

Justus-Liebig-Universität Gießen

Fachbereich 07: Mathematik und Informatik, Physik, Geographie

Institut für Geographie

Professur für Wirtschaftsgeographie

Webdatenbasierte Identifizierung von Hidden Champions – Wechselwirkungen im regionalen Innovationskontext

Vom Fachbereich 07 der Justus-Liebig-Universität Gießen zur Erlangung des
akademischen Grades Doktorin der Naturwissenschaften (Dr. rer. nat.)

genehmigte Dissertation

vorgelegt von

Lisa Katharina Zirbes

Bonn, August 2023

Wissenschaftliche Betreuung:

Prof. Dr. Stefan Hennemann

Professur für Wirtschaftsgeographie
am Institut für Geographie, Justus-Liebig-Universität Gießen

Erstgutachten:

Prof. Dr. Stefan Hennemann

Zweitgutachten:

Prof. Dr. Ingo Liefner

Tag der Promotion:

03. November 2023

Zusammenfassung

Die Dissertation analysiert die Rolle von unbekanntem marktführenden Unternehmen, sog. Hidden Champions (HCs), im regionalen Innovationskontext. Das Forschungsvorhaben und die Fragestellung der Arbeit ist in drei inhaltliche Schritte eingeteilt. Zunächst die Identifizierung des Untersuchungsgegenstandes, um die HCs zu lokalisieren. Dies geschieht nach einer ausführlichen Analyse der aktuellen Literatur zu HCs durch einen neuen methodischen Ansatzes. Dazu werden die Identifizierungskriterien von HCs nach Simon (2012, S. 84) operationalisiert. Die Operationalisierung der Marktführerschaft erfolgt basierend auf Webdaten und der Kombination eines automatisierten Keyword-Suchansatzes mit einem Klassifizierungsalgorithmus. Der Unbekanntheitsgrad wurde anhand der Google-Suche-Treffer der Unternehmen festgelegt. Im Ergebnis konnten 3.654 HCs identifiziert werden, welche zu 70 Prozent in ländlichen Räumen verortet wurden. Die HCs treten in Bayern, Baden-Württemberg und NRW in Clustern auf.

Das zweite Ziel der Arbeit beinhaltet eine regionale Typisierung des Untersuchungsraums anhand sozioökonomischer Strukturen auf Gemeindeebene. Die Regionstypen unterscheiden sich nach Siedlungsstruktur, Mobilität, Bildung, Beschäftigung, sozialer Infrastruktur und Arbeitsplatzattraktivität. Durch die Kombination einer Hauptkomponentenanalyse mit einer nachgelagerten Clusteranalyse werden neun heterogene Regionstypen identifiziert. Anhand dieser differenzierten Betrachtung können die Verteilung der HCs, sowie die Effekte dieser auf den Innovationsoutput der Gemeinden eingeordnet werden.

Die Analyse der Wechselwirkungen zwischen den regionalen Strukturen, den HCs und dem Innovationsoutput beschreibt das dritte Ziel dieser Arbeit. Zunächst wird festgestellt, dass je nach sozioökonomischer Struktur in den Regionstypen die Anwesenheit von HCs unterschiedlich beeinflusst wird. Die Berücksichtigung der regionalen Charaktereigenschaften durch die Regionstypisierung trägt zu einem besseren Verständnis der innovationsfördernden Faktoren bei. Sind HCs in Regionen ansässig, trägt dies ebenfalls je nach regionaler Struktur zur Steigerung des Innovationsoutputs bei. Nachweislich hat die Anwesenheit von HCs auf Kreisebene einen positiven Einfluss auf die Zusammenhänge zwischen den sozioökonomischen Faktoren und dem Innovationsoutput von Gemeinden. Weiter wird festgestellt, dass HCs positive Auswirkungen auf die Innovationsleistung ihrer direkten Umgebung haben können. Die Ergebnisse dieser Arbeit sind vielversprechende Grundlagen für weitere Untersuchungen zu HCs. Webdatenbasierte Erkenntnisse tragen dazu bei, auf neue Weise Daten zu erfassen und zu strukturieren. Die dadurch mögliche differenzierte Betrachtung kleinräumiger Strukturen leistet einen Beitrag zum besseren Verständnis von regionalen, unternehmerischen Wechselwirkungen im Innovationskontext.

Abstract

The dissertation analyses the role of unknown market leaders, so-called hidden champions (HCs), in the context of innovation. The research interest of the thesis is divided into three sections. First, the identification of the object of study to locate HCs. This is based on a detailed analysis of current literature on HCs using a new methodological approach that operationalises the HC definition according to Simon (2012, p. 84). The identification of market leadership is based on web data and the combination of an automated keyword search approach with a classification algorithm. The level of unfamiliarity was determined based on the companies' Google search hits. As a result, 3,654 HCs were identified, 70 percent of which were located in rural areas. The HCs appear in clusters in Bavaria, Baden-Württemberg and NRW.

The second objective of the work involves a regional typification of the study area based on socio-economic structures at municipality level. The region types differ according to settlement structure, mobility, education, employment, social infrastructure, and job attractiveness. By combining a principal component analysis with a downstream cluster analysis, nine heterogeneous region types are identified. Based on this differentiated view, the distribution of the HCs, as well as the effects of these on the innovation output of the municipalities, can be classified.

The analysis of the interactions between the regional structures, the HCs and the innovation output describes the third objective of this work. First, it is noted that depending on the socio-economic structures in the region types, the presence of HCs is influenced differently. The consideration of regional characteristics through region typing contributes to a better understanding of the factors that promote innovation. If HCs are located in regions, this also contributes to increasing innovation output depending on the regional structure. Evidence shows that the presence of HCs at the district level has a positive influence on the correlations between socio-economic factors and the innovation output of municipalities. It is further found that HCs can have a positive impact on the innovation output of their immediate surroundings. The results of this work are promising foundations for further research on HCs. Web-based findings help to collect and structure data in a new way. The resulting differentiated view of small-scale structures contributes to a better understanding of regional, entrepreneurial interactions in the innovation context.

Danksagung

Zunächst bedanke ich mich bei meinem Betreuer Prof. Dr. Stefan Hennemann, für seine Unterstützung, beginnend bei der anfänglichen Motivation zur Promotion, der anschließenden Ideenfindung und der fachlichen Betreuung bis zur Abgabe dieser Arbeit. Ich bedanke mich bei Prof. Dr. Ingo Liefner für das Zweitgutachten dieser Arbeit und die Begleitung im Forschungsprojekt. Außerdem bedanke ich mich bei Prof. Dr. Lea Schneider und Prof. Dr. Christian Diller für die Bereitschaft, Teil der Prüfungskommission zu sein.

Darüber hinaus möchte ich mich bei meinen ehemaligen Kolleg:innen bedanken, die mich mit wertvollen Anregungen und hilfreichen Diskussionen unterstützt haben. Auch die Work-Life-Balance, ob in Präsenz oder digital, kam dank euch nie zu kurz. Danke an Leon in Hannover, die Gießener AG Wigeo mit Julia, Marie-Louise, Moritz, Natalie, Niklas, Tim und Sina sowie an das 3. OG mit Annette, Charlotte, Chris, Jan, Jan, Jonas, Julia, Manuel, Marie, Martin, Philipp, Sergej und Sarah.

Besonderer Dank gilt Carsten, denn deine strukturierte, motivierende und geduldige Arbeitsweise in unserem gemeinsamen Forschungsprojekt hat mich und diese Dissertation nachhaltig geprägt. Ich bin froh, dass neben unseren Abschlüssen auch unsere Freundschaft als Ergebnis des HiDi-Projekts entstanden ist.

Dass Freund:innen zu Kolleg:innen wurden, hatte nachweislich einen sehr positiven Effekt auf meine Arbeit. Ich bin sehr dankbar für die enge Zusammenarbeit mit Lukas. Danke für dein immer offenes Ohr, deine ansteckende Hands-On-Mentalität und die immer lösungsorientierte Zusammenarbeit! Sarah, danke, dass du mir dabei geholfen hast, immer wieder den roten Faden zu finden, den Überblick zu bewahren und auch aufs kleinste Detail zu achten. Ich bin dankbar für unsere Freundschaft, die schon seit den Einführungswochen des Bachelors bzw. Masters besteht und wächst. Unsere Gespräche haben mir immer wieder neue Perspektiven eröffnet und meine Forschung und Art zu Denken in vielerlei Hinsicht bereichert.

Bedanken möchte ich mich auch bei meinen Studienfreund:innen aus Gießen und meinen liebsten Bonner:innen für eure allgegenwärtige Unterstützung in jeder Lebenslage. Ein großes Dankeschön gilt insbesondere meiner Familie, die mich durch ihren stetigen Rückhalt konstant ermutigt und gestärkt hat. Danke, dass ihr nie müde wurdet zu fragen und vor allem zuzuhören! Ich bin dankbar für das Vorbild meiner Eltern. Ein langer Atem und trotz Rückschlägen oder Hindernissen immer das Positive im Blick zu behalten, war Dank und durch Euch nie schwer.

Von ganzem Herzen bedanken möchte ich mich bei meinem Ehemann Michael, für seine bedingungslose Unterstützung schon seit dem Abitur. Deine ermutigenden Worte und Gesten zu jeder Tages und Nachtzeit, dein Verständnis und deine Zuversicht haben mich stets motiviert. Ohne dich an meiner Seite und durch deinen Rückhalt wäre dieser Weg nicht halb so erfüllend gewesen. Dir gebührt mein größter Dank. Danke für deine Liebe und Geduld auf dieser Reise.

Inhaltsverzeichnis

| | |
|--|-----------|
| Zusammenfassung..... | I |
| Abstract..... | II |
| Danksagung..... | III |
| Abbildungsverzeichnis..... | VII |
| Tabellenverzeichnis..... | VIII |
| Abkürzungsverzeichnis..... | X |
| | |
| 1 Einleitung..... | 1 |
| 1.1 Übergeordnetes Forschungsinteresse..... | 3 |
| 1.2 Struktur der Arbeit..... | 4 |
| | |
| I: Theoretisch-konzeptionelle Grundlagen..... | 6 |
| | |
| 2 Regionaler Innovationskontext..... | 6 |
| 2.1 Innovationstheorien und Wissensgenerierungsprozesse..... | 6 |
| 2.2 Spillover-Effekte und räumliche Verteilung von Innovationsaktivitäten..... | 10 |
| 2.3 Wettbewerbsstrategien..... | 13 |
| | |
| 3 Die Unternehmenskategorie Hidden Champion..... | 16 |
| 3.1 Begriffsklärung..... | 16 |
| 3.2 Unternehmerischer Charakter..... | 18 |
| 3.3 Fokussierung und Tiefe durch Innovation..... | 19 |
| 3.4 Internationalisierung..... | 22 |
| | |
| 4 Stand der Forschung: Hidden Champions..... | 24 |
| 4.1 Definitionen, Identifizierungsmethodik und Untersuchungsgegenstände..... | 25 |
| 4.2 Forschungsinhalte Hidden Champions..... | 31 |
| 4.2.1 Internationalisierung..... | 32 |
| 4.2.2 Innovation..... | 34 |
| 4.2.3 Räumliche Muster und Zusammenhänge..... | 39 |
| | |
| 5 Forschungslücken und Fragestellungen..... | 42 |

| | |
|---|-----------|
| II: Methodik | 46 |
| 6 Methodisches Framework | 46 |
| 7 Identifizierung des Untersuchungsgegenstandes | 48 |
| 7.1 Web Mining | 48 |
| 7.2 Ausgangsdatenbasis und Hidden Champions Umsatzgrenze..... | 51 |
| 7.3 Champions | 53 |
| 7.4 Hiddenness..... | 56 |
| 7.5 Geokodierung der Hidden Champions..... | 57 |
| 8 Regionstypisierung | 58 |
| 8.1 Räumliche Autokorrelation | 58 |
| 8.2 Methodenauswahl und Untersuchungsebene | 59 |
| 8.2.1 Indikatorenauswahl..... | 60 |
| 8.2.2 Hauptkomponentenanalyse..... | 61 |
| 8.2.3 Clusteranalyse | 63 |
| 9 Räumliche Wirkungszusammenhänge | 65 |
| 9.1 Datenbasis und Untersuchungsvariablen..... | 65 |
| 9.2 Regression mit Zählvariablen..... | 66 |
| 9.3 Multiple lineare Regressionsmodelle..... | 68 |
| 9.4 Hierarchisch lineare Mehrebenenanalyse..... | 69 |
| 9.4.1 Modell 1: Random-Intercept-Only-Modell | 71 |
| 9.4.2 Modell 2: Random-Intercept-Modell..... | 72 |
| 9.4.3 Modell 3: Random-Slope-Modell | 74 |
| 9.4.4 Modell 4: Cross-Level-Interaktion | 75 |
| 9.5 Räumliche Regressionsanalyse..... | 76 |

| | |
|--|----------------|
| III: Ergebnispräsentation und -diskussion | 78 |
| 10 Lokalisierung und Deskription der Hidden Champions..... | 78 |
| 10.1 Identifizierte Hidden Champions..... | 78 |
| 10.2 Räumliche Autokorrelation | 83 |
| 10.3 Fallbeispiele | 86 |
| 11 Regionstypisierung | 88 |
| 11.1 Hauptkomponentenanalyse | 88 |
| 11.2 Deskriptive Analyse der sozioökonomischen Charaktereigenschaften..... | 91 |
| 11.3 Model Based Clustering..... | 103 |
| 11.4 Deskriptive Analyse Regionstypen..... | 103 |
| 12 Darstellung der quantitativen Ergebnisse..... | 125 |
| 12.1 Regression mit Zählvariablen..... | 125 |
| 12.2 Multiple Regression | 130 |
| 12.3 Hierarchisch Lineare Modelle..... | 133 |
| 12.3.1 Deutschland..... | 135 |
| 12.3.2 Regionstypen | 139 |
| 12.4 Räumliche Regressionsanalyse..... | 153 |
| 13 Ergebnisdiskussion | 159 |
| 13.1 Identifizierung des Untersuchungsgegenstands | 159 |
| 13.2 Regionale Typisierung..... | 163 |
| 13.3 Regionale Wirkungszusammenhänge..... | 165 |
| 14 Zusammenfassendes Fazit..... | 171 |
| 14.1 Limitationen..... | 172 |
| 14.2 Forschungsausblick | 175 |
| 15 Literatur | 178 |
| Eidesstattliche Erklärung | 201 |

