlagerung politischer Artikulation von informeller oder gewaltsamer Handlung hin zu parlamentarischer Repräsentation beitragen.

6.2 Bedeutung für die Literatur

Die Ergebnisse dieser Arbeit leisten einen Beitrag zur Literatur über rechtsextreme Parteien, politische Normalisierung und fremdenfeindliche Gewalt, indem sie die Annahme eines unmittelbaren kurzfristigen Zusammenhangs zwischen Wahlerfolgen der AfD und Hate Crime empirisch hinterfragen. Während ein Teil der bisherigen Forschung positive Zusammenhänge zwischen rechtsextremer Unterstützung und fremdenfeindlicher Gewalt findet, zeigen die vorliegenden Analysen, dass sich daraus nicht zwangsläufig kurzfristige Veränderungen nach konkreten Wahlereignissen ableiten lassen. Insbesondere Studien wie jene von Rees et al. argumentieren, dass AfD-Unterstützung und rechte Gewalt Teil eines gemeinsamen „Climate of Hate“ seien (Rees u. a. 2019). Die Ergebnisse dieser Arbeit widersprechen solchen Befunden nicht grundsätzlich, relativieren jedoch deren Interpretation. Räumliche Korrelationen zwischen AfD-Unterstützung und Hate Crime bedeuten nicht automatisch, dass Wahlerfolge selbst kurzfristig zu einer Zunahme fremdenfeindlicher Gewalt führen. Vielmehr könnten beide

Phänomene auf gemeinsame gesellschaftliche und strukturelle Ursachen zurückzuführen sein, etwa politische Polarisierung, migrationsbezogene Konflikte oder bestehende rechtsextreme Milieus.

Die Arbeit verdeutlicht damit die Bedeutung der analytischen Unterscheidung zwischen räumlichen Zusammenhängen und zeitlichen Effekten. Viele bestehende Studien analysieren vor allem Unterschiede zwischen Regionen mit unterschiedlich hoher Unterstützung für rechtsextreme Parteien. Die vorliegende Arbeit untersucht dagegen Veränderungen innerhalb derselben Kreise über die Zeit und fokussiert damit stärker auf kurzfristige Dynamiken nach Wahlereignissen. Die Ergebnisse legen nahe, dass sich aus regionalen Zusammenhängen nicht automatisch kurzfristige kausale Effekte ableiten lassen.

Darüber hinaus tragen die Ergebnisse zur Literatur über politische Normalisierung bei. Ein zentraler theoretischer Ansatz dieser Arbeit war die Annahme, dass Wahlerfolge rechtsextremer Parteien als soziale und politische Signale wirken können, die gesellschaftliche Wahrnehmungen von Legitimität und Akzeptanz verändern. Die fehlenden signifikanten Effekte sprechen jedoch gegen die Vorstellung eines unmittelbaren kurzfristigen Normalisierungseffekts auf registrierte Hate Crimes. Gleichzeitig bedeutet dies nicht, dass Prozesse politischer Normalisierung grundsätzlich ausbleiben. Vielmehr deuten die Ergebnisse darauf hin, dass solche Prozesse möglicherweise langsamer, indirekter oder stärker kontextabhängig verlaufen als häufig angenommen.

Dies betrifft insbesondere die Frage nach der zeitlichen Dimension von Normalisierung. Veränderungen gesellschaftlicher Normen, Diskurse oder Wahrnehmungen sozialer Akzeptanz könnten sich über längere Zeiträume entwickeln und sich nicht unmittelbar innerhalb weniger Monate in fremdenfeindlicher Gewalt manifestieren. Die Arbeit spricht damit eher gegen kurzfristige Mobilisierungseffekte nach Wahlen als gegen die Möglichkeit langfristiger kultureller oder diskursiver Verschiebungen.

Zudem zeigen die Ergebnisse, dass mögliche Effekte rechtsextremer Wahlerfolge nicht notwendigerweise generalisiert über alle Regionen hinweg auftreten müssen. Die zusätzlichen Analysen zu Kreisen mit niedrigem vorherigem AfD-Niveau liefern ebenfalls keine signifikanten Effekte, schliessen jedoch kontextabhängige Dynamiken nicht vollständig aus. Möglich ist weiterhin, dass politische Signalwirkungen nur unter spezifischen lokalen Bedingungen sichtbar werden, etwa in Verbindung mit bestehenden rechtsextremen Netzwerken, lokaler Mobilisierung oder hoher medialer Aufmerksamkeit.

Schliesslich unterstreicht die Arbeit auch die theoretische Relevanz von Nullresultaten in der Forschung zu politischer Gewalt und Normalisierung. Gerade weil ein plausibler theoretischer Mechanismus, hoch aufgelöste Daten und mehrere methodische Spezifikationen verwendet

wurden, liefern die ausbleibenden Effekte wichtige Hinweise auf mögliche Grenzen kurzfristiger Signal- und Mobilisierungseffekte. Die Ergebnisse sprechen damit für eine vorsichtigere Interpretation direkter kausaler Zusammenhänge zwischen Wahlerfolgen rechtsextremer Parteien und fremdenfeindlicher Gewalt.

6.3 Ausblick für zukünftige Forschung

Ein möglicher Ansatzpunkt für zukünftige Forschung besteht darin, stärker zwischen unterschiedlichen Formen rechtsextremer Mobilisierung zu unterscheiden. Während die vorliegende Arbeit Hate Crime untersucht, könnten Wahlerfolge rechtsextremer Parteien kurzfristige Effekte eher auf andere Formen politischer Artikulation haben, etwa auf Demonstrationen, Online-Hassrede oder niedrigschwellige Formen öffentlicher Fremdenfeindlichkeit. Zukünftige Studien könnten daher analysieren, ob signalbasierte Normalisierungseffekte in anderen Formen politischen oder gesellschaftlichen Verhaltens deutlicher sichtbar werden.

Darüber hinaus könnte zukünftige Forschung stärker die lokale Kontextabhängigkeit solcher Effekte untersuchen. Möglicherweise hängen potenzielle Normalisierungseffekte weniger von Wahlergebnissen allein ab, sondern stärker von Faktoren wie lokaler Medienaufmerksamkeit, Gegenmobilisierung, parteipolitischer Konkurrenz oder regionalen Protestdynamiken. Insbesondere kleinräumigere Analysen auf Gemeinde- oder Stadtebene könnten lokale Eskalationsprozesse präziser erfassen.

Schliesslich wäre es sinnvoll, den Untersuchungszeitraum über 2019 hinaus auszuweiten. Seitdem haben sich sowohl die gesellschaftliche Polarisierung als auch die institutionelle Etablierung der AfD weiter verändert. Dadurch könnten mögliche Normalisierungs- oder Mobilisierungseffekte heute stärker ausfallen als in der hier untersuchten frühen Phase des AfD-Aufstiegs. Insbesondere langfristige Analysen könnten dazu beitragen, besser zu verstehen, ob und unter welchen Bedingungen Wahlerfolge rechtsextremer Parteien gesellschaftliche Normen und fremdenfeindliches Verhalten nachhaltig beeinflussen.

7.0 Limitation

Eine zentrale Limitation der Arbeit betrifft die Messung fremdenfeindlicher Hate Crimes. Die verwendeten Daten basieren auf offiziell registrierten Delikten und erfassen daher nur Vorfälle, die von Behörden als Hate Crime klassifiziert und dokumentiert wurden. Es ist davon auszugehen, dass ein Teil fremdenfeindlicher Vorfälle nicht angezeigt oder nicht entsprechend kategorisiert wird. Die tatsächliche Anzahl von Hate Crimes dürfte daher höher liegen als in den vorliegenden Daten abgebildet wird.

Darüber hinaus können Unterschiede im Anzeigeverhalten, in polizeilichen Klassifikationspraktiken oder in der Sensibilität lokaler Behörden zu regionalen Unterschieden in der Erfassung führen. Solche Unterschiede lassen sich mit den verfügbaren Daten nur begrenzt kontrollieren. Eine zusätzliche Limitation betrifft die mögliche Konfundierung durch zivilgesellschaftliche Gegenmobilisierung. AfD-Wahlerfolge könnten nicht nur fremdenfeindliches Verhalten begünstigen, sondern gleichzeitig auch Gegenmobilisierung auslösen – etwa in Form von Demonstrationen, erhöhter sozialer Kontrolle oder verstärktem zivilgesellschaftlichem Engagement gegen Rechtsextremismus. Solche Gegenmobilisierungseffekte könnten einen allfälligen Anstieg von Hate Crime dämpfen oder kompensieren und damit zu einem Nullresultat führen, obwohl der theoretisch erwartete Normalisierungseffekt tatsächlich existiert.