Abbildungsverzeichnis

| | |
|--|-----|
| Abbildung 1: Unternehmerische Wettbewerbsstrategien..... | 14 |
| Abbildung 2: Methodisches Framework | 46 |
| Abbildung 3: Datenbasis Webseiten | 53 |
| Abbildung 4: Keyword-Extraktion..... | 54 |
| Abbildung 5: Vorgehensweise der Operationalisierung des Hiddenness Kriteriums..... | 57 |
| Abbildung 6: Ebenenübergreifende Interaktionen in der HLM..... | 70 |
| Abbildung 7: Verteilung der Unternehmensgründungsjahre der Hidden Champions | 80 |
| Abbildung 8: Hidden Champions nach Wirtschaftszweig und Unternehmensgröße | 81 |
| Abbildung 9: Hidden Champions je 1.000 EW auf Gemeindeebene | 82 |
| Abbildung 10: Local Moran's I..... | 85 |
| Abbildung 11: Ausprägungen F01: Siedlungs- und Branchenstruktur (Gemeinden) | 92 |
| Abbildung 12: Ausprägungen F02: Mobilität und Erreichbarkeit (Gemeinden)..... | 94 |
| Abbildung 13: Ausprägungen F03: Lokale Beschäftigung (Gemeinden)..... | 96 |
| Abbildung 14: Ausprägungen F04: Hochschulbildung (Gemeinden)..... | 98 |
| Abbildung 15: Ausprägungen F05: Lokale Arbeitsplatzattraktivität (Gemeinden)..... | 100 |
| Abbildung 16: Ausprägungen F06: Soziale Infrastruktur (Gemeinden)..... | 102 |
| Abbildung 17: Räumliche Verteilung Regionstyp 1..... | 108 |
| Abbildung 18: Räumliche Verteilung Regionstyp 2..... | 110 |
| Abbildung 19: Räumliche Verteilung Regionstyp 3..... | 112 |
| Abbildung 20: Räumliche Verteilung Regionstyp 4..... | 114 |
| Abbildung 21: Räumliche Verteilung Regionstyp 5..... | 116 |
| Abbildung 22: Räumliche Verteilung Regionstyp 6..... | 118 |
| Abbildung 23: Räumliche Verteilung Regionstyp 7..... | 120 |
| Abbildung 24: Räumliche Verteilung Regionstyp 8..... | 122 |
| Abbildung 25: Räumliche Verteilung Regionstyp 9..... | 124 |
| Abbildung 26: Ebenenübergreifende Interaktionen in der HLM..... | 134 |

Tabellenverzeichnis

| | |
|--|-----|
| Tabelle 1: Variablen zur sozioökonomischen Charakterisierung der Gemeinden | 60 |
| Tabelle 2: Faktoren Regionalstruktur | 63 |
| Tabelle 3: Hidden Champions-Verteilung nach Bundesländern | 79 |
| Tabelle 4: Korrelationsmatrix..... | 89 |
| Tabelle 5: Rotierte Komponentenmatrix | 90 |
| Tabelle 6: Anzahl der Gemeinden je Faktorausprägung F01..... | 91 |
| Tabelle 7: Anzahl der Gemeinden je Faktorausprägung F02..... | 93 |
| Tabelle 8: Anzahl der Gemeinden je Faktorausprägung F03..... | 95 |
| Tabelle 9: Anzahl der Gemeinden je Faktorausprägung F04..... | 97 |
| Tabelle 10: Anzahl der Gemeinden je Faktorausprägung F05 | 99 |
| Tabelle 11: Anzahl der Gemeinden je Faktorausprägung F06 | 101 |
| Tabelle 12: Deskription der Regionstypen..... | 104 |
| Tabelle 13: Deskriptive Statistik der Regionstypen | 106 |
| Tabelle 14: Voraussetzungen Regression mit Zählvariablen Hidden Champions-Anzahl | 125 |
| Tabelle 15: Parameterschätzungen negativ binomiale Regressionen | 126 |
| Tabelle 16: Ergebnisse der multiplen Regression..... | 130 |
| Tabelle 17: Modell 2 Fixe Effekte (Deutschland insgesamt)..... | 136 |
| Tabelle 18: Modell 3 Random Effekte und Modellgüte (Deutschland insgesamt)..... | 136 |
| Tabelle 19: Random Effekte M4 (Deutschland insgesamt)..... | 137 |
| Tabelle 20: Fixe Effekte M4 (Deutschland insgesamt) | 138 |
| Tabelle 21: Interklassenkoeffizient (ICC) Modell 1 und Modell 2 | 140 |
| Tabelle 22: M1 Random Effekte..... | 141 |
| Tabelle 23: M2 Random Effekte..... | 142 |
| Tabelle 24: Regionstyp 1 M2 Fixe Effekte..... | 143 |
| Tabelle 25: Regionstyp 2 M2 Fixe Effekte..... | 144 |
| Tabelle 26: Regionstyp 4 M2 Fixe Effekte..... | 144 |
| Tabelle 27: Regionstyp 5 M2 Fixe Effekte..... | 145 |

| | |
|--|-----|
| Tabelle 28: Regionstyp 6 M2 Fixe Effekte..... | 146 |
| Tabelle 29: Regionstyp 7 M2 Fixe Effekte..... | 146 |
| Tabelle 30: Regionstyp 8 M2 Fixe Effekte..... | 147 |
| Tabelle 31: Regionstyp 9 M2 Fixe Effekte..... | 148 |
| Tabelle 32: M3 Random Slope Varianzen | 149 |
| Tabelle 33: Random und Fixe Effekte M4 Regionstyp 6 | 151 |
| Tabelle 34: Random Effekte M4 Regionstyp 9 | 152 |
| Tabelle 35: Ergebnisse der multiplen Regression..... | 154 |
| Tabelle 36: Nachbarschaftsverteilung nach der Queens-Kontiguität | 155 |
| Tabelle 37: Spatial Lag Modell..... | 156 |
| Tabelle 38: Direkte und indirekte Effekte Spatial Lag Modell..... | 157 |

Abkürzungsverzeichnis

| | |
|------|--|
| BBSR | Bundesinstitut für Bau-, Stadt- und Raumforschung |
| BIC | Bayesian Information Criterion |
| BRIC | Brasilien, Russland, Indien, China und Südafrika |
| BULE | Bundesministerium für Ernährung und Landwirtschaft im Bundesprogramm Ländliche Entwicklung |
| BWK | Bundesministerium für Wirtschaft und Klimaschutz |
| CSR | Corporate Social Responsibility |
| CWC | Center Within Cluster |
| EW | Einwohner:innen |
| F&E | Forschung und Entwicklung |
| GMM | Gaussian Mixture Model |
| GNML | Global Niche Market Leaders |
| HC | Hidden Champion |
| HLM | Hierarchisch lineare Mehrebenenanalysen |
| HTML | Hypertext Markup Language |
| ICC | Interklassenkoeffizient |
| KMU | Kleine und Mittlere Unternehmen |
| LAU | Lokal agierende Unternehmen |
| MAUP | Modifiable Areal Unit Problem |
| MBC | Model-Based-Clusteranalyse |
| MNU | Multinationale Unternehmen |

| | |
|------|--|
| MOEL | Mittel- und Osteuropäische Länder |
| NBR | Negativ binomiale Regression |
| NIS | Nationale Innovationssysteme |
| NLP | Natural Language Processing |
| RIS | Regionale Innovationssysteme |
| URL | Uniform Resource Locator |
| WZ | Wirtschaftszweig |
| ZEW | Leibniz-Zentrum für Europäische Wirtschaftsforschung |

1 Einleitung

Um die Wettbewerbsfähigkeit sowie Marktführerschaft in der deutschen Industrie auf internationaler Ebene zu halten und auszubauen, wurde durch die Bundesregierung die Industriestrategie 2030 formuliert (Bundesministerium für Wirtschaft und Energie 2019, S. 7-10). Einen maßgeblichen Beitrag leisten diesbezüglich mittelständische als auch große Industrieunternehmen. Besonders hervorgerufen wird eine Unternehmenskategorie, die sog. Hidden Champions (HC). Diese werden trotz ihrer geringen Anzahl (ca. 1.500) maßgebliche Triebkräfte zur Stärkung der Wirtschaft durch ihre unternehmerischen Aktivitäten und Strategien beschrieben (Simon 2022, S. 5). Um als ein HC zu gelten, müssen Unternehmen laut Simon (2012, S. 83) drei Kriterien erfüllen:

1. Maximalumsatz von fünf Milliarden Euro im Jahr
2. Weltmarktführerschaft im Nischenmarkt ihres Produktes: Top-3 weltweit oder Top-1 kontinental
3. Niedriger Bekanntheitsgrad in der Öffentlichkeit in Bezug auf das Unternehmen, dessen Dienstleistungen oder Produkte

Den HCs wird unter anderem ein stabilisierender Effekt zur Bewältigung von Wirtschaftskrisen (Rasche 2003, S. 220) und eine besondere Stellung in den lokalen Wirtschaftsräumen zugeschrieben (Rietmann 2021a, S. 10). Sie gelten als innovative Unternehmen, die Demonstrationseffekte auf andere Unternehmen in ihrer Region ausstrahlen, während sie überregional mehrheitlich im Verborgenen agieren. Die in der Regel hoch innovativen Unternehmen sind überwiegend in ländlichen Räumen angesiedelt (Simon 2012, S. 259, 381; Schenkenhofer 2022, S. 419). Inhaltlich wird dies mit einer historisch gewachsenen Standortwahl und der Anwendung von Kompensationsstrategien zum Ausgleich möglicher regionaler wirtschaftlicher Nachteile in der eigenen Region begründet. Inwieweit es sich hierbei um strukturstarke oder -schwache Regionen handelt, wurde bisher nicht untersucht.

Um strukturschwache Regionen wirtschaftlich zu stärken, liegt die Gemeinschaftsaufgabe „Verbesserung der regionalen Wirtschaftsstruktur“ der regionalen Wirtschafts- und Strukturpolitik als Instrument zugrunde (Bundesministerium für Wirtschaft und Klimaschutz 2023). Das übergeordnete Leitbild der Schaffung gleichwertiger Lebensverhältnisse wird durch die Stärkung der wirtschaftlichen Entwicklungspotenziale und die Verbesserung der Fähigkeiten zur Bewältigung der Transformationsprozesse angestrebt. Im Laufe der Zeit müssen hierzu neue

Einleitung

Blickwinkel eingenommen, Perspektiven diskutiert und fehlende Ansätze identifiziert werden (Audretsch & Feldmann 2004, S. 2715).

Das Wachstum und die Transformation der Wirtschaft basiert auf den prozessualen Grundlagen von Wissensgenerierung und Innovation (Bathelt et al. 2017, S. 8-9). Diese grundlegenden Triebkräfte fördern nicht nur das Unternehmenswachstum, sondern auch räumliche und strukturelle Veränderungen. In der Analyse der Verortung dieser Prozesse fand in den vergangenen Jahren ein Perspektivwechsel statt. Es wurden zunächst urbane Agglomerationsräume als Innovationsräume identifiziert und analysiert (Rodriguez-Pose & Fitjar 2013, S. 26). In der Forschung, in öffentlichen Debatten und bei politischen Entscheidungsträger:innen erfolgte die Annahme, dass periphere Regionen nicht die passende Ausstattung für innovative Aktivitäten haben und Städte die Hauptantriebskräfte für wirtschaftlichen Wohlstand sind (Shearmur 2012, S. 9). Glückler et al. (2022, S. 350) fassen die wissenschaftliche Diskussion um den Zusammenhang zwischen Innovation und Peripherie in drei Narrativen zusammen. In der ersten „Phase“ wird beschrieben, dass in peripheren Lagen *keine* Innovation stattfinden kann. Das zweite Narrativ beschreibt, dass Innovation *trotz* der peripheren Räume entsteht. An dritter Stelle wird auf Basis von Analysen von Innovation in der Peripherie argumentiert, dass diese *wegen* der peripheren Lagen stattfinden kann.

Vonnahme und Lang (2019, S. 20) begreifen Innovation als territorial gebundenen Prozess. Hier identifizieren die Autoren zwei wesentliche Punkte. Erstens die Dynamik der beteiligten (räumlichen) Prozesse und Akteur:innen, zweitens die Relevanz von Nähe, welche über den alleinigen Fokus auf räumliche Nähe hinaus geht (Boschma 2005, S. 63). Es lässt sich schlussfolgern, dass ein geeignetes institutionelles Umfeld die Wahrscheinlichkeit für erfolgreiche Innovationsprozesse erhöht (Glückler & Bathelt 2017, S. 130). Die Innovationstätigkeit und -fähigkeit wird als ein entscheidender Aspekt angesehen, um eine gesteigerte Wirtschaftsleistung in sog. abgehängten Regionen zu erreichen. Regionale Unterschiede der Wirtschaftsstruktur sind dabei das zentrale Element. In strukturschwachen Regionen werden unterschiedliche Kompensations- und Verwertungsstrategien verfolgt, die in Unternehmen Anwendung finden, um Innovationsbarrieren und -vorteile zu überwinden (Eder & Trippel 2019, S. 1512). Die erfolgreiche Kompensation und das Ausnutzen der geographischen Nachteile durch die lokalen Unternehmen selbst ist erforderlich, um Innovationen in abgelegenen Gebieten zu fördern (Virkkala 2007, S. 515; Eder & Trippel 2019, S. 1512). Dies hängt mit dem zielführenden Management, dem damit verbundenen hohen Kompetenzniveau und der Wissenserweiterung innerhalb der Unternehmen zusammen. Wie eingangs beschrieben, rückt eine spezifische Unternehmenskategorie

diesbezüglich regelmäßig in den Fokus, die sog. HCs welche der Untersuchungsgegenstand der vorliegenden Dissertation sind.

1.1 Übergeordnetes Forschungsinteresse

Vor dem Hintergrund der in der Einleitung beschriebenen Relevanz von HCs als Triebkräfte der deutschen Wirtschaft und der Relevanz der räumlichen Strukturen für die Innovation, ist es Ziel der vorliegenden Untersuchung zu verstehen, inwieweit die Anwesenheit von HCs innovationstreibende Strukturen von Gemeinden stärkt. Dazu wurden die Fragestellungen dieser Arbeit¹ in drei Teile gegliedert.

Das erste Ziel ist es, einen vergleichbaren methodischen Ansatz für ein besseres Verständnis der HC-Definition zu schaffen. Denn um die eingangs erwähnten Zusammenhänge zu untersuchen, ist die *Identifizierung des Untersuchungsgegenstandes* notwendig. Dazu wird ein Vorgehen für einen allgemein zugänglichen Ansatz der Operationalisierung von HCs entwickelt. Bisher existiert neben der historisch gewachsenen Auflistung Simons (2022) keine operationalisierte Identifizierung von HCs. Die Erstellung einer Datenbank aller in Deutschland angesiedelten HCs ist für das Vorhaben in dieser Arbeit erforderlich. Die Ausgangsdatenbasis der Identifizierung sind unternehmensbezogene Webdaten. Das Internet hat sich zu einer vielversprechenden Datenquellen entwickelt, welche in den letzten Jahren in der Wissenschaft an Relevanz und in den Erkenntnissen an Bedeutung gewonnen hat (Gök et al. 2015, S. 653-655). Für die wissenschaftliche Forschung kann die Analyse von unstrukturierten Webdaten den Zugang zu bisher ungenutzten Daten ermöglichen. Insbesondere die Messung der Innovationstätigkeit von Unternehmen auf Basis von Webseitendaten ist hier hervorzuheben (u. a. Kinne & Axenbeck 2020; Dörr et al. 2021; Li et al. 2018; Youtie et al. 2012).

Als zweites Ziel verfolgt die vorliegende Dissertation die *regionale Typisierung* der Gemeinden. Dies ist unterliegt dem Zweck nicht nur bundesweite generalisierende Aussagen über die HC-Verteilung und Wirkungszusammenhänge der Unternehmen und Regionen zu treffen. Ziel ist es die heterogenen sozioökonomischen Strukturen der knapp 11.000 Gemeinden Deutschlands zu erfassen und unterscheiden zu können (BKG 2016). Es werden Erkenntnisse erarbeitet, wie die

¹ Die vorliegende Monographie entstand im Kontext des Forschungsprojektes „Hidden Champions als zentrales Element für die Stabilisierung ländlicher Regionen in Zeiten der Digitalisierung“ (HiDi), gefördert vom Bundesministerium für Ernährung und Landwirtschaft im Bundesprogramm Ländliche Entwicklung (BULE). Die Erkenntnisse der Arbeit ergänzen als quantitative Methodenkomponente die Inhalte des Projektes, indem sie mit den Erkenntnissen Rietmanns (2022a) gebündelt werden.

Einleitung

Unternehmen in unterschiedlichen Raumtypen agglomeriert sind. Die Regionstypen sind dann weiterführend räumliche Untersuchungsgrundlage des abschließenden dritten Ziels dieser Dissertation.

An finaler Position werden die räumlich-strukturellen *Wirkungszusammenhänge* der HCs zu analysiert. Beginnend bei der Frage welche sozioökonomischen Faktoren auf die Anwesenheit von HCs einen Einfluss haben wird untersucht, inwieweit die als Treiber der deutschen Wirtschaft betitelten Unternehmen als Innovationstreiber in den unterschiedlichen Regionstypen gelten. Die Zusammenhänge werden analysiert und abschließend vor dem theoretischen Hintergrund diskutiert.

1.2 Struktur der Arbeit

Aufbauend auf den Zielsetzungen wird im Folgenden die übergeordnete Struktur der Arbeit beschrieben. Die Dissertation ist in drei Abschnitte gegliedert. Abschnitt *I. Theoretisch-konzeptionelle Grundlagen* beinhaltet Kapitel 2, in welchem die theoretischen Konzepte von Innovationen und Wissensgenerierungsprozessen dargelegt werden. Es folgt ein Unterkapitel zu den räumlichen Verteilungen von Innovationsaktivitäten sowie der Theorie zu Wissens-Spillovern. Weiter werden die Wettbewerbsstrategien nach Porter (2013) ausgeführt. Diese sind relevant als Grundlage für Kapitel 3, in dem die Klärung des HCs-Begriffs selbst sowie die Einordnung dieser in Porters Konzept folgt. Ziel ist es, in diesem Kapitel die allgemeinen Charakterzüge der HCs genau aufzuschlüsseln, um die Differenzierung zu klassischen Kleinen und Mittleren Unternehmen (KMU) deutlich zu machen. Die in diesem Kapitel aufgeführten Inhalte beschreiben zudem die Arbeitsdefinition der vorliegenden Arbeit. In Kapitel 4 erfolgt eine umfassende Literaturanalyse zu HCs. Dazu wurden Arbeiten mit besonderem Fokus auf die Definitionsmethodik und Datenverfügbarkeit bezüglich HCs betrachtet. Dies dient dazu, die Forschungslücke einer einheitlichen Identifikationsmethodik der HCs zu verdeutlichen. Weiter wird die Relevanz der Fragestellung dieser Arbeit im Innovationskontext aus räumlicher Perspektive verdeutlicht. Anschließend erfolgt in Kapitel 5 eine Ableitung und Ausformulierung der Forschungslücken und Fragestellungen. Das Kapitel fasst die theoretischen und konzeptionellen Grundlagen zusammen und ordnet sie in das Konzept der HCs ein, sodass die Forschungslücke deutlich wird.

Der Abschnitt *II. Methodik* beinhaltet Kapitel 6 bis 9. Kapitel 6 beschreibt das methodische Vorgehen dieser Arbeit, indem ein Überblick über das Framework gegeben wird. Es folgt die Beschreibung der Identifizierungsmethodik der HCs (Kapitel 7). Hier wird zunächst allgemein auf

Einleitung

Web Mining eingegangen, bevor das Vorgehen im Detail erläutert wird. Im nächsten Schritt beinhaltet Kapitel 8 die Methodik der Regionstypisierung. In Kapitel 9 geht es um die Anwendungen in der Analyse der räumlich-strukturellen Wirkungszusammenhänge.

Die Kapitel 10 bis 14 umfassen den finalen Abschnitt *III. Ergebnispräsentation und -diskussion* dieser Arbeit. Die inhaltliche Reihenfolge entspricht der im vorangehenden Kapitel ausgeführten Methoden. Der identifizierte HC-Datensatz wird in Kapitel 10 ausführlich beschrieben. Neben einigen allgemeinen Kennzahlen zum Datensatz erfolgt auch die Deskription der räumlichen Verteilung sowie die Präsentation einiger Fallbeispiele. In Kapitel 11 wird dann die Regionstypisierung präsentiert. Die Ergebnisse der Methoden zur Analyse der regionalen Wechselbeziehungen folgen in Kapitel 12. Die Ergebnisse werden in Kapitel 13 durch die Beantwortung der Forschungsfragen aus Kapitel 5 in den konzeptionellen, theoretischen und politischen Kontext eingeordnet. Die vorliegende Arbeit schließt mit der kritischen Würdigung der Methodik und Ergebnisse sowie mit einem Ausblick auf weitere neu identifizierte Forschungsfragestellungen im Kontext des Themas (Kapitel 14).

I: Theoretisch-konzeptionelle Grundlagen

2 Regionaler Innovationskontext

Der erste Teil des Kapitels zum regionalen Innovationskontext beschäftigt sich mit Innovationstheorien und Wissensentstehungsprozessen. Dies dient als theoretische Grundlage, um die in dieser Arbeit untersuchten Wechselwirkungen zwischen den als hoch innovativ geltenden HCs und ihren Regionen einzuordnen. Im anschließenden Kapitel 2.2 werden die Mechanismen von Spillover-Effekte beschrieben. Durch das theoretische Erfassen von Spillovern können grenzüberschreitende Effekte von HCs auf den Innovationsoutput und innovationssteigernde Einflussgrößen untersucht werden. Der Schwerpunkt wird in beiden Unterkapiteln auf die räumliche Perspektive dieser Konzepte gelegt, um diese Fokussierung der Analyse im Zusammenhang mit HCs zu begründen. Kapitel 2.3 stellt die unternehmerischen Wettbewerbsstrategien nach Porter (2013) dar. Diese dient in Kapitel 3 der konzeptuellen Einordnung der Unternehmensstrategie der HCs.

2.1 Innovationstheorien und Wissensgenerierungsprozesse

Innovation ist ein Prozess, in welchem Routinen verlassen werden, Risiken eingegangen und neue Kombinationen des beispielsweise in Unternehmen bestehenden Wissens zur allseitigen Weiterentwicklung zu erschaffen (Schumpeter 1911). Wissensentstehung und Innovation sind prozessuale Grundlagen der Weiterentwicklung und Veränderung von Wirtschaft und Gesellschaft (Bathelt et al. 2017, S. 8-9). Die Triebkräfte führen nicht nur zu Wachstum auf unternehmerischer, sondern auch auf geographischer, struktureller Ebene zu Weiterentwicklungen.

Um innovationsfördernde Handlungsempfehlungen zu entwerfen, gilt es dazu notwendige Interaktionen zu definieren und ihre Wirkungen zu verstehen (Bathelt et al. 2017, S. 3). Der Prozess basiert auf den Handlungen und Interaktionen zwischen Akteur:innengruppen. Er ist also sozial abhängig und dadurch in gewisser Weise unsicher (Lundvall 1992, S. 298). Die Ausgangspositionen, auf welchen das Wachstum fußt, gelten als nicht konstant, was im räumlichen Kontext zu Heterogenität zwischen Regionen führt. Um die komplexe Beziehung zwischen Innovation und den Institutionen besser zu verstehen, ist es notwendig, die räumliche Perspektive einzunehmen (Glückler & Bathelt 2017, S. 5). Innovationssysteme im räumlichen Kontext werden auf nationaler Ebene als Nationale Innovationssysteme (NIS) erfasst (Lundvall 1992, S. 234-235). Jedoch finden Innovation und Wissensentstehung nicht nur auf nationaler

Ebene homogen statt (Bathelt & Henn 2017, S. 457). Besonders die regionale Variation unterhalb der nationalen Ebene kann zu Innovationen führen und genauso auf das wirtschaftliche Handeln und die regionalen Institutionen wirken (Bathelt & Henn 2017, S. 467). Glückler und Bathelt (2017, S. 10) fassen in Ihrem Sammelband zusammen, dass die Literatur zu Regionalen Innovationssystemen (RIS) sich auf Innovationsnetzwerke konzentriert, die um Akteur:innen mit geographischer Nähe aufgebaut sind und von der Nähe beziehungsweise Affinitäten in relationalen, kognitiven und institutionellen Bereichen profitieren (u. A. Rallet & Torre 1999, S. 383; Rallet & Torre 2017, S. 423-424 ; Boschma 2005, S. 69).

Glückler und Bathelt (2017, S. 130) analysieren Mechanismen, die Innovationen aus räumlicher Perspektive fördern oder hemmen. Sie stellen fest, dass erfolgreiche Innovationsprozesse durch einen passenden institutionellen Kontext wahrscheinlicher werden. Ausschlaggebend ist hier die räumliche Variation der Wirtschaftsstruktur. Dazu ist im Prozess entweder die Innovation oder die Interaktionsmuster der beteiligten Akteur:innen anzupassen (Bathelt et al. 2017, S. 122). Die Autoren beschreiben, dass durch die Einnahme eines geographischen Blickwinkels die Ergebnisse eines Innovationsprozesses noch komplexer werden. Dies begründen sie damit, dass durch räumliche Disparitäten auch die Innovation und der wirtschaftliche Kontext noch stärker variieren. Der geographische Blickwinkel wird weiterführend als ausschlaggebend für die Variation in RIS und NIS betitelt. Entsprechend sind zielgerichtete politische Handlungsempfehlungen notwendig, um unterschiedliche Regionen zu fördern, denn aufgrund räumlicher Disparitäten besteht die Option erfolgreicher allgemeingültiger Handlungsmaßnahmen nicht. In einer globalisierten, lernenden Wirtschaft ist Innovation (im weitesten Sinne) für alle Regionstypen sinnvoll. Jedoch sind die Innovationsaktivitäten zur Sicherung der Wettbewerbsfähigkeit nicht in allen Regionen gleich (Tödling & Trippel 2005, S. 1204).

Während die Forschung zu RIS im Allgemeinen darauf ausgerichtet ist, regionale Innovationspolitik zu fördern, um die Wettbewerbsfähigkeit zu steigern und lokale Beschäftigung zu stärken, betonen Bathelt et al. (2017, S. 14) die bestehende Forschungslücke in Bezug auf periphere/ländliche RIS. Eder und Trippel (2019, S. 1512) beschreiben die negative Sicht auf periphere Lagen in der Innovationsforschung. Denn in einigen Beiträgen werden Agglomerationsräume als ausschlaggebende Triebkraft für Innovation betitelt (Glaeser 2011). Florida et al. (2017) beschreiben Städte sprichwörtlich als Innovationsmaschinen.

Eder (2019a) analysiert die in der Literatur vorherrschende "Unzufriedenheit" mit dem Fokus auf Agglomerationen und Konzentration basierenden theoretischen Rahmen der territorialen

Innovationsmodelle (TIM). TIM gehen davon aus, dass räumliche Nähe und Verstärkung vorteilhaft oder sogar zwingend notwendig für Innovationsentwicklung sind (Eder 2019a, S. 120). Unternehmen in peripheren Lagen könnten demnach nicht innovativ sein. Jedoch ist diese Perspektive mittlerweile häufig widerlegt worden (u. a. durch Moulaert & Sekia 2003; Crevoisier 2014). Die Innovation in Agglomerationsräumen ist der Literatur nach überwiegend radikal und patentbasiert schlussfolgert Eder (2019a S. 129-130). Außerdem beschreibt der Autor, dass die Verfügbarkeit von Mitteln und Wegen zur Verbreitung der Innovation häufiger in urbanen Räumen vorliegt, sodass die Innovation in ländlichen Räumen übersehen werden oder nicht diffundieren können. So bieten urbane Räume zwar viele innovationsverstärkende Voraussetzungen. Jedoch schließt dies Innovationen in ländlichen Regionen nicht aus. Auch ländliche Regionen können ein hohes Maß an Innovationskraft mit sich bringen, beispielsweise durch langfristig etablierte (persönliche) Verbindungen und Beziehungen. Unter Berücksichtigung institutioneller Rahmenbedingungen, sind die unterschiedlichen Innovationstätigkeiten zu analysieren (Bathelt et al. 2017, S. 14). Unternehmen in ländlichen Räumen sind innovativ. Allerdings sind die Prozesse divers und differenziert zu denen von Unternehmen in urbanen Räumen zu betrachten. Effiziente interne Organisation und strategischer Innovationsaufwand sind neben Verbindungen zu nicht lokalen Akteur:innen maßgeblich (Eder & Trippel 2019, S. 1209).