Eine weitere Limitation betrifft die räumliche Aggregation der Daten auf Kreisebene. Obwohl die verwendeten Daten eine vergleichsweise hohe räumliche Auflösung besitzen, können lokale Dynamiken innerhalb einzelner Kreise dadurch nur begrenzt erfasst werden. Mögliche Effekte könnten sich auf einzelne Städte, Gemeinden oder spezifische lokale Konfliktsituationen konzentrieren und im aggregierten Kreisdurchschnitt teilweise verschwinden. Insbesondere kurzfristige Mobilisierungseffekte oder lokale Eskalationsdynamiken könnten dadurch unterschätzt werden. Die Ergebnisse der Arbeit beziehen sich daher auf durchschnittliche Veränderungen auf Kreisebene und nicht auf kleinräumige lokale Prozesse.

Die Arbeit untersucht primär kurzfristige Veränderungen nach Wahlereignissen. Dadurch können langfristige Prozesse politischer oder gesellschaftlicher Normalisierung nur eingeschränkt erfasst werden. Mögliche Veränderungen sozialer Normen, öffentlicher Diskurse oder gesellschaftlicher Akzeptanz könnten sich über deutlich längere Zeiträume entwickeln und sich nicht unmittelbar innerhalb weniger Monate in registrierten Hate Crimes niederschlagen.

Zudem bezieht sich der Analysezeitraum ausschliesslich auf die Jahre 2015 bis 2019 und damit auf eine vergleichsweise frühe Phase des Aufstiegs der AfD. Seitdem haben sich sowohl die politische Position der Partei als auch gesellschaftliche Debatten über Migration, Polarisierung und Rechtsextremismus weiter verändert. Ebenso ist die AfD seit dem Untersuchungszeitraum institutionell und gesellschaftlich deutlich stärker etabliert worden. Es ist daher möglich, dass potenzielle Normalisierungs- oder Mobilisierungseffekte in späteren Jahren stärker sichtbar wären als im hier untersuchten Zeitraum. Insbesondere eine Analyse bis in die Jahre nach 2020 könnte zusätzliche Erkenntnisse darüber liefern, ob sich mögliche Zusammenhänge zwischen rechtsextremer Wahlerfolgen und Hate Crime langfristig verändern oder verstärken. Die Ergebnisse dieser Arbeit erlauben daher vor allem Aussagen über kurzfristige Dynamiken in einer frühen Phase des AfD-Aufstiegs.

Obwohl die verwendeten Fixed-Effects-Modelle zentrale Formen unbeobachteter Heterogenität kontrollieren, erlaubt das Forschungsdesign keine vollständige kausale Identifikation im strengen experimentellen Sinne. Unbeobachtete zeitvariable Faktoren auf lokaler Ebene könnten weiterhin sowohl Wahlergebnisse als auch Hate Crime beeinflussen. Zudem ist nicht auszuschliessen, dass Wahlerfolge der AfD und fremdenfeindliche Gewalt teilweise gemeinsame gesellschaftliche Ursachen haben, ohne dass ein direkter kausaler Zusammenhang zwischen beiden Phänomenen besteht. Die Ergebnisse sollten daher vorsichtig interpretiert werden und nicht als endgültiger Nachweis oder Widerlegung politischer Normalisierungseffekte verstanden werden.

Eine weitere Limitation betrifft die Operationalisierung von Hypothese 2. Die Einteilung der Kreise in Gruppen mit niedrigem und höherem AfD-Ausgangsniveau basiert auf dem ersten verfügbaren AfD-Stimmenanteil eines Kreises bei Landtagswahlen. Da sich die AfD im Untersuchungszeitraum jedoch von einer euroskeptischen zu einer rechtsextremen Partei gewandelt hat, misst ein früher Ausgangswert aus 2013 inhaltlich etwas anderes als ein späterer Wert aus 2016 oder 2017. Ein niedriges Ausgangsniveau in der Frühphase der Partei spiegelt damit nicht zwingend eine geringe rechtsextreme Verankerung wider, sondern möglicherweise lediglich geringe Unterstützung für eine zu diesem Zeitpunkt noch moderat positionierte Partei. Diese Einschränkung wird anerkannt. Der Median-Split wurde dennoch als pragmatische Näherungslösung gewählt, da keine Normierung auf einen einheitlichen Referenzzeitpunkt möglich war. Zukünftige Analysen sollten die zeitliche Dimension der Parteigeschichte der AfD explizit in die Operationalisierung einbeziehen.

Die externe Validität der Ergebnisse ist begrenzt, da sich die Analyse spezifisch auf Deutschland im Zeitraum 2015 bis 2019 bezieht. Dieser Zeitraum stellt einen besonderen politischen und gesellschaftlichen Kontext dar, der stark durch die sogenannte Flüchtlingskrise, migrationspolitische Polarisierung und die frühe Aufstiegsphase der AfD geprägt war. Die Ergebnisse lassen sich daher nur eingeschränkt auf andere Länder, Zeiträume oder politische Kontexte übertragen. Gleichzeitig besitzt gerade der deutsche Fall eine besondere theoretische Relevanz. Offene rechtsextreme und rassistische Positionen sind in Deutschland historisch besonders stark stigmatisiert und mit vergleichsweise hohen sozialen Kosten verbunden. Aus Perspektive des signalbasierten Normalisierungsmechanismus wäre daher gerade hier zu erwarten, dass sichtbare Wahlerfolge rechtsextremer Parteien die Wahrnehmung gesellschaftlicher Akzeptanz besonders stark verändern. Dass die Analyse dennoch keine robusten kurzfristigen Effekte auf Hate Crime findet, könnte darauf hindeuten, dass Wahlergebnisse allein nicht ausreichen, um unmittelbar gewaltsames Verhalten auszulösen. Ebenso ist möglich, dass Normalisierungseffekte weniger kurzfristig und direkt auf Hate Crime wirken, sondern sich eher langfristig, diskursiv oder in anderen Formen politischer Artikulation

zeigen. Die Ergebnisse sprechen daher nicht zwingend gegen Prozesse gesellschaftlicher Normalisierung, sondern eher gegen einen klaren kurzfristigen Zusammenhang zwischen Wahlerfolgen und Hate Crime im untersuchten Zeitraum.

Literaturverzeichnis

- Anderson, D. Mark, Benjamin Crost, und Daniel I. Rees. 2020. «Do Economic Downturns Fuel Racial Animus?» *Journal of Economic Behavior & Organization* 175 (Juli): 9–18. <https://doi.org/10.1016/j.jebo.2020.04.004>.
- Apffelstaedt, Arno, Jana Freundt, und Christoph Oslislo. 2022. «Social Norms and Elections: How Elected Rules Can Make Behavior (in)Appropriate». *Journal of Economic Behavior & Organization* 196 (April): 148–77. <https://doi.org/10.1016/j.jebo.2022.01.031>.
- Arzheimer, Kai, und Carl C. Berning. 2019. «How the Alternative for Germany (AfD) and Their Voters Veered to the Radical Right, 2013–2017». *Electoral Studies* 60 (August): 102040. <https://doi.org/10.1016/j.electstud.2019.04.004>.
- Blumer, Herbert. 1958. «Race Prejudice as a Sense of Group Position». Abschn. 1. *The Pacific Sociological Review* (Kalifornien) 1.
- BMI. 2025. «Neuer Höchststand politisch motivierter Kriminalität». Bundesministerium des Innern, Mai 20. <https://www.bmi.bund.de/SharedDocs/pressemitteilungen/DE/2025/05/pmk2024.html?nn=9390260>.
- Bray, Kerry, Nils Braakmann, und John Wildman. 2024. «Austerity, Welfare Cuts and Hate Crime: Evidence from the UK's Age of Austerity». *Journal of Urban Economics* 141 (Mai): 103439. <https://doi.org/10.1016/j.jue.2022.103439>.
- Bursztyn, Leonardo, Georgy Egorov, und Stefano Fiorin. 2020. «From Extreme to Mainstream: The Erosion of Social Norms». *American Economic Review* 110 (11): 3522–48. <https://doi.org/10.1257/aer.20171175>.
- Caiani, Manuela, und Rossella Borri. 2012. *Between Violent and Non-Violent Action Strategies: A Study on Extreme-Right Organizations in Italy and Spain*. Institut für Höhere Studien (IHS). <https://nbn-resolving.org/urn:nbn:de:0168-ssoar-314371>.
- Caramani, Daniele, und Luca Manucci. 2019. «National past and populism: the re-elaboration of fascism and its impact on right-wing populism in Western Europe». *West European Politics* 42 (6): 1159–87. <https://doi.org/10.1080/01402382.2019.1596690>.
- Curthoys, Alex. 2013. *Identifying the Effect of Unemployment on Hate Crime*.
- Decker, Frank, und Bundeszentrale für politische Bildung. 2022. «Etappen der Parteigeschichte der AfD | Parteien in Deutschland». bpb.de, Dezember 2. <https://www.bpb.de/themen/parteien/parteien-in-deutschland/afd/273130/etappen-der-partiegeschichte-der-afd/>.
- Decker, Frank, und Lazaros Miliopoulos. 2009. «From a Five to a Six-Party System? Prospects of the Right-wing Extremist NPD». *German Politics & Society* 27 (2 (91)): 92–107.

- Falk, Armin, Andreas Kuhn, und Josef Zweimüller. 2011. «Unemployment and Right-wing Extremist Crime*». *The Scandinavian Journal of Economics* 113 (2): 260–85. <https://doi.org/10.1111/j.1467-9442.2011.01648.x>.
- Franz, Christian, Marcel Fratzscher, und Alexander S. Kritikos. 2017. *German Right-Wing Party AfD Finds More Support in Rural Areas with Aging Populations*.
- Hagemeister, Felix. 2022. «Populism and Propagation of Far-Right Extremism». *European Journal of Political Economy* 72 (März): 102116. <https://doi.org/10.1016/j.ejpoleco.2021.102116>.
- Höber, Alexa, und Lalon Sander. 2026. «Bundesweite Statistik zur Hasskriminalität weiter unvollständig». tagesschau.de, Januar 28. <https://www.tagesschau.de/investigativ/panorama/hasskriminalitaet-statistik-100.html>.
- Jäckle, Sebastian, und Pascal D. König. 2017. «The Dark Side of the German ‘Welcome Culture’: Investigating the Causes behind Attacks on Refugees in 2015». *West European Politics* 40 (2): 223–51. <https://doi.org/10.1080/01402382.2016.1215614>.
- Kleinfeld, Rachel, und Nicole Bibbins Sedaca. 2024. «How to Prevent Political Violence». *Journal of Democracy* 35 (4): 35–45.
- Koopmans, Ruud, P. Statham, M. Giugni, und F. Passy. 2005. *Contested Citizenship: Immigration and Cultural Diversity in Europe*. University of Minnesota Press.
- Kumral, Şefika. 2017. «Ballots with Bullets: Elections, Violence, and the Rise of the Extreme Right in Turkey». *Journal of Labor and Society* 20 (2): 231–61. <https://doi.org/10.1111/wusa.12287>.
- Muis, Jasper, und Tim Immerzeel. 2017. «Causes and consequences of the rise of populist radical right parties and movements in Europe». *Current Sociology. La Sociologie Contemporaine* 65 (6): 909–30. <https://doi.org/10.1177/0011392117717294>.
- Müller, Karsten, und Carlo Schwarz. 2021. «Fanning the Flames of Hate: Social Media and Hate Crime». *Journal of the European Economic Association* 19 (4): 2131–67. <https://doi.org/10.1093/jeea/jvaa045>.
- Noelle-Neumann, Elisabeth. 1974. «The Spiral of Silence a Theory of Public Opinion». *Journal of Communication* 24 (2): 43–51. <https://doi.org/10.1111/j.1460-2466.1974.tb00367.x>.
- Pascale, Celine-Marie. 2019. «The weaponization of language: Discourses of rising right-wing authoritarianism». *Current Sociology* 67 (6): 898–917. <https://doi.org/10.1177/0011392119869963>.
- Porta, Donatella della. 2014. «On Violence and Repression: A Relational Approach». *Government and Opposition* 49 (2): 159–87.

- Ravndal, Jacob Aasland. 2016. «Right-Wing Terrorism and Violence in Western Europe: Introducing the RTV Dataset». *Perspectives on Terrorism* 10 (3): 2–15.
- Rees, Jonas H., Yann P. M. Rees, Jens H. Hellmann, und Andreas Zick. 2019. «Climate of Hate: Similar Correlates of Far Right Electoral Support and Right-Wing Hate Crimes in Germany». *Frontiers in Psychology* 10 (Oktober): 2328.
<https://doi.org/10.3389/fpsyg.2019.02328>.
- Rhein-Fischer, Paula, und Anna Wójcik. 2023. «The Politicisation of Constitutional Review of Memory Laws». *European Constitutional Law Review* 19 (4): 664–89.
<https://doi.org/10.1017/S1574019623000287>.
- Riaz, Sascha, Daniel Bischof, und Markus Wagner. 2020. *Out-Group Threat and Xenophobic Hate Crimes: Evidence of Local Intergroup Conflict Dynamics between Immigrants and Natives*.
- Romarri, Alessio. 2019. «Do Far-Right Mayors Increase the Probability of Hate Crimes? Evidence From Italy». *SSRN Electronic Journal*, Online-Vorab-Publikation.
<https://doi.org/10.2139/ssrn.3506811>.
- Rydgren, Jens. 2003. «Meso-Level Reasons for Racism and Xenophobia: Some Converging and Diverging Effects of Radical Right Populism in France and Sweden». *European Journal of Social Theory* 6 (1): 45–68.
<https://doi.org/10.1177/1368431003006001560>.
- Salzborn, Samuel. 2018. *Rechtsextremismus. Erscheinungsformen und Erklärungsansätze*. 3. Aufl. Studienkurs Politikwissenschaft. Nomos Verlagsgesellschaft.
- Tankard, Margaret E., und Elizabeth Levy Paluck. 2016. «Norm Perception as a Vehicle for Social Change». *Social Issues and Policy Review* 10 (1): 181–211.
<https://doi.org/10.1111/sipr.12022>.
- Valentim, Vicente. 2021. «Parliamentary Representation and the Normalization of Radical Right Support». *Comparative Political Studies* 54 (14): 2475–511.
<https://doi.org/10.1177/0010414021997159>.
- Whittington, Whitney, und Sylwia J. Piatkowska. 2025. «Far-Right Extremism, Elections and Hate Crime: A Temporal Evaluation of Bias-Motivated Violence in Slovakia». *The British Journal of Criminology* 65 (1): 126–46.
<https://doi.org/10.1093/bjc/azae032>.
- Wodak, Ruth. 2021. *The Politics of Fear: The Shameless Normalization of Far-Right Discourse*. 2nd edition. SAGE.

Abbildungs- und Tabellenverzeichnis

<i>Abbildung 1: Theoretischer Mechanismus (eigene Grafik)</i>	9
<i>Abbildung 2: Monatliche Entwicklung fremdenfeindlicher Hate Crimes</i>	21
<i>Tabelle 1: Deskriptive Statistiken der zentralen Variablen</i>	20
<i>Tabelle 2: Anteil der Kreis-Monate ohne Hate Crime-Ereignis</i>	20
<i>Tabelle 3: Eventbasierte Fixed-Effects-Modelle für Landtagswahlen</i>	22
<i>Tabelle 4: Eventbasierte Fixed-Effects-Modelle für Bundestagswahlen</i>	23
<i>Tabelle 5: Event-Study-Modell für Bundestagswahlen</i>	24
<i>Tabelle 6: Event-Study-Modell für Landtagswahlen</i>	24

Deklaration zur Verwendung von künstlicher Intelligenz


Zur sprachlichen Überarbeitung und Strukturierung einzelner Abschnitte wie auch für das Schreiben von Codes in R, wurden unterstützend KI-Sprachmodelle von OpenAI verwendet.

Appendix

Grafiken:


Monatliche Entwicklung fremdenfeindlicher Hate Crimes

Aggregierte Anzahl registrierter Delikte pro Monat




Anteil der Kreise mit mindestens einem Hate Crime

Monatlicher Anteil betroffener Kreise




Verteilung von Hate Crimes pro Kreis-Monat

Beobachtungen mit maximal fünf registrierten Delikten




Durchschnittliche Hate-Crime-Rate nach Ost- und Westdeutschland

Mittelwert über alle Kreis-Monate




Monatliche Entwicklung von Hate Crime

Gestrichelte Linien markieren Landtagswahlmonate



Event-Study-Schätzung für Landtagswahlen

Interaktionseffekte zwischen Post-Wahl-Perioden und AfD-Stimmenanteil



10.2 Analysis BA.SamuelBrotschi

Samuel T. Brotschi

1 Konstruktion der Variablen

1.1 Aggregation auf Monatsebene

```
library(tidyverse)
library(fixest)
library(modelsummary)
library(lubridate)
library(texreg)
```

```
analysis_df <- readRDS("panel_mit_wahlen_controls.rds") %>%
  filter(county_id != "16056")
```

```
last_non_missing <- function(x) {
  x <- x[!is.na(x)]
  if (length(x) == 0) return(NA_real_)
  dplyr::last(x)
}
```

```
df_month <- analysis_df %>%
  mutate(
    date = as.Date(date),
    month = floor_date(date, "month")
  ) %>%
  group_by(county_id, month) %>%
  summarise(
    county_name = first(county_name),
    ost_west = first(ost_west),

    hatecrimes = sum(n_hatecrimes, na.rm = TRUE),
    population = mean(bevoelkerung_gesamt, na.rm = TRUE),

    afd_share_btw = last_non_missing(afd_anteil_btw_kreis),
    afd_share_ltw = last_non_missing(afd_anteil_ltw_kreis),

    arbeitslosenquote = mean(arbeitslosenquote, na.rm = TRUE),
    auslaenderanteil = mean(auslaenderanteil, na.rm = TRUE),
    haushaltseinkommen = mean(haushaltseinkommen_monat, na.rm = TRUE),
    sgb2_quote = mean(sgb2_quote, na.rm = TRUE),
    share_age_18_24 = mean(share_age_18_24, na.rm = TRUE),
```

```

share_age_65_74 = mean(share_age_65_74, na.rm = TRUE),
laendlichkeit = mean(laendlichkeit, na.rm = TRUE),

.groups = "drop"
) %>%
mutate(
  hatecrime_rate = hatecrimes / population * 100000
)