Eder und Trippel (2019) untersuchen in ihrem Beitrag die konkreten Innovationsvorteile und -herausforderungen peripherer Gebiete. Sie analysieren Kompensations- und Verwertungsstrategien, die Unternehmen anwenden, um Innovationshemmnisse zu überwinden und -vorteile zu nutzen. Dazu untersuchen sie insbesondere die Rolle klassischer Standortfaktoren in peripheren Lagen. Die Ergebnisse der Studie werden im Folgenden näher ausgeführt. Eder und Trippel (2019, S. 1513) beschreiben bezüglich der Innovationsherausforderungen ländlicher Räume sog. *dünne RIS* durch das Fehlen von Clustern und externer Effekten. Es sind häufig nur schwache organisatorische Unterstützungsstrukturen und ungünstige institutionelle Rahmenbedingungen gegeben. Der wissenschaftliche Konsens beschreibt entsprechend, dass Unternehmen in der Peripherie mehr strategische Anstrengung zur Generierung von Innovation benötigen als solche in urbanen Räumen. Durch die sog. geographische Isolation sind die Herausforderungen vor allem das niedrige Forschungsniveau sowie der dadurch einhergehende geringe Innovationsoutput (Tödling & Trippel 2005; Landabaso et al. 1999). Damit verbunden wird auch eine schwache Ausstattung mit innovationsfördernden Maßnahmen in peripheren Gebieten. Bezugnehmend auf die Narrative der peripheren Innovation (Glückler 2022, S. 235) gibt es vereinzelt Innovationen, die nur in der Peripherie stattfinden können. Hierbei handelt es sich beispielsweise um ortsspezifisches Wissen und Erkenntnisse

(Glückler 2014, S. 36). Innovation kann in der Peripherie leichter im „Verborgenen“ entwickelt werden, sodass durch Wissensaustausch lokale Innovation geschaffen werden kann. In der Literatur werden drei Kompensationsstrategien beschrieben. Zunächst die internen Kompetenzen nicht nur auf höchstem Niveau zu halten, sondern diese auch zu halten (Eder & Trippel 2019, S. 1516). Dies geschieht durch überregionale Verbindungen und Zusammenarbeit und an dritter Stelle der Teilnahme und Aufnahme von externem Wissen.

Die erste Kompensationsstrategie zielt wie genannt darauf ab, durch die erfolgreiche Kompensation von Standortnachteilen durch die Unternehmen, Innovation in der Peripherie zu fördern (Virkkala 2007, S. 515; Eder & Trippel 2019, S. 1512). Hiermit ist ein effizientes Management sowie hohe Kompetenz und Wissensaufbau in den Unternehmen gemeint. Eder und Trippel (2019, S. 1516) tragen die in der Literatur bisher identifizierten Kompensationsstrategien zusammen. Dazu gehören zunächst die erfolgreichen Globalisierungsreaktionen durch forschungs- und entwicklungsintensive Aktivitäten. Dies beinhaltet, dass periphere Unternehmen hochqualifizierte Fachkenntnisse generieren, indem sie international rekrutieren (Meili & Shearmur 2019, S. 503), Prozesse internalisieren (Doloreux & Shearmur 2012, S. 85) und eine hohe Absorptionsfähigkeit und -kapazität entwickeln, um Wissensquellen zu identifizieren und verwerten zu können (Grillitsch & Nilsson 2017, S. 305).

Die zweite Kompensationsstrategie beinhaltet überregionale nicht lokale Verbindungen, z. B. sog. *Global Pipelines* (Eder & Trippel 2019, S. 1516). Peripher gelegene Unternehmen können räumliche Nähe kompensieren, indem sie sich auf andere Dimensionen der Nähe und den Aufbau solcher Verbindungen über sog. Global Pipelines durch formale Zusammenarbeit stützen (Grillitsch & Nilsson 2017, S. 314). Es werden neue Technologien, Handel und Messen in nicht-lokalen Wissenspools ermöglicht (Eder & Trippel 2019, S. 1514). Die Unternehmen suchen gezielt nach Kooperationspartnerschaften und setzen dabei vor allem auf Netzwerke und soziales Kapital (Dubois 2016, S. 10; Fitjar & Rodríguez-Pose 2017, S. 37). Sie streben dabei als dritte Kompensationsstrategie einen konstanten Zufluss von externem Wissen an, indem sie beispielsweise an langfristigen (digitalen) Netzwerken partizipieren (Grabher & Ibert 2014, S. 105; Bathelt & Schludt 2010, S. 1958). Abschließend spielt aber auch die Größe, Branche und Kultur des Unternehmens bei der Kompensation der räumlichen Lage eine Rolle. Eder und Trippel (2019, S. 1514) erfassen diese Erkenntnisse basierend auf diversen Arbeiten (u. a. Beugelsdijk & Cornet 2002; Fitjar & Rodríguez-Pose 2011a, 2011b; Lorentzen 2007; Virkkala 2007). Wissensaustausch und Innovation profitieren also nicht nur von geographischer Nähe, sondern im Wesentlichen ebenfalls von kognitiven, organisatorischen, sozialen und institutionellen Formen der Nähe (Balland et al. 2015, S. 9; Boschma 2005, S. 64-69).

Beim Zusammentragen der Verwertungsstrategien der peripheren Unternehmen stellen Eder und Trippl (2019, S. 1516) fest, dass deren "abgelegener" Standort von Vorteil sein kann. Hier ist zu nennen, dass dieser den Markteintritt externer Konkurrenz erschweren kann (Doloreux 2003, S. 73) indem die Distanz unter Umständen unerwünschte Wissensübertragungen begrenzt (Grillitsch & Nilsson 2017, S. 1222). Dies erfolgt beispielsweise durch Abwerbung von Arbeitskräften. An zweiter Stelle nutzen Unternehmen ihren institutionellen Spielraum in der Peripherie (Polèse & Shearmur 2002, S. 182; Meili & Shearmur 2019, S. 505). Im Gegensatz zu engen Agglomerationsräumen mit hohem Andrang, lassen sich in ländlichen Räumen kleinere Gerichtsbarkeiten ggf. schneller an die Bedürfnisse regionaler Wirtschaftsakteure anpassen. Dies kann unter anderem auch mit der engen (vermeidlich auch persönlichen) Verbindung zwischen regionalen Politiker:innen und Unternehmer:innen verbunden sein.

Die dritte Verwertungsstrategie ist der potenzielle Kostenvorteil in der Peripherie (Eder & Trippl 2019, S. 1516; Oughton et al. 2002, S. 105; Meili & Shearmur 2019, S. 505). Günstigere Grundstücke und Nebenkosten ermöglichen höhere Investitionen in beispielsweise Forschungs- und Entwicklungs- (F&E) Aktivitäten. Auch weiche Standortfaktoren sind von Bedeutung (Dinis 2006, S. 15; Mayer et al. 2016, S. 8). So kann beispielsweise die Außenwirksamkeit einer Region durch Traditionen und Image zur Vermarktung bestimmter Produkte oder zur erfolgreichen Arbeitskräftebindung beitragen (Brydges & Hrac 2019, S. 518).

Eder und Trippl (2019, S. 1526) schlussfolgern, dass die Anwendung, der aus der Literatur zusammengetragenen Kompensations- und Verwertungsstrategien, in der Regel unterschiedlich ist und auf den individuellen regionalen und unternehmerischen Strukturen fußt. Weiter betonen sie, dass insbesondere der strukturelle Charakter ausschlaggebend für die Innovationsleistung einer Region sein kann.

2.2 Spillover-Effekte und räumliche Verteilung von Innovationsaktivitäten

Die Ausstattung einer Region mit Ressourcen dient der Steigerung neuen wirtschaftlichen Wissens (Audretsch & Feldman 2004, S. 2720; Feldmann 1994, S. 30-31). Dies gilt außerdem als Mechanismus zur Förderung von Spillovern in benachbarte Regionen und Unternehmen. Um grenzüberschreitende Effekte von HCs auf den Innovationsoutput und innovationssteigernde Einflussgrößen festzustellen, ist es notwendig das theoretische Konzept der Spillover-Effekte zu erörtern. Die thematische Einordnung erfolgt in Kapitel 5 zu den Forschungsfragen und Lücken.

Im Folgenden werden diese positiven Externalitäten betrachtet. Sie entstehen beispielsweise durch F&E-Investitionen, Humankapitalausstattung, Entrepreneurship (Audretsch & Feldman 2004, S. 2727-2728) und lokale Verbindungen/Netzwerke (Kiese 2018, S. 352; Bathelt & Turi 2011, S. 523), wobei die geographische Nähe mit gesteigerten Interaktionen einhergeht (Allen et al. 2016, S. 646-647). Jedoch reicht räumliche Nähe allein nicht aus, um Innovationstätigkeiten zu stärken (Allen et al. 2016, S. 639).

Um regionale Spillover-Effekte mit Innovation als Output auszulösen, werden drei übergeordnete Mechanismen benötigt (Blomström & Kokko 2001, S. 442-444). Diese werden im Folgenden grundlegend erläutert. Der aktuelle Diskurs der Literatur über die Wechselwirkungen zwischen Regionen und Unternehmen wird im Kontext räumlicher Nähe und sozioökonomischer Struktur dargestellt.

Der erste Mechanismus ist die *Vernetzung mit einheimischen Firmen*, hier sind insbesondere Zulieferer- und Abnehmerbeziehungen gemeint (Blomström & Kokko 2001, S. 442-444). Unternehmen erlangen von lokalen Unternehmen Produkt-, Prozess- oder Organisationswissen. Durch diese Beziehungen findet ein Wissensaustausch statt. Je höher die Intensität der Vernetzung ist, desto höher kann der Wissensaustausch sein. Ferner spielt die Art der Vernetzung eine Rolle. Handelt es sich um eine durch lokale Partner:innen, sind ebenfalls Spillover-Effekte zu erwarten. Die Autoren beschreiben, dass die Vernetzung zwar zu intensivem jedoch nicht zu vollumfänglichem Wissensaustausch führen kann. Beispiele für den Spillovermechanismus von multinationalen Unternehmen (MNU) auf lokale Firmen sind unter anderem die Förderung von lokalen Produktionsstätten der Zuliefernden, die Verbreitung von technologischem Wissen, die Unterstützung oder Bereitstellung von Rohstoffen und Teilprodukten, Schulungen und Weiterbildungsmöglichkeiten für Management oder auch die Hilfe der lokalen Lieferant:innen bei der Kund:innenaquise (Lall 1980). In der Literatur wird weiterhin diskutiert, in welche Richtung der Spillover mehr Auswirkungen hat. Blomström und Kokko (2001) unterscheiden hier zwischen *Backward Linkages* also externen Effekten von lokal agierenden Unternehmen (LAU) zum MNU und *Forward Linkages*. vom MNU zum LAU.

Der zweite Mechanismus ist die *Qualifikation von einheimischen Beschäftigten* (Blomström & Kokko 2001, S. 444-445). Unternehmen beschäftigen in der Regel aus der Region stammende Fachkräfte. Handelt es sich um Führungspositionen oder um Positionen, die eine spezialisierte Qualifikation erfordern, können diese alternativ auch extern besetzt werden. Diesbezüglich betreiben die Unternehmen Weiterbildungsaufwände für das Personal, um diese für ihre Bedürfnisse passend auszubilden. Der Wechsel qualifizierter Fachkräfte zu anderen regional

ansässigen Unternehmen fördert diese Spillover-Effekte, da sie das an sie gebundene implizite Wissen ebenfalls mitnehmen.

Der dritte Mechanismus sind sog. *Demonstrationseffekte* (Blomström & Kokko 2001, S. 445-446). Das erfolgreiche Handeln von Unternehmen kann andere dazu veranlassen, sich an den Verhaltensweisen dieser zu orientieren. Hier geht es beispielsweise um innovative Arbeitsweisen aber auch um Produkte oder Dienstleistungen.

Ähnlich wie in Kapitel 2.1 zur Innovationstheorie wird angenommen, dass Wissensspillover in ländlichen Räumen, welche weniger "enge" sozioökonomische Strukturen aufweisen, weniger ausgeprägt sind als in urbanen Räumen (Juhász & Lengyel 2018, S. 1205-1206). Dort herrschen größere geographische Distanzen, welche Wissensspillover erschweren können. Die sog. *Organizational Thinness* ländlicher Räume kann Innovationsgenerierung ausbremsen (Tödtling & Tripl 2005, S. 1209). Diese Annahmen beschreiben die bereits erwähnten TIM.

Geographische Nähe bringt parallel eine höhere Dichte und Zufälligkeit der Effekte mit sich, wodurch neben interaktiven auch einseitige Spillover wahrscheinlicher werden (Blomström & Kokko 2001, S. 445-446). Eine unmittelbare Konsequenz dieser Annahme ist, dass Netzwerke kollektives Lernen nur teilweise erklären können, da nicht-interaktives Lernen nicht zwingend Beziehungen oder soziale Netzwerke erfordert. Um die Vernetzung mit einheimischen Unternehmen zu steigern, kann die geographische Nähe den Umfang an Kommunikation mit regionalen Akteur:innen erhöhen und somit können Wissensübertragungsprozesse erleichtert werden (Allen et al. 2016, S. 646-647). Weiter gibt es Argumente für einen positiven Einfluss der geographischen Nähe zwischen Netzwerkpartnerschaften auf die Qualität der Zusammenarbeit (Juhász & Lengyel 2018, S. 1205-1206). Die regionale Anwesenheit steigert beispielsweise die Möglichkeit von Demonstrationseffekten. Räumliche Nähe schafft auf diese Weise Spillover-Effekte im Sinne eines *Local Buzz* (Bathelt et al. 2004, S. 12). Dieser beschreibt die gemeinsame Entwicklung einer institutionellen Struktur unterschiedlicher Akteur:innen, die an einem Ort angesiedelt sind. Die „bloße“ räumliche Anwesenheit in einer Region schafft bereits Wissensübertragungsprozesse, steigert die Innovation und die Wirtschaftsleistung (Glückler 2013, S. 888).