```

1.2 Event-basierte Operationalisierung von Wahlerfolg

Um den theoretisch erwarteten Signal- bzw. Normalisierungseffekt empirisch zu untersuchen, muss zunächst bestimmt werden, wann im Datensatz überhaupt ein relevantes Wahlereignis vorliegt.

```

df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    election_btw = ifelse(
      afd_share_btw != lag(afd_share_btw) & !is.na(lag(afd_share_btw)),
      1, 0
    ),
    election_ltw = ifelse(
      afd_share_ltw != lag(afd_share_ltw) & !is.na(lag(afd_share_ltw)),
      1, 0
    )
  ) %>%
  ungroup()

```

Hier erstellen wir die Post-Wahl Variable. Es wird methodisch zwischen BTW und LTW unterschieden.

```

df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    post_btw = lag(election_btw, 1),
    post_ltw = lag(election_ltw, 1)
  ) %>%
  ungroup()

```

Check:

```
df_month %>%  
  filter(post_btw == 1 | post_ltw == 1) %>%  
  select(county_name, month, post_btw, post_ltw) %>%  
  arrange(county_name, month) %>%  
  print(n = 50)
```

A tibble: 747 x 4

	county_name <chr>	month <date>	post_btw <dbl>	post_ltw <dbl>
1	Ahrweiler	2016-04-01	0	1
2	Ahrweiler	2017-10-01	1	0
3	Aichach-Friedberg (Lkr)	2017-10-01	1	0
4	Aichach-Friedberg (Lkr)	2018-11-01	0	1
5	Alb-Donau-Kreis, Landkreis	2016-04-01	0	1
6	Alb-Donau-Kreis, Landkreis	2017-10-01	1	0
7	Altenburger Land	2017-10-01	1	0
8	Altenkirchen (Westerwald)	2016-04-01	0	1
9	Altenkirchen (Westerwald)	2017-10-01	1	0
10	Altmarkkreis Salzwedel	2016-04-01	0	1
11	Altmarkkreis Salzwedel	2017-10-01	1	0
12	Altötting (Lkr)	2017-10-01	1	0
13	Altötting (Lkr)	2018-11-01	0	1
14	Alzey-Worms	2016-04-01	0	1
15	Alzey-Worms	2017-10-01	1	0
16	Amberg (Krfr.St)	2017-10-01	1	0
17	Amberg (Krfr.St)	2018-11-01	0	1
18	Amberg-Sulzbach (Lkr)	2017-10-01	1	0
19	Amberg-Sulzbach (Lkr)	2018-11-01	0	1
20	Ammerland	2017-10-01	1	0
21	Ammerland	2017-11-01	0	1
22	Ansbach (Krfr.St)	2017-10-01	1	0
23	Ansbach (Krfr.St)	2018-11-01	0	1
24	Ansbach (Lkr)	2017-10-01	1	0
25	Ansbach (Lkr)	2018-11-01	0	1
26	Aschaffenburg (Krfr.St)	2017-10-01	1	0
27	Aschaffenburg (Krfr.St)	2018-11-01	0	1
28	Aschaffenburg (Lkr)	2017-10-01	1	0
29	Aschaffenburg (Lkr)	2018-11-01	0	1
30	Augsburg (Krfr.St)	2017-10-01	1	0
31	Augsburg (Krfr.St)	2018-11-01	0	1

32 Augsburg (Lkr)	2017-10-01	1	0
33 Augsburg (Lkr)	2018-11-01	0	1
34 Aurich	2017-10-01	1	0
35 Aurich	2017-11-01	0	1
36 Bad Dürkheim	2016-04-01	0	1
37 Bad Dürkheim	2017-10-01	1	0
38 Bad Kissingen (Lkr)	2017-10-01	1	0
39 Bad Kissingen (Lkr)	2018-11-01	0	1
40 Bad Kreuznach	2016-04-01	0	1
41 Bad Kreuznach	2017-10-01	1	0
42 Bad Tölz-Wolfratshausen (Lkr)	2017-10-01	1	0
43 Bad Tölz-Wolfratshausen (Lkr)	2018-11-01	0	1
44 Baden-Baden, Stadtkreis	2016-04-01	0	1
45 Baden-Baden, Stadtkreis	2017-10-01	1	0
46 Bamberg (Krfr.St)	2017-10-01	1	0
47 Bamberg (Krfr.St)	2018-11-01	0	1
48 Bamberg (Lkr)	2017-10-01	1	0
49 Bamberg (Lkr)	2018-11-01	0	1
50 Barnim	2017-10-01	1	0

i 697 more rows

Für die erste Beobachtung jedes Kreises ist die Post-Variable aufgrund fehlender Vorperiodeninformation nicht definiert und wird daher als fehlend belassen.

2 Modelle LTW Eventbasiert

Zur Untersuchung des Zusammenhangs zwischen Wahlerfolgen und Hate Crime wird ein Fixed-Effects-Modell geschätzt.

Die Analyse nutzt die Variation innerhalb von Kreisen über die Zeit und kontrolliert gleichzeitig für unbeobachtete, zeitinvariante Unterschiede zwischen Kreisen sowie für gemeinsame zeitliche Schocks. Dies wird durch die Verwendung von Kreis- und Zeit-Fixed-Effects erreicht.

2.1 Modell 1: Zusammenhang zwischen Landtagswahlen und Hate Crime Basismodell

```
model1.0_ltw <- feols(
  hatecrime_rate ~ post_ltw * afd_share_ltw | county_id + month,
  data = df_month,
  cluster = ~county_id
```

```
)
```

```
screenreg(model1.0_ltw)
```

```
=====
                                Model 1
-----
post_ltw                        -0.07
                                (0.07)
afd_share_ltw                   0.00
                                (0.00)
post_ltw:afd_share_ltw         0.00
                                (0.01)
-----
Num. obs.                      20000
Num. groups: county_id        400
Num. groups: month             50
R^2 (full model)               0.21
R^2 (proj model)               0.00
Adj. R^2 (full model)          0.19
Adj. R^2 (proj model)         -0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05
```

2.2 Modell 1.1: Erweiterung um Arbeitslosenquote

```
model1.1_ltw <- feols(
  hatecrime_rate ~ post_ltw * afd_share_ltw + arbeitslosenquote | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(model1.1_ltw)
```

```
=====
                                Model 1
-----
```

```

post_ltw                -0.07
                        (0.07)
afd_share_ltw           0.00
                        (0.00)
arbeitslosenquote      -0.04
                        (0.02)
post_ltw:afd_share_ltw  0.00
                        (0.01)
-----
Num. obs.                20000
Num. groups: county_id   400
Num. groups: month       50
R^2 (full model)         0.21
R^2 (proj model)         0.00
Adj. R^2 (full model)    0.19
Adj. R^2 (proj model)    0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05

```

```
screenreg(list(model1.0_ltw, model1.1_ltw ))
```

```

=====
                        Model 1    Model 2
-----
post_ltw                -0.07      -0.07
                        (0.07)      (0.07)
afd_share_ltw           0.00        0.00
                        (0.00)      (0.00)
post_ltw:afd_share_ltw  0.00        0.00
                        (0.01)      (0.01)
arbeitslosenquote      -0.04
                        (0.02)
-----
Num. obs.                20000      20000
Num. groups: county_id   400        400
Num. groups: month       50         50
R^2 (full model)         0.21        0.21
R^2 (proj model)         0.00        0.00
Adj. R^2 (full model)    0.19        0.19
Adj. R^2 (proj model)    -0.00       0.00
=====

```

*** p < 0.001; ** p < 0.01; * p < 0.05

2.3 Modell 1.2: Erweiterung um Ausländeranteil

```
model1.2_ltw <- feols(
  hatecrime_rate ~ post_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(list(model1.0_ltw, model1.1_ltw, model1.2_ltw))
```

	Model 1	Model 2	Model 3
post_ltw	-0.07 (0.07)	-0.07 (0.07)	-0.06 (0.07)
afd_share_ltw	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)
post_ltw:afd_share_ltw	0.00 (0.01)	0.00 (0.01)	0.00 (0.01)
arbeitslosenquote		-0.04 (0.02)	-0.04 * (0.02)
auslaenderanteil			0.04 ** (0.02)
Num. obs.	20000	20000	20000
Num. groups: county_id	400	400	400
Num. groups: month	50	50	50
R ² (full model)	0.21	0.21	0.21
R ² (proj model)	0.00	0.00	0.00
Adj. R ² (full model)	0.19	0.19	0.19
Adj. R ² (proj model)	-0.00	0.00	0.00

*** p < 0.001; ** p < 0.01; * p < 0.05

2.4 Modell 1.3: Erweiterung um SGB-II-Quote

```

modell1.3_ltw <- feols(
  hatecrime_rate ~ post_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(list(modell1.0_ltw, modell1.1_ltw, modell1.2_ltw, modell1.3_ltw))

```

	Model 1	Model 2	Model 3	Model 4
post_ltw	-0.07 (0.07)	-0.07 (0.07)	-0.06 (0.07)	-0.06 (0.07)
afd_share_ltw	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)
post_ltw:afd_share_ltw	0.00 (0.01)	0.00 (0.01)	0.00 (0.01)	0.00 (0.01)
arbeitslosenquote		-0.04 (0.02)	-0.04 * (0.02)	-0.06 (0.03)
auslaenderanteil			0.04 ** (0.02)	0.04 ** (0.01)
sgb2_quote				0.02 (0.02)
Num. obs.	20000	20000	20000	20000
Num. groups: county_id	400	400	400	400
Num. groups: month	50	50	50	50
R ² (full model)	0.21	0.21	0.21	0.21
R ² (proj model)	0.00	0.00	0.00	0.00
Adj. R ² (full model)	0.19	0.19	0.19	0.19
Adj. R ² (proj model)	-0.00	0.00	0.00	0.00

*** p < 0.001; ** p < 0.01; * p < 0.05

```

library(texreg)

htmlreg(
  list(model1.0_ltw, model1.1_ltw, model1.2_ltw, model1.3_ltw),

  file = "ltw_models.html",

  custom.model.names = c(
    "Modell 1",
    "Modell 2",
    "Modell 3",
    "Modell 4"
  ),

  custom.coef.names = c(
    "Post-Wahl",
    "AfD-Stimmenanteil",
    "Post x AfD",
    "Arbeitslosenquote",
    "Auslaenderanteil",
    "SGB-II-Quote"
  ),

  digits = 3,

  stars = c(0.001, 0.01, 0.05),

  caption = "Eventbasierte Fixed-Effects-Modelle fuer Landtagswahlen",

  caption.above = TRUE,

  include.rsquared = TRUE,
  include.adjrs = FALSE,
  include.nobs = TRUE
)

```

2.5 Explorative Erweiterung: Vergleich mit der Partei Die Linke

Im nächsten Schritt wird das Modell explorativ um den Stimmenanteil der Partei Die Linke erweitert. Ziel ist es zu prüfen, ob der zuvor untersuchte Zusammenhang spezifisch für die AfD ist oder ob sich ähnliche Muster auch bei anderen Parteien beobachten lassen.

Die Linke stellt dabei eine interessante Vergleichsgröße dar, da sie ideologisch am anderen Ende des politischen Spektrums verortet ist. Sollte sich ein Effekt ausschließlich für die AfD zeigen, würde dies die Interpretation eines spezifischen Normalisierungseffekts rechtsextremer Positionen stärken. Umgekehrt würde ein ähnliches Muster bei anderen Parteien darauf hindeuten, dass es sich eher um einen allgemeinen politischen oder konfliktbezogenen Effekt handelt.

Die Analyse ist explorativ zu verstehen und dient der Einordnung der bisherigen Ergebnisse.

```
df_month <- analysis_df %>%
  mutate(
    date = as.Date(date),
    month = floor_date(date, "month")
  ) %>%
  group_by(county_id, month) %>%
  summarise(
    county_name = first(county_name),

    hatecrimes = sum(n_hatecrimes, na.rm = TRUE),
    population = mean(bevoelkerung_gesamt, na.rm = TRUE),

    afd_share_ltw = dplyr::last(afd_anteil_ltw_kreis[!is.na(afd_anteil_ltw_kreis)]),

    linke_share_ltw = dplyr::last(linke_anteil_ltw_kreis[!is.na(linke_anteil_ltw_kreis)]),

    arbeitslosenquote = mean(arbeitslosenquote, na.rm = TRUE),
    auslaenderanteil = mean(auslaenderanteil, na.rm = TRUE),

    .groups = "drop"
  ) %>%
  mutate(
    hatecrime_rate = hatecrimes / population * 100000
  )
```

```
df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    election_ltw = ifelse(
      afd_share_ltw != lag(afd_share_ltw) & !is.na(lag(afd_share_ltw)),
      1, 0
    ),
```

```

    post_ltw = lag(election_ltw, 1)
  ) %>%
  ungroup()

model_linke_ltw <- feols(
  hatecrime_rate ~ post_ltw * linke_share_ltw +
    arbeitslosenquote +
    auslaenderanteil
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(list(model1.0_ltw, model1.1_ltw, model1.2_ltw, model1.3_ltw, model_linke_ltw))

```

	Model 1	Model 2	Model 3	Model 4	Model 5
post_ltw	-0.07 (0.07)	-0.07 (0.07)	-0.06 (0.07)	-0.06 (0.07)	-0.06 (0.04)
afd_share_ltw	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	0.00 (0.00)	
post_ltw:afd_share_ltw	0.00 (0.01)	0.00 (0.01)	0.00 (0.01)	0.00 (0.01)	
arbeitslosenquote		-0.04 (0.02)	-0.04 * (0.02)	-0.06 (0.03)	-0.04 (0.02)
auslaenderanteil			0.04 ** (0.02)	0.04 ** (0.01)	0.04 ** (0.01)
sgb2_quote				0.02 (0.02)	
linke_share_ltw					-0.01 (0.01)
post_ltw:linke_share_ltw					0.01 (0.01)
Num. obs.	20000	20000	20000	20000	20000
Num. groups: county_id	400	400	400	400	400
Num. groups: month	50	50	50	50	50
R ² (full model)	0.21	0.21	0.21	0.21	0.21
R ² (proj model)	0.00	0.00	0.00	0.00	0.00

Adj. R ² (full model)	0.19	0.19	0.19	0.19	0.19
Adj. R ² (proj model)	-0.00	0.00	0.00	0.00	0.00

=====

*** p < 0.001; ** p < 0.01; * p < 0.05

3 Modelle BTW Eventbasiert

3.1 Modell 2: Zusammenhang zwischen Bundestagswahlen und Hate Crime Basismodell

```
df_month <- analysis_df %>%
  mutate(
    date = as.Date(date),
    month = floor_date(date, "month")
  ) %>%
  group_by(county_id, month) %>%
  summarise(
    county_name = first(county_name),

    hatecrimes = sum(n_hatecrimes, na.rm = TRUE),
    population = mean(bevoelkerung_gesamt, na.rm = TRUE),

    afd_share_ltw = dplyr::last(afd_anteil_ltw_kreis[!is.na(afd_anteil_ltw_kreis)]),
    linke_share_ltw = dplyr::last(linke_anteil_ltw_kreis[!is.na(linke_anteil_ltw_kreis)]),

    afd_share_btw = dplyr::last(afd_anteil_btw_kreis[!is.na(afd_anteil_btw_kreis)]),
    linke_share_btw = dplyr::last(linke_anteil_btw_kreis[!is.na(linke_anteil_btw_kreis)]),

    arbeitslosenquote = mean(arbeitslosenquote, na.rm = TRUE),
    auslaenderanteil = mean(auslaenderanteil, na.rm = TRUE),
    sgb2_quote = mean(sgb2_quote, na.rm = TRUE),

    .groups = "drop"
  ) %>%
  mutate(
    hatecrime_rate = hatecrimes / population * 100000
  )
```

```

df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    # LTW
    election_ltw = ifelse(
      afd_share_ltw != lag(afd_share_ltw) & !is.na(lag(afd_share_ltw)),
      1, 0
    ),
    post_ltw = lag(election_ltw, 1),

    # BTW
    election_btw = ifelse(
      afd_share_btw != lag(afd_share_btw) & !is.na(lag(afd_share_btw)),
      1, 0
    ),
    post_btw = lag(election_btw, 1)
  ) %>%
  ungroup()