Whittington et al. (2009, S. 90) beschreiben, dass Unternehmen, die in keinen verbindlichen Netzwerken verortet sind, dennoch innovativ sein können, sofern sie geographisch nah zu solchen Industriennetzen verortet sind. Glückler (2013, S. 13) diskutiert in seiner Arbeit, dass die räumliche Anwesenheit oder Nähe die Wahrscheinlichkeit erhöht, dass sich neue Beziehungen entwickeln. Es reicht jedoch nicht aus, vor Ort zu sein, um von lokalem Wissen und Spillover-

Effekten nachhaltig zu profitieren. Wissens-Spillover können sowohl vertikal als auch horizontal stattfinden, sie können freiwillig oder unfreiwillig sein und der Transfermechanismus direkt oder indirekt (Autio et al. 2018, S. 79-80; Döring 2004, S. 96-97, Brökel et al. 2014, S. 2-3). Wissensspillover sind über größere Distanzen für internationalisierte, digitalisierte Unternehmen möglich. Ein überregionales Netzwerk spielt eine zentrale Rolle für den wirtschaftlichen Erfolg, ungeachtet des Unternehmensstandorts. Sie können selten in entweder urban oder peripher eingeteilt werden. Regionen können viele Nuancen beinhalten und sind selten einheitlich zu kategorisieren (Eder 2019a). Diese Charaktereigenschaften sind wirtschaftlicher, sozialer und politischer Natur und ausschlaggebend für die Analyse von Räumen. Weitere empirische Untersuchungen stellen Erklärungen für periphere Innovationen dar und widerlegen, wie oben bereits beschrieben, die Annahmen der TIM (siehe u. a. Eder 2019a; Verkalb, 2007; Rodriguez-Pose, 2011a; Petrov, 2011; Lagendijk & Lorentzen 2007; Mayer und Baumgartner 2014; Bathelt, Feldman & Kogler 2011; Danson & de Souza 2012, Shearmur et al. 2016).

Bathelt et al. (2004, S. 12) präsentieren in ihrer Arbeit das Framework der Global Pipelines und des Local Buzz. Wissen wird demnach auch auf globaler Ebene verteilt, was besonders relevant für hoch spezialisierte Nischenunternehmen und Innovator:innen ist. Diese Internationalisierungsstrategie, so argumentieren Fitjar und Rodrigues-Pose (2011b, S. 1264), löst das regionale Umfeld in seiner Relevanz ab. Geographische Nähe ist demnach im Kontext anderer Nahedimensionen zu betrachten (Boschma 2005, S. 69). Periphere Räume können über institutionelle, kognitive und technologische Nähe geprägt und vernetzt sein, um den Innovationsprozess voranzutreiben. Eder und Trippel (2019, S. 1516-1517) beschreiben, dass für internationalisierte Spitzenunternehmen, unter der Annahme, dass sie über Global Pipelines verfügen, der Standort für ihren Erfolg in diesem Sinne irrelevant ist. Wissens-Spillover sind also auch über größere Distanzen durch internationalisierte, digitalisierte Unternehmen möglich. Glückler (2022, S. 235) schildert, dass die Unternehmen gerade durch ihre periphere Lage innovativ sein können. Der begrenzte Raum bietet Möglichkeiten für Kreativität (Grabher 2018, S. 1791).

2.3 Wettbewerbsstrategien

Im folgenden Unterkapitel wird auf das Modell der langfristigen unternehmerischen Wettbewerbsstrategien nach Porter (2013) eingegangen, um im Verlauf der Arbeit die Strategien der HCs einzuordnen und auf den theoretischen Rahmen zu beziehen. Porter (2013, S. 73) beschreibt in seinem Werk, dass Unternehmen Wettbewerbsstrategien nutzen, um fünf zentrale Wettbewerbskräfte zu lenken. Dazu gehören die Verhandlungsstärke der Lieferant:innen,

Bedrohung durch Konkurrenz, Verhandlungsmacht der Abnehmenden, Bedrohung durch Ersatzprodukte und Rivalität unter den bestehenden Unternehmen der Branche (Porter 2013, S. 36). Gemeinsames Ziel der Unternehmen ist es, den eigenen Ertrag zu steigern. Porter (2013, S. 73) beobachtet drei generische Wettbewerbsstrategien, welche das Ziel haben, die langfristige Erfolgsposition zu erreichen und zu halten. Hierbei handelt es sich um *Umfassende Kostenführerschaft*, *Differenzierung* und *Konzentration auf Schwerpunkte* (s. Abbildung 1). Im Folgenden wird auf die funktionalen Unterschiede der drei Strategien eingegangen.

Abbildung 1: Unternehmerische Wettbewerbsstrategien

| | | Strategischer Vorteil | |
|--------------------------|---------------------------------|--|-------------------------------|
| | | Singularität aus der Sicht des Kaufenden | Kostenvorsprung |
| Strategisches Zielobjekt | Branchenweit | Differenzierung | Umfassende Kostenführerschaft |
| | Beschränkt auf ein Marktsegment | Konzentration auf Schwerpunkte | |

Quelle: Eigene Darstellung nach Porter (2013, S. 74).

Folgt ein Unternehmen der Strategie der *Umfassenden Kostenführerschaft*, setzt es sich zum Ziel, einen Kostenvorteil innerhalb der Branche zu etablieren (Porter 2013, S. 74). Dazu wendet das Unternehmen verschiedene Maßnahmen an. Beispielsweise *“Produktionsanlagen [in] effizienter Größe, energisches Ausnutzen von erfahrungsbedingter Kostensenkung, strenge Kontrolle von variablen Kosten und Gemeinkosten, Vermeidung von marginalen Kunden und Kostenminimierung in Bereichen wie Forschung und Entwicklung, Service, Vertreterstab, Werbung und so weiter”* (vgl. Porter 2013, S. 74). Die gesamte Strategie fußt auf niedrigen Kosten in direkter Konkurrenz zu anderen Wettbewerbern in der Branche oder im Produktsegment. Parallel sind andere Bereiche wie Kund:innenservice oder Produktqualität nicht außer Acht zu lassen. Die Strategie kann zu Branchenrevolutionierung und Marktanteilumverteilungen führen. Sind Wettbewerber beispielsweise nicht darauf vorbereitet, dass ein Konkurrent eine massive Kostenminimierung durchführt, kann dies zu großen Umverteilungen der Marktanteile führen. Porter (2013, S. 75-76) führt das Beispiel eines Maschinenherstellers an, der im produzierenden Gewerbe den Materialgehalt verringert, Prozesse auslagert und auf Fließbandmontage umstellt. Durch eine erfolgreiche Bestellung von großen Mengen an Einzelteilen kann das Unternehmen mit dennoch akzeptabler Produktqualität überzeugen und steigert seinen Marktanteil von 15 auf 25 Prozent.

Der zweite Strategietyp ist die *Differenzierungsstrategie* (Porter 2013, S. 76). Es geht darum, eine Dienstleistung oder ein Produkt zu schaffen, welches in der entsprechenden Branche einzigartig ist. Diese Differenzierung kann in unterschiedlichen Formen durchgeführt werden. Ob in der Technologie oder ausschließlich im Markennamen, im Design oder Kund:innendienst, die Differenzierung kann in einzelnen dieser Segmente sowie im sog. Idealfall in mehreren stattfinden. Anders als in der umfassenden Kostenführerschaft ist die Kostenseite zwar von großer Relevanz, allerdings nicht als übergeordnetes Strategieziel zu sehen. Porter (2013, S. 76-77) beschreibt, dass die Differenzierungsstrategie zu überdurchschnittlichen Erträgen führen kann. Bezogen auf die fünf Wettbewerbskräfte kann sie durch Einzigartigkeit gegen den Wettbewerb ankommen. Sie führt dazu, dass sich Mitarbeitende an die Marke oder das Unternehmen binden, genauso wie Kund:innen, die eine gewisse Loyalität zum Anbietenden empfinden. Es entstehen überdurchschnittliche Ertragsspannen und auf Kund:innenseite eine Preisunempfindlichkeit. Dies hat Auswirkungen auf die Zuliefer:innen- und Lieferant:innenbeziehungen. Porter (2013, S. 77) beobachtet, dass die Differenzierung in der Regel nicht mit Marktführerschaft in Verbindung gebracht wird, da sie oft einen exklusiven Nischenruf hat. Dennoch betont der Autor, dass in manchen Branchen gerade die Differenzierungsstrategie mit dominanten Marktanteilen verknüpft ist, da die Produktalternativen fehlen.

Als dritte Strategie benennt Porter (2013, S. 77-78) die *Konzentration auf Schwerpunkte*. Beispielsweise bedient ein Unternehmen ein bestimmtes Segment einer Produktpalette, eine bestimmte Kund:innengruppe oder einen geographisch begrenzten Markt. Die anderen beiden oben beschriebenen Wettbewerbsstrategien beziehen sich auf ganze Branchen. Bei der Konzentration auf Schwerpunkte wird ein konkretes, eng begrenztes strategisches Ziel angestrebt und alles darauf ausgerichtet. Parallel erfolgen eine Differenzierung und/oder niedrige Kosten in der entsprechenden Marktnische. So kann das Unternehmen, welches in seiner Strategie die Konzentration auf Schwerpunkte verfolgt, den Wettbewerbskräften entgegenstehen. Dennoch beinhaltet diese in der Regel einen Zielkonflikt zwischen Rentabilität und Maximalumsatz. Die Strategien sind in Abbildung 1 dargestellt.

Wie oben beschrieben, ist es notwendig, dass wenn Unternehmen sich auf ein Marktsegment beschränken, ergänzend die Differenzierungsstrategie oder die umfassende Kostenführerschaft zu verfolgen ist, um sich nachhaltig erfolgreich zu positionieren (Porter 2013, S. 82). Für unternehmerischen Erfolg ist es notwendig, dass Unternehmen sich auf eine Strategie fokussieren und diese langfristig verfolgen. HCs sind klar in die unternehmerischen Wettbewerbsstrategien nach Porter (2013) einordnen. Darauf wird in Kapitel 3 bezuggenommen.

3 Die Unternehmenskategorie Hidden Champion

In diesem Kapitel wird der HC-Begriff definiert und deren unternehmerische Charakterzüge präsentiert. Die Erkenntnisse dieses Kapitels stützen sich vor allem auf den Arbeiten von Simon, der den Begriff der HCs in den frühen 1990er Jahren prägte. Bis dato konnte der Autor 1.573 HCs im deutschen Raum identifizieren und verorten (Simon 2021, S. 42).

3.1 Begriffsklärung

Bei HCs handelt es sich um eine Kategorie von Unternehmen. Sie sind in der Regel über die allgemeine Definition eines KMU hinausgewachsen (Umsatzgrenze max. 50 Millionen Euro, unter 250 Mitarbeitende (IfM 2023)) und dennoch nicht als Großunternehmen einzuordnen. Simon formulierte 1992 drei Identifizierungskriterien, die ein Unternehmen erfüllen muss, um als HC zu gelten (Simon 2012, S. 84; s. S. 2 dieser Arbeit). Diese Kriterien generierte der Autor auf der Basis empirischer Untersuchungen, welche über Jahrzehnte durch Erhebungen und Analysen immer wieder reflektiert und aktualisiert wurden (1996a, 2007, 2009, 2012). Ein großer Anteil wissenschaftlicher Arbeiten zu HCs fußen auf dieser Definition (Schenkenhofer 2022, S. 423-443). Viele Autor:innen dehnen sie jedoch aus oder passen die Kriterien zur Operationalisierung ihrer Untersuchungen an. In der vorliegenden Arbeit wird die Definition von Simon (2012, S. 83) verwendet.

Zunächst ist ein HC durch die maximale Umsatzgrenze von fünf Milliarden Euro zu definieren. Die Grenzen dieses Kriteriums wurden seit 1996 mehrfach nachjustiert. Die maximale Umsatzgrenze wurde den Ergebnissen der jeweils aktuellen Analysen angepasst. Die ersten Primärdatenerhebungen zu deutschen HCs ergaben einen maximalen Umsatz von 1,5 Milliarden Deutsche Mark (Simon 1996a, S. 14). 2005 wurde dieser zunächst auf drei Milliarden Euro und 2012 erneut auf fünf Milliarden Euro angehoben (Simon 2012, S. 83). Diese Obergrenze erfasst ebenfalls Großunternehmen (Institut für Mittelstandsforschung (IfM) 2023; Simon 2012, S. 84). Um die Umsatzobergrenze nachzuvollziehen, wurde bei dieser Einordnung ein Vergleich mit den Umsätzen ebenso global agierender Nicht-HCs herangezogen (Simon 2018, S. 5). Betrachtet man beispielsweise die *Fortune Global 500* (2018) lässt sich feststellen, dass das kleinste hier aufgeführte Unternehmen dennoch einen fünfmal höheren Umsatz als die HC-Umsatzobergrenze vorzuweisen hat. 2017 lag der Durchschnittsumsatz der von Simon (2018) betrachteten HCs bei 325 Millionen Euro. Entsprechend sind HCs eindeutig von den Großunternehmen aus den *Fortune Global 500* zu differenzieren. Da auch kleinste Unternehmen mit geringem Umsatz global

Die Unternehmenskategorie Hidden Champion

erfolgreich agieren können, gibt es für HCs keine Untergrenze des Umsatzes. Das Kriterium wird im Rahmen dieser Arbeit als *Umsatz-Kriterium* bezeichnet.

Das zweite Kriterium betrifft die Höhe des relativen Marktanteils des Unternehmens (Simon 2012, S. 83). Um das Kriterium zu erfüllen, muss es weltweit zu den Top-3-Unternehmen in seinem Marktsegment gehören oder auf seinem Kontinent führend sein. Das Kriterium wird im Rahmen dieser Arbeit als *Champions-Kriterium* bezeichnet.

Das dritte Kriterium zur Identifizierung eines HCs ist der geringe Bekanntheitsgrad in der breiten Öffentlichkeit (Simon 2012, S. 83-84). Dieses Kriterium gilt als kaum quantifizierbar und somit schwer zu überprüfen. Die Unbekanntheit der Unternehmen ist differenziert zu begründen. Viele HCs agieren beispielsweise im Business-to-Business (B2B)-Bereich, sodass sie der Endkundschaft oder den Verbrauchenden weitestgehend unbekannt bleiben. Ein Grund für die allgemein geringe Kommunikation nach außen ist beispielsweise, dass das von ihnen beherrschte Marktsegment weiter im Verborgenen bleiben kann. Einzelne Hidden Champions stehen mit Marktanteilen zwischen 70-90 Prozent an der Spitze ihres Segments und können deswegen ohne große Konkurrenz die Markführerschaft leichter halten. Das Kriterium spielt für diese Firmen eine übergeordnete Rolle. Oft agieren HCs tief in der Wertschöpfungskette der Produktion (Simon 2012, S. 97). So bieten sie Maschinen, Software oder Prozesse an, die für das Endprodukt oder in der Leistung nicht mehr offensichtlich sind. Außerdem gelten sie als verschwiegen und wenden ihre Erfolgsstrategien im Verborgenen an. Ihnen liegt wenig daran, in den Fokus der Öffentlichkeit zu geraten. HCs sind Unternehmen, welche eher auf Innovation und Zielverfolgung als Außendarstellung setzen (Simon 2012, S. 99). Sie schätzen einerseits die Geheimhaltung und sind dennoch in der Lage Spillover auf andere Unternehmen in ihrer Region zu verursachen (Rietmann 2021a, S. 10). Entsprechend sind sie in ihrem Markt sowie bei ihrer Kundschaft besser bekannt (Simon 2012, S. 99). Kontinuierliches Wachstum steuert der Unbekanntheit entgegen, sodass nach und nach Marken durch beispielsweise ihre überdurchschnittliche Reputation bekannter werden. Simon (1996) nennt in seiner Studie das Kriterium des geringen Bekanntheitsgrades als "*nur qualitativ geschätzt*". Auch in den folgenden Jahrzehnten sind Versuche, den geringen Bekanntheitsgrad zu messen, selten geblieben. Collins (2016) untersucht den Zusammenhang zwischen unternehmerischem Erfolg und der Häufigkeit, mit der die Unternehmensleitung in der Öffentlichkeit auftritt. In diesem Sinne stimmt er zu, dass Unternehmen langfristig eher erfolgreich sind, wenn sie im Verborgenen bleiben. Entsprechende Strategien für HCs sind noch nicht erforscht worden. Diese Unbekanntheit wird im Rahmen dieser Arbeit als *Hiddenness-Kriterium* benannt.