```

```

model2.0_btw <- feols(
  hatecrime_rate ~ post_btw * afd_share_btw | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(model2.0_btw)

```

```

=====
                                Model 1
-----
afd_share_btw                    -0.00
                                (0.00)
post_btw:afd_share_btw          -0.00
                                (0.01)
-----
Num. obs.                        20000
Num. groups: county_id          400
Num. groups: month              50
R^2 (full model)                0.21

```

```

R^2 (proj model)          0.00
Adj. R^2 (full model)     0.19
Adj. R^2 (proj model)     0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05

```

3.2 Modell 2.1: Erweiterung um Arbeitslosenquote

```

model2.1_btw <- feols(
  hatecrime_rate ~ post_btw * afd_share_btw +
    arbeitslosenquote
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)
screenreg(list(model2.0_btw, model2.1_btw ))

```

```

=====
                                Model 1      Model 2
-----
afd_share_btw                   -0.00        -0.01 *
                                (0.00)        (0.00)
post_btw:afd_share_btw          -0.00        -0.00
                                (0.01)        (0.01)
arbeitslosenquote                                -0.05 **
                                                (0.02)
-----
Num. obs.                       20000        20000
Num. groups: county_id          400          400
Num. groups: month               50           50
R^2 (full model)                 0.21         0.21
R^2 (proj model)                 0.00         0.00
Adj. R^2 (full model)            0.19         0.19
Adj. R^2 (proj model)            0.00         0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05

```

3.3 Modell 2.2: Erweiterung um den Ausländeranteil

```
model2.2_btw <- feols(
  hatecrime_rate ~ post_btw * afd_share_btw +
    arbeitslosenquote +
    auslaenderanteil
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(list(model2.0_btw, model2.1_btw, model2.2_btw))
```

```
=====
                                Model 1      Model 2      Model 3
-----
afd_share_btw                   -0.00      -0.01 *      -0.01 *
                                (0.00)      (0.00)      (0.00)
post_btw:afd_share_btw          -0.00      -0.00      -0.00
                                (0.01)      (0.01)      (0.01)
arbeitslosenquote                -0.05 **      -0.06 **
                                (0.02)      (0.02)
auslaenderanteil                 0.04 **
                                (0.02)

-----
Num. obs.                       20000      20000      20000
Num. groups: county_id          400        400        400
Num. groups: month              50         50         50
R^2 (full model)                 0.21       0.21       0.21
R^2 (proj model)                 0.00       0.00       0.00
Adj. R^2 (full model)            0.19       0.19       0.19
Adj. R^2 (proj model)            0.00       0.00       0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05
```

3.4 Modell 2.3: Erweiterung um die SGB-II-Quote

```

model2.3_btw <- feols(
  hatecrime_rate ~ post_btw * afd_share_btw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(list(model2.0_btw, model2.1_btw, model2.2_btw, model2.3_btw))

```

```

=====
                                Model 1      Model 2      Model 3      Model 4
-----
afd_share_btw                  -0.00        -0.01 *        -0.01 *        -0.01
                                (0.00)        (0.00)        (0.00)        (0.00)
post_btw:afd_share_btw        -0.00        -0.00          -0.00          -0.00
                                (0.01)        (0.01)        (0.01)        (0.01)
arbeitslosenquote              -0.05 **        -0.06 **        -0.07 *
                                (0.02)        (0.02)        (0.03)
auslaenderanteil                0.04 **        0.04 **
                                (0.02)        (0.01)
sgb2_quote                     0.01
                                (0.02)
-----
Num. obs.                      20000        20000        20000        20000
Num. groups: county_id        400          400          400          400
Num. groups: month            50           50           50           50
R^2 (full model)              0.21         0.21         0.21         0.21
R^2 (proj model)              0.00         0.00         0.00         0.00
Adj. R^2 (full model)         0.19         0.19         0.19         0.19
Adj. R^2 (proj model)         0.00         0.00         0.00         0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05

```

```

library(texreg)

htmlreg(
  list(model2.0_btw, model2.1_btw, model2.2_btw, model2.3_btw),

```

```

file = "btw_models.html",

custom.model.names = c(
  "Modell 1",
  "Modell 2",
  "Modell 3",
  "Modell 4"
),

custom.coef.names = c(
  "AfD-Stimmenanteil",
  "Post x AfD",
  "Arbeitslosenquote",
  "Auslaenderanteil",
  "SGB-II-Quote"
),

digits = 3,

stars = c(0.001, 0.01, 0.05),

caption = "Eventbasierte Fixed-Effects-Modelle fuer Bundestagswahlen",

caption.above = TRUE,

include.rsquared = TRUE,
include.adjrs = FALSE,
include.nobs = TRUE
)

```

3.5 Explorative Erweiterung: Vergleich mit der Partei Die Linke

```

model2.4_btw_linke <- feols(
  hatecrime_rate ~ post_btw * linke_share_btw +
    arbeitslosenquote +
    auslaenderanteil
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

```

```
screenreg(list(model2.0_btw, model2.1_btw, model2.2_btw, model2.3_btw, model2.4_btw_linke))
```

	Model 1	Model 2	Model 3	Model 4	Model 5
afd_share_btw	-0.00 (0.00)	-0.01 * (0.00)	-0.01 * (0.00)	-0.01 (0.00)	
post_btw:afd_share_btw	-0.00 (0.01)	-0.00 (0.01)	-0.00 (0.01)	-0.00 (0.01)	
arbeitslosenquote		-0.05 ** (0.02)	-0.06 ** (0.02)	-0.07 * (0.03)	-0.07 ** (0.02)
auslaenderanteil			0.04 ** (0.02)	0.04 ** (0.01)	0.03 * (0.02)
sgb2_quote				0.01 (0.02)	
linke_share_btw					0.01 * (0.01)
post_btw:linke_share_btw					-0.01 (0.01)
Num. obs.	20000	20000	20000	20000	20000
Num. groups: county_id	400	400	400	400	400
Num. groups: month	50	50	50	50	50
R ² (full model)	0.21	0.21	0.21	0.21	0.21
R ² (proj model)	0.00	0.00	0.00	0.00	0.00
Adj. R ² (full model)	0.19	0.19	0.19	0.19	0.19
Adj. R ² (proj model)	0.00	0.00	0.00	0.00	0.00

*** p < 0.001; ** p < 0.01; * p < 0.05

4 Modelle Erweiterung: Event Study

4.1 LTW

```
df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
```

```

pre2_ltw = lead(election_ltw, 2),
pre1_ltw = lead(election_ltw, 1),
post1_ltw = lag(election_ltw, 1),
post2_ltw = lag(election_ltw, 2),
post3_ltw = lag(election_ltw, 3)
) %>%
ungroup()

```

```

model_eventstudy_ltw <- feols(
  hatecrime_rate ~
    pre2_ltw * afd_share_ltw +
    pre1_ltw * afd_share_ltw +
    post1_ltw * afd_share_ltw +
    post2_ltw * afd_share_ltw +
    post3_ltw * afd_share_ltw
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)
screenreg(model_eventstudy_ltw)

```

```

=====
                                Model 1
-----
pre2_ltw                        -0.07
                                (0.04)
afd_share_ltw                   -0.00
                                (0.00)
pre1_ltw                        -0.12 **
                                (0.04)
post1_ltw                       -0.06
                                (0.07)
post2_ltw                       -0.13
                                (0.11)
post3_ltw                       -0.12 *
                                (0.06)
pre2_ltw:afd_share_ltw          -0.02
                                (0.02)
afd_share_ltw:pre1_ltw           0.02
                                (0.01)

```

```

afd_share_ltw:post1_ltw      0.01
                             (0.01)
afd_share_ltw:post2_ltw      0.01
                             (0.01)
afd_share_ltw:post3_ltw      0.01
                             (0.01)
-----
Num. obs.                    18400
Num. groups: county_id      400
Num. groups: month          46
R^2 (full model)             0.21
R^2 (proj model)             0.00
Adj. R^2 (full model)        0.19
Adj. R^2 (proj model)        0.00
=====
*** p < 0.001; ** p < 0.01; * p < 0.05

```

```

library(texreg)

htmlreg(
  model_eventstudy_ltw,

  file = "eventstudy_ltw.html",

  custom.model.names = c("Event-Study LTW"),

  custom.coef.names = c(
    "2 Monate vor Wahl",
    "AfD-Stimmenanteil",
    "1 Monat vor Wahl",
    "1 Monat nach Wahl",
    "2 Monate nach Wahl",
    "3 Monate nach Wahl",
    "2 Monate vor Wahl x AfD",
    "1 Monat vor Wahl x AfD",
    "1 Monat nach Wahl x AfD",
    "2 Monate nach Wahl x AfD",
    "3 Monate nach Wahl x AfD"
  ),

  digits = 3,