3.2 Unternehmerischer Charakter

Das folgende Kapitel fasst die von Simon (2012) identifizierten unternehmerischen Charakterzüge von HCs zusammen. Es ist notwendig, den HC definitionsgerecht zu verstehen, um im Folgenden der Arbeit die Abweichungen anderer Autor:innen zu erkennen und unterscheiden zu können. Dazu sollten die unterschiedlichen Facetten der Unternehmen besprochen werden. 46,2 Prozent aller weltweit identifizierten HCs, sind in Deutschland angesiedelt (bis dato 1.573) (Simon 2021, S. 42). Weiter besitzen die HCs in ihren Weltmärkten übergeordnete Marktpositionen und sind häufig zu global agierenden Unternehmen herangewachsen (Simon 2012, S. 109). Ihre Produkte sind in der Regel unauffällig und einzigartig, wodurch es auf den ersten Blick verwunderlich scheint, dass die Unternehmen mit ihrem Portfolio bestehen. Diese *Überlebensfähigkeit* ist ihr herausragender Charakterzug.

HCs sind ambitionierte Unternehmen, die kontinuierliches Wachstum benötigen, um am Markt zu bestehen (Simon 2012, S. 12). Langfristige auf die internationale Marktführerschaft ausgerichtete Ziele sind der Kern ihres wirtschaftlichen Handelns. Im Grunde kann die übergeordnete Strategie der HCs in zwei sog. Säulen aufgeteilt werden: *Fokussierung und Tiefe* sowie *Internationalisierung*. Die sogenannte *Zwei-Säulen-Strategie* der HCs fasst diese zusammen. Ursprung dieser Erfolgsstrategien ist die genaue Marktdefinition (Simon 2007, S. 85). HCs spezialisieren sich auf sehr konkrete Marktsegmente (Rammer & Spielkamp 2015, S. 12; 24). Sie streben einen hohen Grad der Spezialisierung an, um strategisch in die Markttiefe zu wachsen, statt sich in die Marktbreite auszudehnen (Simon 2007, S. 115-116; 2018, S. 9). Anhand dessen umgehen sie die bestehende Gefahr der Marktengen, welche sich negativ auf die unternehmerischen Wachstumsmöglichkeiten auswirken kann (Simon 2007, S. 119-120; Venohr & Meyer 2007, S. 15-17). Die Größenvorteile lassen sich generieren, indem die HCs ihre Nischen nicht nur lokal, sondern global vermarkten.

In Kapitel 2.3 wurden die unternehmerischen Wettbewerbsstrategien nach Porter (2013) vorgestellt. HCs verfolgen diesbezüglich die Strategie der Konzentration auf Schwerpunkte in einem Marktsegment (Rasche 2003, S. 218-219; Porter 2013, S. 73). HCs agieren selten preisorientiert (Strategie der umfassenden Kostenführerschaft), sondern fokussiert sich eher auf die Spezialisierung (Strategie der Konzentration auf Schwerpunkte, Differenzierungsstrategie). HC erweitern die Nische, in der sie tätig sind, durch Internationalisierung und entgehen so der Gefahr der Marktengen. Parallel treiben sie die Spezialisierung weiter voran. Entsprechend entstehen Wettbewerbsvorteile wie Skalen- und Verbundeffekte, dank denen es den HCs möglich

ist, ihre Marktposition weiter auszubauen. Hier sind die durch Simon (2018) dargestellten Säulen wiederzufinden.

Zwei Drittel der Hauptsitze von deutschen HCs sind in ländlichen Räumen angesiedelt (Simon 2012, S. 382). Die Unternehmen prägen ihren Standort und die Standorte wiederum die Unternehmen: obwohl in der breiten Öffentlichkeit unbekannt, sind die HCs meistens die größten Arbeitgebenden der Regionen und lokal bekannt. Die Gründer:innen und/oder das Management sind häufig in der jeweiligen Region aufgewachsen und identifizieren sich mit ihr genauso wie die Mitarbeitenden.

3.3 Fokussierung und Tiefe durch Innovation

HCs halten ihre Märkte eng und erarbeiten sich eine langfristige starke Position in diesen (Simon 2012, S. 165). Dadurch bleiben die (Welt-)Märkte in der Regel klein. Die Fokussierung auf den (Nischen-)Markt beinhaltet eine Kund:innenorientierung und Konzentration auf bestimmte Zielgruppen sowie das Produkt selbst und die dahinterstehende Technologie. Schlüsselement ihrer Position ist häufig die technologische Führung (Zastempowski 2011, Schenkenhofer 2022). Dadurch ist die Kundschaft von den HCs, und die HCs durch die Fokussierung von den entsprechenden Kernmärkten, abhängig (Simon 2012, S. 166). Teilweise ist das Marktrisiko dadurch höher und gleichzeitig das Konkurrenzrisiko gesenkt. Eine nachhaltige Konzentration auf ihre Marktnische und eine strenge Definition dieser sind antreibend für die Weltmarktführung der Unternehmen (Simon 2012, S. 166).

HCs halten und steigern ihre Marktposition durch ständige Innovationen und Internationalisierung (Simon 2018, S. 11; 2012, S. 165). Ausgaben für F&E sind in der Regel doppelt so hoch im Vergleich zu Nicht-HCs (Simon 2012, S. 259; Kaudela-Baum et al. 2014, S. 2; Zastempowski 2011). Die Innovationen sind weniger disruptiver als vielmehr inkrementeller Natur (Schenkenhofer 2022, S. 446). Disruptive Innovationen dienen im Kontext des Unternehmenserfolgs von HCs zum primären Ausbau einer Vorreiterrolle mit spezifischem Produktfokus (Rammer & Spielkamp 2015, S. 22; Simon 2007, S. 220-221). Inkrementelle Innovationen kommen häufiger vor und tragen dazu bei, die Marktposition der HCs nachhaltig zu festigen. In Simons (2012) Forschungsarbeit stellt er fest, dass HCs aggregiert auf 1.000 Mitarbeitende ca. fünf Mal so viele Patente zu einem Fünftel der Kosten anmelden als patentstarke Großunternehmen (Simon 2012, S. 259). Weitere Forschungsarbeiten (Rammer & Spielkamp 2015; 2019a) bestätigen durch den Vergleich mit Kontrollgruppen, dass HCs bei ähnlichen Ausgaben für F&E deutlich mehr innovieren. Venohr und Meyer (2007) beschreiben dies als

Die Unternehmenskategorie Hidden Champion

Resultat der Prozesseffizienz. Die Differenzierung und Spezialisierung, vordefiniert als unternehmerische Erfolgsstrategie, beinhaltet kontinuierliche Innovationen in der Organisation und in den unternehmensweiten Arbeitsprozessen. So gelingt es den HCs, den Vorsprung auszubauen. Die globale Marktführerschaft in ihrem Segment ist durch technologische Führung, Spezialisierung, strategisches Netzwerken und große Investitionen in Fachkräfteweiterbildung und -bindung zu erreichen (Rammer & Spielkamp 2019a).

Die Unternehmensstrategie der HCs besteht häufig darin, dass HCs mehrere Teile der Wertschöpfungskette abdecken (Simon 2012, S. 185-186). Dies wird als Tiefe betitelt. Der enge Markt wird so durch ein tiefes Angebot an Leistungen bespielt und treibt das Wachstum der Unternehmen an. Outsourcing im Kerngeschäft ist kaum vorhanden. Der Durchschnitt der Wertschöpfungstiefe liegt bei 42 Prozent, die Fertigungstiefe bei 50 Prozent (Deutschland: Industrie durchschnittlich 30 Prozent) (Simon 2012, S.185). Viele HCs fertigen neben den Endprodukten zusätzlich ihre eigenen spezialisierten Maschinen zur Herstellung dieser an. Neben der Tiefe in der Produktion besteht ein Kern dieser Strategie vor allem in der F&E der HCs (Simon 2012, S. 178-179). So investieren HCs in ihre wissensbasierte Eigenständigkeit, um interne Innovationen inkrementell und kontinuierlich voranzutreiben (Simon 2012, S. 185; Kaudela-Baum 2014, S. 75-78). Prozessinnovationen sind dabei häufig bedeutsamer als Produktinnovationen (Kaudela-Baum 2014, S. 75).

Für HCs ist die eigene Unternehmensunabhängigkeit besonders wichtig, weshalb sie in der Regel strategische Allianzen ablehnen (Rammer & Spielkamp 2015, S. 20). Ein stetiger Austausch mit Wissenschaft und Kundschaft und die damit einhergehende Zusammenarbeit in F&E ist für HCs, wie bereits beschrieben, jedoch unabdingbar (Simon 2007, S. 216). Diese Netzwerke stärken die Innovationskraft und liefern der Kundschaft ein spezialisiertes Leistungsangebot. Inhalte der Innovationen dienen der Befriedigung von Kund:innenwünschen und -anforderungen (Voudouris et al. 2000; Simon 2018, S. 10; Riisalu & Leppiman 2013). Die Nähe zur Kundschaft der HCs trägt außerdem dazu bei, das Angebot ihrer Leistungen exakt auf die Anforderungen und Wünsche dieser anzupassen (Schlepphorst et al. 2016, S. 4; Simon 2007, S. 187-188). Die engen Beziehungen entstehen, da die Anforderungen der Kundschaft bei den HCs an erster Stelle stehen. Ein ausgeprägter Service trägt dazu bei, diese Leistungen konsequent zu erhalten und auszubauen (Simon 2018, S. 10). Drei Viertel der HCs sind im Direktvertrieb tätig. Dies trägt dazu bei, dass ein natürlicher und konstanter Austausch besteht und die Kundschaft als Leistungstreiber wahrgenommen werden können (Simon 2012, S. 211). Dies fördert die permanente Optimierung der Fertigungstiefe und spiegelt sich sowohl in Dienstleistungen, Marketing, Technologien und Produkten als auch in Systemen und Prozessen wider (Simon 2012, S. 259).

Die Unternehmenskategorie Hidden Champion

Um die Innovationskraft der HCs zu erhalten, gelten besonders hochqualifizierte Beschäftigte als wichtige Ressource (Schlepphorst et al. 2016, S. 4). So bedeuten die internen Kompetenzen, dargestellt in dem Engagement der Mitarbeitenden, die Ausgangslage für externe Wettbewerbsvorteile in Bezug auf Produktqualität, Service, Beratung und Systemintegration (Simon 2012, S. 391). HCs bieten diverse unternehmensinterne Weiterbildungsangebote an, um ihre Mitarbeitenden für ihre Bedürfnisse aus- und weiterzubilden. Sie setzen in der Mitarbeitendenführung vor allem auf Dezentralisierung und Teamarbeit, um die Motivation und den Einsatz zu stärken (Rammer & Spielkamp 2015, S. 30). Die Fluktuationsrate ist im Resultat bei den deutschen HCs sehr gering. 2007 lag sie bei lediglich 2,7 Prozent, mit einer durchschnittlichen Betriebszugehörigkeit von 37 Jahren (Simon 2007, S. 305-306). Deutschland weist im allgemeinen Vergleich seiner gesamten Unternehmenslandschaft einen Durchschnittswert von neun Prozent auf, was etwa elf Jahren Betriebszugehörigkeit entspricht. Durch die geringe Fluktuation kann das Wissen gebündelt und können Kosten gespart werden (Simon 2012, S. 391). Eine hohe Fluktuation ist besonders dann nachteilig, wenn Arbeitgebende hoch spezialisierte Fachkräfte benötigen, welche auf dem Arbeitsmarkt schwer zu akquirieren sind (Simon 2007, S. 305-306). Dies trifft auf HCs zu, die durch die Fokussierung in Nischenbranchen einen hohen Bedarf an spezialisierten, hochqualifizierten Arbeitskräften haben. Eine geringe Fluktuationsrate lässt HCs langfristig von dem Knowhow der Mitarbeitenden profitieren und ermöglicht eine nachhaltige Förderung ihres Markterfolgs. Dass zwei Drittel der identifizierten HCs in ländlichen Räumen angesiedelt sind, wird ebenfalls als Vorteil der Mitarbeitendenbindung gesehen (Simon 2012, S. 382). Da das Angebot an Arbeitsplätzen sowie Fachkräften hier niedriger ist, besteht eine gewisse gegenseitige Abhängigkeit. Die Gewinnung von hochqualifiziertem Personal stellt von Unternehmensseite einen großen Nachteil dar (Simon 2012, S. 391).

Die Fokussierung auf (Nischen-)Markt und Tiefe birgt neben der Stärke der HC-Strategie einige Risiken (Simon 2012, S. 163). Zunächst ist dies die Abhängigkeit des Marktes, auf welchem die HCs agieren. Ferner ist die Marktnische der HCs angreifbar. Handelt es sich beispielsweise um hochpreisige Premiumprodukte, können diese durch Standardprodukte der Konkurrenz in ihrer Vorreiterposition auf dem Markt gefährdet sein. An dritter Stelle steht das potenzielle Herauspreisen aus dem Markt. So produzieren HCs häufig an Hochlohnstandorten und auch das geringe Volumen ihres Marktes kann hier einen preisbezogenen Einfluss nehmen. Fokussieren sich HCs also auf eine Kostenführerschaft allein, kann dies zu einem Geschäftsrisiko werden. Die überwiegende Zahl der untersuchten HCs wenden die Strategie der Konzentration auf Schwerpunkte an (Porter 2013). Dazu muss der Markt ständig beobachtet werden, um technologische Veränderungen sowie Bedürfnisse und Kundschaft frühzeitig zu erkennen und

darauf einzugehen. Innovation kann das Markt- und Wettbewerbsrisiko entsprechend minimieren (Simon 2012, S. 164).