```

```

stars = c(0.001, 0.01, 0.05),

caption = "Event-Study-Modell fuer Landtagswahlen",

caption.above = TRUE,

include.rsquared = TRUE,
include.adjrs = FALSE,
include.nobs = TRUE
)

```

4.2 BTW

```

df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    pre2_btw = lead(election_btw, 2),
    pre1_btw = lead(election_btw, 1),
    post1_btw = lag(election_btw, 1),
    post2_btw = lag(election_btw, 2),
    post3_btw = lag(election_btw, 3)
  ) %>%
  ungroup()

```

```

model_eventstudy_btw <- feols(
  hatecrime_rate ~
    pre2_btw * afd_share_btw +
    pre1_btw * afd_share_btw +
    post1_btw * afd_share_btw +
    post2_btw * afd_share_btw +
    post3_btw * afd_share_btw
  | county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(list(model_eventstudy_ltw, model_eventstudy_btw))

```

	Model 1	Model 2
pre2_ltw	-0.07 (0.04)	
afd_share_ltw	-0.00 (0.00)	
pre1_ltw	-0.12 ** (0.04)	
post1_ltw	-0.06 (0.07)	
post2_ltw	-0.13 (0.11)	
post3_ltw	-0.12 * (0.06)	
pre2_ltw:afd_share_ltw	-0.02 (0.02)	
afd_share_ltw:pre1_ltw	0.02 (0.01)	
afd_share_ltw:post1_ltw	0.01 (0.01)	
afd_share_ltw:post2_ltw	0.01 (0.01)	
afd_share_ltw:post3_ltw	0.01 (0.01)	
afd_share_btw		-0.00 (0.00)
pre2_btw:afd_share_btw		-0.02 (0.02)
afd_share_btw:pre1_btw		0.04 (0.03)
afd_share_btw:post1_btw		-0.01 (0.01)
afd_share_btw:post2_btw		-0.01 ** (0.00)
afd_share_btw:post3_btw		-0.00 (0.00)
Num. obs.	18400	18400
Num. groups: county_id	400	400
Num. groups: month	46	46
R ² (full model)	0.21	0.21
R ² (proj model)	0.00	0.00

Adj. R ² (full model)	0.19	0.19
Adj. R ² (proj model)	0.00	0.00

=====

*** p < 0.001; ** p < 0.01; * p < 0.05

```
htmlreg(
  model_eventstudy_btw,

  file = "eventstudy_btw.html",

  custom.model.names = c("Bundestagswahlen"),

  custom.coef.names = c(
    "AfD-Stimmenanteil",
    "2 Monate vor Wahl x AfD",
    "1 Monat vor Wahl x AfD",
    "1 Monat nach Wahl x AfD",
    "2 Monate nach Wahl x AfD",
    "3 Monate nach Wahl x AfD"
  ),

  digits = 3,

  stars = c(0.001, 0.01, 0.05),

  caption = "Event-Study-Modell fuer Bundestagswahlen",

  caption.above = TRUE,

  include.rsquared = TRUE,
  include.adjrs = FALSE,
  include.nobs = TRUE
)
```

5 Poisson-Modelle

```
model_pois_ltw <- fepois(
  hatecrimes ~ post_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil +
```

```

    sgb2_quote |
    county_id + month,
    offset = ~ log(population),
    data = df_month,
    cluster = ~county_id
)

model_pois_btw <- fepois(
  hatecrimes ~ post_btw * afd_share_btw +
  arbeitslosenquote +
  auslaenderanteil +
  sgb2_quote |
  county_id + month,
  offset = ~ log(population),
  data = df_month,
  cluster = ~county_id
)

screenreg(list(model_pois_ltw,model_pois_btw) )

```

```

=====
                        Model 1      Model 2
-----
post_ltw                -0.55 *
                        (0.25)
afd_share_ltw           -0.00
                        (0.00)
arbeitslosenquote      -0.15      -0.13
                        (0.10)      (0.10)
auslaenderanteil        0.21 ***    0.22 ***
                        (0.06)      (0.06)
sgb2_quote              -0.07      -0.05
                        (0.08)      (0.08)
post_ltw:afd_share_ltw  0.03
                        (0.02)
afd_share_btw                                0.01
                                           (0.01)
post_btw:afd_share_btw                                -0.00
                                           (0.01)
-----
Num. obs.                20000      20000

```

Num. groups: county_id	400	400
Num. groups: month	50	50
Deviance	16933.23	16936.65
Log Likelihood	-14535.66	-14537.37
Pseudo R ²	0.31	0.31

=====

*** p < 0.001; ** p < 0.01; * p < 0.05

5.1 Erweiterte Robustheitsanalyse: Poisson Event Study

```
model_pois_event_ltw <- fepois(
  hatecrimes ~
    pre2_ltw * afd_share_ltw +
    pre1_ltw * afd_share_ltw +
    post1_ltw * afd_share_ltw +
    post2_ltw * afd_share_ltw +
    post3_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote
  | county_id + month,
  offset = ~ log(population),
  data = df_month,
  cluster = ~county_id
)

model_pois_event_btw <- fepois(
  hatecrimes ~
    pre2_btw * afd_share_btw +
    pre1_btw * afd_share_btw +
    post1_btw * afd_share_btw +
    post2_btw * afd_share_btw +
    post3_btw * afd_share_btw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote
  | county_id + month,
  offset = ~ log(population),
  data = df_month,
  cluster = ~county_id
)
```

```
screenreg(list(model_pois_event_ltw, model_pois_event_btw ))
```

	Model 1	Model 2
pre2_ltw	-0.36 ** (0.11)	
afd_share_ltw	-0.01 (0.01)	
pre1_ltw	-0.35 ** (0.12)	
post1_ltw	-0.54 * (0.25)	
post2_ltw	-0.50 (0.30)	
post3_ltw	-0.36 (0.25)	
arbeitslosenquote	-0.16 (0.10)	-0.15 (0.10)
auslaenderanteil	0.25 *** (0.06)	0.26 *** (0.06)
sgb2_quote	-0.06 (0.08)	-0.03 (0.08)
pre2_ltw:afd_share_ltw	-0.18 (0.13)	
afd_share_ltw:pre1_ltw	0.06 (0.11)	
afd_share_ltw:post1_ltw	0.03 * (0.02)	
afd_share_ltw:post2_ltw	0.03 (0.02)	
afd_share_ltw:post3_ltw	0.03 * (0.01)	
afd_share_btw		0.01 (0.01)
pre2_btw:afd_share_btw		0.00 (0.07)
afd_share_btw:pre1_btw		0.12 (0.06)
afd_share_btw:post1_btw		-0.00

		(0.01)
afd_share_btw:post2_btw	-0.02	(0.02)
afd_share_btw:post3_btw	0.01	(0.01)

Num. obs.	18400	18400
Num. groups: county_id	400	400
Num. groups: month	46	46
Deviance	16146.92	16184.14
Log Likelihood	-13983.96	-14002.57
Pseudo R ²	0.30	0.30

*** p < 0.001; ** p < 0.01; * p < 0.05

6 Alternative Operationalisierung: Wahlerfolg als Veränderung

```
df_month <- analysis_df %>%
  mutate(
    date = as.Date(date),
    month = floor_date(date, "month")
  ) %>%
  group_by(county_id, month) %>%
  summarise(
    county_name = first(county_name),
    ost_west = first(ost_west),

    hatecrimes = sum(n_hatecrimes, na.rm = TRUE),
    population = mean(bevoelkerung_gesamt, na.rm = TRUE),

    afd_share_ltw = last_non_missing(afd_anteil_ltw_kreis),
    afd_diff_ltw = last_non_missing(afd_diff_ltw_kreis),

    afd_share_btw = last_non_missing(afd_anteil_btw_kreis),
    afd_diff_btw = last_non_missing(afd_diff_btw_kreis),

    linke_share_ltw = last_non_missing(linke_anteil_ltw_kreis),
    linke_share_btw = last_non_missing(linke_anteil_btw_kreis),

    arbeitslosenquote = mean(arbeitslosenquote, na.rm = TRUE),
```

```

    auslaenderanteil = mean(auslaenderanteil, na.rm = TRUE),
    sgb2_quote = mean(sgb2_quote, na.rm = TRUE),

    .groups = "drop"
  ) %>%
  mutate(
    hatecrime_rate = hatecrimes / population * 100000
  )

df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    election_ltw = ifelse(
      afd_share_ltw != lag(afd_share_ltw) & !is.na(lag(afd_share_ltw)),
      1, 0
    ),
    post_ltw = lag(election_ltw, 1),

    election_btw = ifelse(
      afd_share_btw != lag(afd_share_btw) & !is.na(lag(afd_share_btw)),
      1, 0
    ),
    post_btw = lag(election_btw, 1)
  ) %>%
  ungroup()

model_diff_ltw <- feols(
  hatecrime_rate ~ post_ltw * afd_diff_ltw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote |
    county_id + month,
  data = df_month,
  cluster = ~county_id
)

screenreg(model_diff_ltw)