3.4 Internationalisierung

Die Fokussierung und Tiefe der HCs birgt also Risiken der Marktengung und fungiert nicht allein als Treiber des Erfolgs (Simon 2012, S. 187). Globale Vermarktung ist der Schlüssel, um den Nischenmarkt zu vergrößern. Internationalisierung stellt eine der beiden strategischen Säulen der HCs dar. Generell die Frage nach dem Exporterfolg Deutschlands in den 1990er Jahren brachte Simon den Impuls, den Mittelstand genauer zu betrachten (Simon 2012, S. 53-54). Seine Erkenntnis ist, dass der Export Deutschlands nicht ausschließlich auf seinen internationalen Großunternehmen fußt, sondern vor allem auf dem Mittelstand und insbesondere den HCs. Die globale Denkweise der HCs führt zur Internationalisierung. Sie internationalisieren durch unterschiedliche Auslöser. So ist beispielsweise die Kund:innennähe zu benennen, die ein unabdingbarer Faktor in der Erfolgsformel von HCs und durch Dezentralisierung und Internationalisierung auch auf ausländischen Zielmärkten gegeben ist (Simon 2012, S. 231). HCs internationalisieren stärker als Nicht-HCs, häufig schon direkt nach deren Gründung (Simon 2012, S. 131). Während dies dennoch eher inkrementell geschieht, lernen HCs schnell und es wird nicht zwischen räumlich nahen oder weit entfernten Märkten unterschieden. Die vollständige Globalisierung dauert in der Regel mehrere Generationen und wird durch langfristige Ziele gesteuert (Simon 2012, S. 207-208). HCs verstehen die Internationalisierung als umfänglichen Lernprozess, sodass auf Rückschläge mit Innovation und Anpassung reagiert wird. Auslöser der Internationalisierung sind, wie beschrieben, die begrenzten inländischen Märkte, die Erschließung neuer Märkte, die bestehende hohe Nachfrage auf ausländischen Märkten und der Wettbewerb im Allgemeinen (Witt & Carr 2013, S. 105-107). So wurde festgestellt, dass eine erfolgreiche Internationalisierung darauf basiert, dass Kund:innen eines Wirtschaftszweigs (WZ) über mehrere Länder hinweg ähnliche Bedürfnisse haben (Simon 2012, S. 207). HCs nutzen ihre Erfahrung, expandieren in einem inhaltlich kleinen Markt und minimieren dadurch das Wettbewerbsrisiko, anstatt in einer neuen Region in unterschiedliche Märkte einzusteigen.

In Bezug auf (internationale) Kooperationen bevorzugen HCs Export- bzw. hundertprozentige Tochtergesellschaften (Witt & Carr 2013, S. 102). Auch abhängige Partnerschaften wie Joint Ventures gehören vereinzelt zu ihren Strategien. Sie arbeiten mit Lizenzierungs-, Produktions- und Vertriebsgesellschaften. Venohr und Meyer (2007, S. 10) fassen zusammen, dass für HCs Prozessmanagement eine herausragende Rolle spielt. Gerade in operativen Bereichen sind sie besonders effektiv und kontinuierlich auf der Suche nach Verbesserungsmöglichkeiten, die dann

Die Unternehmenskategorie Hidden Champion

schnell und konsequent implementiert werden, was auch auf die Internationalisierung zutrifft. Eine Hemmschwelle und ein Engpass im Zuge der Internationalisierungsprozesse ist der Mangel an hochqualifiziertem Personal im In- wie auch im Ausland (Simon 2012, S. 208; Simon 2021, S. 228-230). Damit sind vor allem die sog. Schlüsselmitarbeitenden gemeint. Diese (Führungs-) Kräfte müssen sich im Ausland behaupten und gleichzeitig die Werte des Unternehmens dort implementieren. Kulturelle Barrieren müssen überwunden werden und der schwierige langwierige Anfangsprozess jedes Internationalisierungsvorhabens muss getragen werden. Simon (2012, S. 207) beschreibt die mentale und kulturelle Globalisierung der Mitarbeitenden als eine unverzichtbare Voraussetzung auf dem Weg zur Internationalisierung.

4 Stand der Forschung: Hidden Champions

Dieses Kapitel gibt einen Überblick über den aktuellen Forschungsstand zu HCs. Die Begriffsklärung und Definition von HCs erfolgte bereits im Kapitel 3 zu den theoretischen und konzeptionellen Grundlagen der Arbeit. Die Forschungsfragen zur *Identifizierung des Untersuchungsgegenstandes* werden beantwortet. Um den HC-Forschungsgegenstand ausführlich betrachten zu können, wurde eine umfangreiche Literaturrecherche durchgeführt. Die Literaturanalyse Schenkenhofers (2022) diente hier vor allem zur Identifizierung von relevanter Literatur. Die im folgenden präsentierten Ergebnisse sind Erkenntnisse der darauf aufbauenden eigenen Analyse. Zur Darlegung des aktuellen Stands der HC-Forschung wurde ähnlich vorgegangen wie in Schenkenhofer (2022), jedoch mit einem differenzierten inhaltlichen Schwerpunkt. Schenkenhofer (2022) zielt darauf ab, einen allgemeinen umfänglichen inhaltlichen Überblick zu geben und das Gesamtkonstrukt der HCs basierend auf den bestehenden Arbeiten zusammenzutragen. In der vorliegenden Arbeit wird in der Literaturanalyse ein Schwerpunkt auf die verwendete Methodik, die Datenverfügbarkeit und den tatsächlichen Arbeitsdefinitionen gelegt. Insgesamt 110 Arbeiten zu HCs konnten recherchiert und gesichtet werden.

Im ersten Unterkapitel werden neben den in der Literatur verwendeten Definitionen auch die Identifizierungsmethoden und Untersuchungsgegenstände der Forschungsarbeiten ausführlich beschrieben. Viele Arbeiten behandeln Fallstudien, andere führen große Befragungen durch oder basieren auf bestehenden Datenbanken. Auch die Datenverfügbarkeit wird hier thematisiert. Ein Überblick über die Forschungsinhalte, welche maßgeblich in HC-Veröffentlichungen betrachtet werden, folgt im zweiten Unterkapitel. In den vergangenen Jahrzehnten entstanden viele Arbeiten, die HCs in unterschiedlichen fachlichen Perspektiven untersuchen. Ziel ist es, eine möglichst umfassende Darstellung des Forschungsgegenstandes zu vermitteln und die Relevanz einer Operationalisierung der Identifikationskriterien zu begründen. Das Kapitel dient als Grundlage für die Entwicklung einer empirisch nachvollziehbaren, gebietsübergreifenden Identifikationstechnik.

4.1 Definitionen, Identifizierungsmethodik und Untersuchungsgegenstände

Wie bereits durch Schenkenhofers (2022, S. 423-443) ausführliche Literaturanalyse festgestellt und durch diese Arbeit bestätigt, stützt sich Forschung zu HCs in der Regel auf die Definition von Simon (1996a, 2007, 2009, 2012). Ca. 95 Prozent der in dieser Arbeit betrachteten Literatur verwenden die Definition nach Simon (1996a, 2007, 2009, 2012). Häufig wird die Definition aufgrund der Datenverfügbarkeit oder Fragestellungen für die Weiterverarbeitung dennoch angepasst. Fünf Prozent der Veröffentlichungen verwenden eigene Ausgangsdefinitionen. Eine einzelne Arbeit aus der Schweiz beinhaltet keine HC-Definition und setzt den Begriff als bekannt voraus (Feubli et al. 2007).

Simon selbst passt die Definition auf Basis seiner Erkenntnisse im Laufe der Jahre immer wieder an. Seine Arbeiten und solche, an denen er beteiligt war, orientieren sich genau an seiner Definition und bedienen sich seiner über die Jahre zusammengetragenen Liste (Simon 1996a, 2007, 2009, 2012; Simon & Huber 2007; Simon & Lippert 2007; Simon & Zatta 2008).

Nur vereinzelt haben Wissenschaftler:innen Zugriff auf die Liste Simons. So erstellen Benz et al. (2021) eine kombinierte Liste (1.645 HCs) basierend auf Simons unveröffentlichter Liste (2012), der Marktführer-Liste der WirtschaftsWoche (2020) sowie dem Lexikon der deutschen Weltmarktführer von Langenscheidt und Venohr (2010) für ihre Zwecke. Dazu kommt noch die Liste der deutschen Familienunternehmen von Seibold et al. (2019), die Liste innovativer Mittelständler (Yogeshwar 2019) und die der Frankfurter Allgemeinen Zeitung (2019) auf potenzielle HCs untersucht.

Viele, überwiegend qualitative Arbeiten, die bei der Auswahl der Untersuchungsgegenstände streng nach Simon vorgehen, identifizieren ihre Fallbeispiele aus seinen Veröffentlichungen. Tiwari und Buse (2014) untersuchen so die internationalen Innovationsstrategien von 53 HCs aus Deutschland, China und Indien, recherchiert aus Simon (2009 und 2012) (siehe auch Herstatt et al. 2017; Buse & Tiwari 2014). Witt und Carr (2013) analysieren 143 HCs, zusammengetragen aus Simon (2009). Hier ist zu erwähnen, dass sie zwar streng der Definition aus dem Werk folgen, nichtsdestotrotz das Hiddenness-Kriterium zur Identifizierung der HCs nur untergeordnet betrachten. Witt (2015) geht ähnlich vor, wobei sie die Quellen Simons (1996a, 2007, 2009, 2012) noch um die Erkenntnisse von Langenscheidt und Venohr (2014) aus dem Lexikon deutscher Weltmarktführer als zweite Datenquelle zur Untersuchung der Internationalisierungsstrategie von 30 HCs heranzieht. Weitere Beispiele sind Venohr und Meyer (2007), die auf Basis von 220 genannten HCs Simons die Entwicklung dieser bis 2004 analysieren. Schenkenhofer und Wilhelm

(2020) untersuchen den Zusammenhang zwischen der Anwesenheit von dual ausgebildeten Fachkräften HCs auf Basis von Simons Datenbank (2012).

Viele weitere Autor:innen haben zwar keinen Zugang auf die Datenbank Simons. Sie identifizieren allerdings durch aufwendige Literaturrecherchen möglichst flächendeckend HCs in begrenzten Untersuchungsregionen, streng nach seinen Identifikationskriterien (Simon 2012). Rietmann (2021a; 2021b; 2022b) nutzt für seine Analysen ein eigenes Sample von 84 HCs. Hierzu recherchiert er in bestehenden Datenbanken von regionalen Industrie- und Handelskammern sowie dem Weltmarktführerindex von Müller (2018). Rietmann (2019a, S. 6) führt Interviews und erfragt bei Expert:innen weitere potenzielle HCs aus den Untersuchungsregionen, welche er dann anhand der Identifizierungskriterien manuell prüft (Simon 2012). Wie Büchler (2017) vorgeht, ist beispielsweise nicht ganz eindeutig. Er brachte einen Sammelband zum Thema Innovation über HCs heraus. Ausgewählt für die Fallstudien wurden Unternehmen, wenn sie eine Weltmarktführerposition innehaben und Mittelständler sind. Während Simon (2017) einen Beitrag in dem Fallstudienkompodium verfasst, bleibt offen, wie genau die anderen Autor:innen bei der Auswahl vorgegangen sind und ob sie, ohne es konkret zu nennen, den Hinweisen Simons gefolgt sind oder Zugang zu seinen Daten hatten.

Qualitative Arbeiten nehmen ca. 50 Prozent der Literatur zu HCs ein. Es wird deutlich, dass insbesondere hier zur Beantwortung von Fragestellungen auf Sekundärdatenerhebungen anhand bestehender Veröffentlichungen zurückgegriffen wird (z. B. Witt & Carr 2013; Buse & Tiwari 2014; Rietmann 2021a, 2021b, 2022b; Kaudela-Baum 2014). Quantitative Ansätze, die ihre Datenbasis selbst erheben, Simons (2012) Definition auch als Arbeitsdefinition verwenden und die HCs ebenfalls nach seinen drei Identifizierungskriterien vornehmen, sind nicht vorhanden. Im Rahmen der für diese Arbeit durchgeführten Literaturrecherche konnten für quantitative Studien maximal Annäherungen an die drei Kriterien festgestellt werden, beispielsweise durch Benz et al. 2021. Von den empirisch vorgehenden Arbeiten (ca. 94 Prozent) verwenden ca. 23 Prozent quantitative Methoden. Weitere ca. 27 Prozent verwenden Mixed Methods-Ansätze (u. a. Venohr & Meyer 2007; Schenkenhofer & Wilhelm 2020).

Es werden unterschiedliche Ansätze verfolgt, um HCs aus Unternehmensdatenbanken zu extrahieren. Einige der Arbeiten werden im Folgenden präsentiert. Es wird deutlich, dass nur einige wenige eine Untersuchung auf Bundesebene anstreben, hierzu aber häufig die Definition der HCs aufgrund unterschiedlicher Schwächen in den vorliegenden Daten erweitert werden muss (u. a. in Frietsch 2015; Rammer & Spielkamp 2015; Rammer & Spielkamp 2019A; Audretsch

et al. 2018). Die Identifizierung von HCs ist eine Herausforderung, die sich allen HC-Forschenden stellt.

Venohr und Meyer (2009; 2007) analysieren die Entwicklung von 220 HCs, die 1994 von Simon identifiziert und in seinen Büchern namentlich erwähnt wurden. 15 Jahre später erkennen sie, dass die meisten weiterhin erfolgreich auf dem globalen Markt agieren. Weiter identifizieren sie insgesamt 1.400 Unternehmen, die bis zu einer Milliarde Euro Umsatz generieren und als Weltmarktführer einzuordnen sind (Simon 2007). Das Hiddenness-Kriterium wird bei der Definition der HCs in ihrer Datenbank jedoch nicht berücksichtigt.

Yoon (2013, S. 6259) verwendet quantifizierbare Identifizierungskriterien auf der Grundlage von Fallstudienliteratur. Yoons Arbeitsdefinition nach in dem Artikel sind HCs KMU mit einem Umsatz von über 40 Milliarden US-Dollar, einer Export-Umsatz-Quote von 30 Prozent und einem Gewinn von fünf Milliarden US-Dollar.