```

=====

Model 1

```

-----
post_ltw                -0.08
                        (0.07)
arbeitslosenquote       0.11 *
                        (0.05)
auslaenderanteil        0.01
                        (0.04)
sgb2_quote              0.08
                        (0.04)
post_ltw:afd_diff_ltw   0.01
                        (0.01)
-----
Num. obs.                7154
Num. groups: county_id  347
Num. groups: month       47
R^2 (full model)         0.19
R^2 (proj model)         0.01
Adj. R^2 (full model)    0.14
Adj. R^2 (proj model)    0.01
=====
*** p < 0.001; ** p < 0.01; * p < 0.05

```

7 Negativ Binomial

7.1 Landtagswahl

```

model_nb_ltw <- fenegbin(
  hatecrimes ~ post_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote |
    county_id + month,
  offset = ~ log(population),
  cluster = ~county_id,
  data = df_month
)

etable(model_nb_ltw)

```

model_nb_ltw

```

Dependent Var.:          hatecrimes

post_ltw                 -0.5252* (0.2537)
afd_share_ltw            -0.0020 (0.0046)
arbeitslosenquote       -0.0679 (0.0936)
auslaenderanteil        0.2283*** (0.0584)
sgb2_quote              -0.1259. (0.0738)
post_ltw x afd_share_ltw  0.0254 (0.0161)
Fixed-Effects:          -----
county_id                Yes
month                    Yes
-----
S.E.: Clustered          by: county_id
Observations              20,000
Squared Cor.              0.58520
Pseudo R2                 0.19475
BIC                       33,081.4
Over-dispersion           2.6906
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

7.2 Bundestagswahl

```

model_nb_btw <- fenegbin(
  hatecrimes ~ post_btw * afd_share_btw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote |
    county_id + month,
  offset = ~ log(population),
  cluster = ~county_id,
  data = df_month
)

etable(model_nb_btw)

```

```

model_nb_btw
Dependent Var.: hatecrimes

post_btw          2.303 (NA)

```

afd_share_btw	0.0026 (NA)
arbeitslosenquote	-0.0650 (NA)
auslaenderanteil	0.2295 (NA)
sgb2_quote	-0.1208 (NA)
post_btw x afd_share_btw	-0.0007 (NA)
Fixed-Effects:	-----
county_id	Yes
month	Yes

S.E. type	NA (not-ava.)
Convergence	FALSE
Observations	20,000
Squared Cor.	0.58623
Pseudo R2	0.19460
BIC	33,086.6
Over-dispersion	2.6811

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

8 Binary Model

```
df_month <- df_month %>%
  group_by(county_id) %>%
  arrange(month) %>%
  mutate(
    election_ltw = ifelse(
      afd_share_ltw != lag(afd_share_ltw) & !is.na(lag(afd_share_ltw)),
      1, 0
    ),
    post_ltw = lag(election_ltw, 1),

    pre2_ltw = lead(election_ltw, 2),
    pre1_ltw = lead(election_ltw, 1),
    post1_ltw = lag(election_ltw, 1),
    post2_ltw = lag(election_ltw, 2),
    post3_ltw = lag(election_ltw, 3)
  ) %>%
  ungroup()
```

```
df_month <- df_month %>%
  mutate(hc_dummy = ifelse(hatecrimes > 0, 1, 0))
```

```
model_bin_ltw <- feols(
  hc_dummy ~ post_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote |
    county_id + month,
  data = df_month,
  cluster = ~county_id
)
```

```
model_bin_event_ltw <- feols(
  hc_dummy ~
    pre2_ltw * afd_share_ltw +
    pre1_ltw * afd_share_ltw +
    post1_ltw * afd_share_ltw +
    post2_ltw * afd_share_ltw +
    post3_ltw * afd_share_ltw +
    arbeitslosenquote +
    auslaenderanteil +
    sgb2_quote |
    county_id + month,
  data = df_month,
  cluster = ~county_id
)
```

```
screenreg(list(model_bin_ltw, model_bin_event_ltw))
```

	Model 1	Model 2
post_ltw	-0.08 (0.05)	
afd_share_ltw	0.00 (0.00)	-0.00 (0.00)
arbeitslosenquote	-0.02 (0.02)	-0.03 (0.02)
auslaenderanteil	0.03 ***	0.04 ***

	(0.01)	(0.01)
sgb2_quote	-0.02	-0.02
	(0.01)	(0.01)
post_ltw:afd_share_ltw	0.01	
	(0.00)	
pre2_ltw		-0.02
		(0.03)
pre1_ltw		-0.06 *
		(0.03)
post1_ltw		-0.07
		(0.05)
post2_ltw		-0.01
		(0.05)
post3_ltw		-0.07
		(0.06)
pre2_ltw:afd_share_ltw		-0.02
		(0.02)
afd_share_ltw:pre1_ltw		-0.00
		(0.02)
afd_share_ltw:post1_ltw		0.01
		(0.00)
afd_share_ltw:post2_ltw		-0.00
		(0.00)
afd_share_ltw:post3_ltw		0.01
		(0.00)

Num. obs.	20000	18400
Num. groups: county_id	400	400
Num. groups: month	50	46
R ² (full model)	0.24	0.24
R ² (proj model)	0.00	0.00
Adj. R ² (full model)	0.22	0.22
Adj. R ² (proj model)	0.00	0.00

*** p < 0.001; ** p < 0.01; * p < 0.05

```
saveRDS(
  df_month,
  "/Users/samuelbrotschi/Desktop/Abgabe Bachelorarbeit/Bachelorarbeit_S.B./df_month.rds"
)
```

9 Test Hypothese Zwei: Low/High Baseline

```
# Alte Variablen entfernen
df_month <- df_month %>%
  select(
    -any_of(c(
      "afd_baseline_ltw",
      "low_baseline_ltw"
    ))
  )

# Ersten tatsächlichen AfD-Wahlwert (>0) pro Kreis bestimmen
baseline_afd_ltw <- df_month %>%
  group_by(county_id) %>%
  summarise(
    afd_baseline_ltw = first(afd_share_ltw[afd_share_ltw > 0]),
    .groups = "drop"
  )

# Median berechnen
median_baseline_ltw <- median(
  baseline_afd_ltw$afd_baseline_ltw,
  na.rm = TRUE
)

# Variablen zurück in Hauptdatensatz joinen
df_month <- df_month %>%
  left_join(baseline_afd_ltw, by = "county_id") %>%
  mutate(
    low_baseline_ltw = ifelse(
      afd_baseline_ltw < median_baseline_ltw,
      1,
      0
    )
  )

# Kontrolle
table(df_month$low_baseline_ltw, useNA = "ifany")
```

0 1

10200 10200

```
model_h2_ltw <- feols(  
  hatecrime_rate ~  
    post_ltw * afd_share_ltw * factor(low_baseline_ltw) +  
    arbeitslosenquote +  
    auslaenderanteil +  
    sgb2_quote  
  | county_id + month,  
  
  data = df_month,  
  cluster = ~county_id  
)  
  
screenreg(model_h2_ltw)
```

```
=====
                                     Model 1
-----
post_ltw                           -0.16  
                                   (0.17)  
afd_share_ltw                      0.00  
                                   (0.00)  
arbeitslosenquote                 -0.06  
                                   (0.03)  
auslaenderanteil                  0.04 *  
                                   (0.01)  
sgb2_quote                        0.02  
                                   (0.02)  
post_ltw:afd_share_ltw            0.01  
                                   (0.01)  
post_ltw:factor(low_baseline_ltw)1 0.08  
                                   (0.18)  
afd_share_ltw:factor(low_baseline_ltw)1 -0.00  
                                   (0.00)  
post_ltw:afd_share_ltw:factor(low_baseline_ltw)1 0.00  
                                   (0.01)  
-----  
Num. obs.                         20000  
Num. groups: county_id            400  
Num. groups: month                 50
```

R ² (full model)	0.21
R ² (proj model)	0.00
Adj. R ² (full model)	0.19
Adj. R ² (proj model)	0.00

*** p < 0.001; ** p < 0.01; * p < 0.05