Die von Rammer und Spielkamp (2015; 2019a und 2019b) verwendeten Methoden sind vergleichbar. Sie haben sich vorgenommen, HCs mit Nicht-HCs zu vergleichen, um die Erfolgsmerkmale von HCs zu untersuchen. Mit ihrer Top-Down-Methode wählen die Autoren auf Basis der Daten des Mannheimer Innovationspanels insgesamt mehr als 1.500 Unternehmen als HCs aus. Sie verwenden andere, aber quantifizierbare Kriterien zur Identifikation als Simon, ähnlich wie Yoon (2013). Entsprechend entwickeln sie eine eigene Definition angelehnt an Simon (2009) mit vier Kriterien, um aus dem Mannheimer Innnoventionspanel HCs zu extrahieren. (1.) Es muss sich um ein mittelständisches Unternehmen mit weniger als 10.000 Beschäftigten in Deutschland handeln, (2.) das Unternehmen ist marktführend im internationalen Vergleich, (3.) agiert in Nischenmärkten und (4.) generiert ein überdurchschnittlich starkes Umsatzwachstum in den letzten fünf Jahren. Rammer und Spielkamp (2015) stellen ihre Daten weiteren Forschenden zur Verfügung (u. a. Lehmann et al. 2019; Audretsch et al. 2018).

Schlepphorst et al. (2016) analysieren 60 HCs und 346 Nicht-HCs. Ziel der Studie ist herauszufinden, welche Faktoren Unternehmen zu HCs machen. Sie identifizieren die HCs basierend auf dem Kriterium der Marktführerschaft. Dies erheben sie durch eine Unternehmensbefragung. Geben die Unternehmen an, marktführend zu sein, gilt das Kriterium als erfüllt. Die Autor:innen verweisen auf die beiden weiteren Kriterien, ohne sie zu diskutieren. Schlepphorst et al. (2016) sind die ersten, die einen Ansatz formulieren und versuchen ökonomisch zu validieren, welche Faktoren ein Unternehmen dazu veranlassen, ein HC zu sein.

Johann et al. (2021) folgen sorgfältig den Leitlinien von Simon (2012) zur Identifikation ihrer Untersuchungsgegenstände und filtern ihre Paneldaten manuell aus der Orbis-Unternehmensdatenbank. Sie fokussieren ihre Recherche ausschließlich auf das verarbeitende und produzierende Gewerbe. Anhand von Informationen von Firmenwebseiten oder anderen Quellen, wie Pressemitteilungen, analysieren sie die weltweite Marktführerschaft dieser Unternehmen. Weitere Kriterien sind in dieser Arbeit eine Mitarbeitendenzahl von 50-2.999 und dass es sich nicht um eine Tochtergesellschaft oder ausländische Firma und keine Non-Profit oder öffentliche Organisation handelt. Dies wurde manuell für alle 617 Unternehmen überprüft. Die Unbekanntheit der HCs wird hier nicht als entscheidendes Kriterium zur Identifizierung berücksichtigt.

Die bisher größte Liste an HCs generierten Lang et al. (2019, S. 16). In ihrer Arbeit definieren sie HCs als *“kleine und mittelständische Unternehmen, die auf dem Weltmarkt agieren, in der öffentlichen Wahrnehmung relativ unbekannt und wirtschaftlich überdurchschnittlich erfolgreich sind. Neben ihrer globalen Präsenz kennzeichnet diese Unternehmen eine oftmals enge Verbindung zu ihrem Stammsitz, die sich insbesondere aus der Firmengeschichte, der Besitzstruktur und der engen Bindung zur Belegschaft und ggf. weiteren Akteuren und Institutionen vor Ort ergibt”* (vgl. Lang et al. 2019, S. 16). Zur Identifikation der HCs nutzen sie eine Datenbank des Leibniz-Instituts für Länderkunde (ZEW) (2019). Basis sind das Lexikon deutscher Weltmarktführer (Langenscheidt & Venohr 2014) und Daten des Weissmann-Instituts für Familienunternehmen. Weiter verwenden sie die MARKUS-Datenbank für Unternehmensdaten, um Mitarbeitendenzahlen und Umsätze abzurufen. Danach prüfen sie die Liste auf die Identifikationskriterien (Simon 2012) und kommen auf insgesamt 1.691 HCs. Wie diese Identifizierung konkret durchgeführt wurde, wird nicht aufgeführt. Informationen zum Marktanteil oder zum Bekanntheitsgrad liegen in der Datenbank nicht vor. Von den 1.691 HCs liegen 1.354 nach den Raumtypen des Bundesinstituts für Bau-, Stadt- und Raumforschung (BBSR) sehr zentral bis zentral. 337 der HCs sind im peripheren bis sehr peripheren Raum lokalisiert.

Weiter ist zu beobachten, dass besonders Autor:innen, die HCs außerhalb Deutschlands identifizieren möchten, die Kriterien anpassen. Beispielsweise erstellt Jungwirth (2010) eine quantitative Untersuchung zu Marketingstrategien österreichischer HCs. Es wird argumentiert, dass auf Basis der kleinen Unternehmenslandschaft Österreichs die Kriterien (Simon 2012) auf die Rahmenbedingungen des Landes zu skalieren sind. 84 HCs werden identifiziert, wenn sie zu den Top 3 auf dem Weltmarkt zählen oder als europäischer Marktführer gelten. Außerdem müssen sie unter 200 Millionen Euro Umsatz aufweisen und der Unternehmenssitz in Österreich

sein. Die Daten für die Erhebung stammen aus der Datenbank des Kompetenzzentrums für Familienunternehmen. Die Definition wird auch von Jungwirth und König (2019) verwendet, um zu untersuchen, inwieweit österreichische HCs Corporate Social Responsibility (CSR) als Erfolgsfaktor für ihr Unternehmen ansehen. CSR beschreibt die Verantwortung, welche Unternehmen im sozialen, ethischen, ökologischen, menschenrechtlichen und verbraucherbezogenen Kontext für die Gesellschaft tragen und diese in ihrer Erfolgsstrategie berücksichtigen (Europäische Kommission 2001).

In einer Studie aus Griechenland können 20 HCs identifiziert werden (Voudouris et al. 2000, S. 664). Dazu verwenden die Autor:innen vier Kriterien. Es muss sich demnach um ein griechisches Unternehmen handeln, welches zwischen 20 und 250 Mitarbeitende beschäftigt. Weiter muss es auf internationaler Ebene Gewinne erwirtschaften und exzellent in unterschiedlichen Finanzmaßen abschneiden, beispielsweise in der Eigenkapitalrendite (in den Jahren 1993-1997). Datenbasis ist die ICAP-Unternehmensdatenbank, welche griechische Unternehmensfinanzdaten aufführt.

Blackburn et al. (2001) stützen sich auf Simons Definition von 1996 und die Arbeit von Voudouris et al. (2000), um für ihre Innovationsstudie kanadische HCs zu identifizieren. Wie genau sie bei der Auswahl ihrer drei Fallstudien vorgegangen sind, beschreiben sie nicht. Eine chinesische Studie passt die Definition für China wie folgt an. Zunächst muss chinesische- oder Weltmarktführerschaft bestehen (Yu & Chen 2009). Zweitens muss das Unternehmen als KMU gelten, der breiten Öffentlichkeit unbekannt sein und nicht mehr als 100 Millionen Euro Umsatz generieren. An dritter Stelle wird dann wiederholt auf den Unbekanntheitsgrad des Unternehmens verwiesen. Die Autor:innen orientieren sich an einer bestehenden Liste (Deng & Wan 2006) von 80 HCs und kontaktieren 26, um final vier HCs als Fallstudien auszuwählen.

Eine sehr ausführliche Untersuchung zu HCs in Zentral- und Osteuropa (CEE) sowie der Türkei ist der Sammelband von McKiernan und Purg (2013). Konkret war eine der Forschungsfrage, ob sich Simons Definition auf die CEE-Länder und die Türkei übertragen lässt. Die Wissenschaftler:innen untersuchen in 19 Ländern insgesamt 135 HC-Fallstudien. Recherchiert wurde unter anderem in statistischen Berichten, Wirtschaftsanalysen, Datenbanken und Forschungsnetzwerken, Business-Rankings, Beratungsberichten und bei Industrie- und Handelskammern (IHK). Dabei ist ihnen aufgefallen, dass einige Länder keine "Simon-HCs" aufweisen. Entsprechend wurde die Definition dann länderspezifisch angepasst.

Petraite und Dlugoborskyte (2017) identifizieren 13 litauische HCs anhand von sechs Kriterien. Diese erstellen sie auf Basis der Kriterien von Simon (2009) für Litauen. Das erste Kriterium

Stand der Forschung: Hidden Champions

beschreibt, dass das Unternehmen ein KMU sein muss, das zweite ist eine hohe F&E-Intensität und das dritte Kriterium eine frühe Internationalisierung (Exportaktivitäten in den ersten drei Jahren nach Gründung). An vierter Stelle steht der Ausschluss von Unternehmen aus der postsowjetischen Umstrukturierung aus der Stichprobe. Außerdem müssen Operationen auf globalen Märkten mit IPR-geschützten F&E-intensiven Produkten stattfinden. Als fünftes Kriterium gilt, dass die Einnahmen auf dem Niveau der KMU-Definition bleiben, und sechstens muss ein geringerer Bekanntheitsgrad in der breiten Öffentlichkeit bestehen.

Ohne das Hiddenness-Kriterium zur Definition der HCs zu benennen, arbeiten Freimark et al. (2019) vom HC-Institut. Sie definieren HCs nach Simons (2012) ersten beiden Identifikationskriterien, der Marktführerschaft und den maximalen fünf Milliarden Euro Umsatz. Sie befragen für ihre Studie neben 81 Mittelständlern, 82 Großunternehmen und 82 HCs.

Schenkenhofer (2022, S. 472) ist der erste, der einen quantitativen Ansatz zur Operationalisierung des Hiddenness Kriteriums verfolgt. Als Merkmal erstellt er den sog. Niche Brand Awareness Index. Hier werden fünf Kennzahlen zu einem Index zusammengesetzt. Einbezogen wird die Anzahl an LinkedIn Follower:innen, der Facebook Likes, die Anzahl der Besuche der Wikipedia sowie Kununu Webseite und Reviews.

Frietsch (2015) untersucht in seiner Arbeit Globale Champions sowie HCs im Innovationswettbewerb und beschreibt den Beitrag von KMU zur Umsetzung neuer Technologien. Die verwendete HC-Definition besteht aus vier Identifikationskriterien. Unternehmen mit weniger als 10.000 Mitarbeitenden, mit einem Exportanteil über 50 Prozent sowie einem hohen Weltmarktanteil in ihrem Hauptabsatzmarkt gelten als HCs (Frietsch 2015, S. 16). Weiter wird hier das Champions-Kriterium noch stärker geschärft. Ist das Marktvolumen des Marktes klein (unter 200 Millionen Euro), muss der Anteil des HCs bei mindestens zehn Prozent liegen. Bei einem Volumen von 0,5 bis einer Milliarde Euro bei mindestens drei Prozent und beträgt das Volumen des Marktes über eine Milliarde Euro, sollte der Marktanteil des HCs über einem Prozent liegen. Das vierte Kriterium ist ein branchenüberdurchschnittliches Wachstum. Die Datenbasis Frietschs (2015) ist das Mannheimer Innovationspanel. Die Erhebung wird durch das ZEW seit ca. 30 Jahren durchgeführt und stellt Daten zum Innovationsverhalten der deutschen Wirtschaft bereit (ZEW 2023).

4.2 Forschungsinhalte Hidden Champions

Im folgenden Kapitel wird zusammengetragen, mit welchen Forschungsfragen sich bisher im Rahmen der HCs Forschung beschäftigt wurde und zu welchen Erkenntnissen diese führten. Ziel ist es, die Relevanz des HC-Forschungsfeldes darzulegen sowie die Forschungsfragen für die vorliegende Arbeit abzuleiten. Ein gutes Drittel der Arbeiten beschäftigt sich mit den Erfolgsstrategien der HCs im Allgemeinen. Neben den Veröffentlichungen von Simon zu HCs und deren Erfolgsstrategien ist unter anderem die von Rasche (2003) oder Li und Li (2008) zu den Erfolgsstrategien des Unternehmenstypen aufzuführen.

Simon (1996b) beschreibt, dass der HC-Begriff nicht nur auf deutsche Unternehmen anwendbar ist. Internationale Beiträge im Sammelband von McKiernan und Purg (2013) zu HCs in Zentral- und Osteuropa setzen an, HCs in entsprechenden Ländern zu identifizieren. Dazu gehören unter anderem Bosnien und Herzegowina (Brkic & Berberovic 2013), Mazedonien (Santa & Kekeovski 2013), Belarus (Daneyko & Golenchenko 2013), Serbien (Depalov & Todorovic 2013), Albanien (Kume & Kume 2013), Ukraine (Palii & Oksenyuk 2013), Rumänien (Rusu 2013), Lettland (Sauka 2013) und Ungarn (Stocker & Szlavik 2013). Fallstudien zu HCs in der Türkei verarbeiten Çetindamar und Kozanoglu (2012). Chang und Ko (2014) analysieren die Erfolgsfaktoren von koreanischen HCs anhand von Fallbeispielen. Din et al. (2013) untersuchen in ihrer Arbeit schwedische Fallbeispiele auf deren Erfolgsfaktoren und Simon und Zatta (2008) indische Unternehmen. Außerdem zu nennen sind Arbeiten zu HCs in Japan (Simon & Lippert 2007; Ding 2008) oder der Schweiz (Feubli & Gachet 2015).

Dominiert wird die Literatur zu HCs nach den *zwei Säulen der unternehmerischen Erfolgsstrategie*, welche in Kapitel 3 beschrieben wurden. Zum einen der Internationalisierung und zum anderen der Fokussierung und Tiefe durch Innovation. Während sich knapp 20 Prozent der in dieser Arbeit untersuchten Veröffentlichungen überwiegend mit dem Schwerpunkt Internationalisierung beschäftigen, sind es ca. 30 Prozent mit Innovationsstrategien. Die restlichen knapp 17 Prozent der Arbeiten beziehen sich auf unterschiedliche kleinere Themenfelder. Dazu gehören unter anderem Finanzen und Steuern (u. a. Johann et al. 2021; Kamp 2019; Sariyev 2022), die Unternehmenskultur (z. B. Pitroff 2011), Management (beispielsweise Walravens & Filipvic 2013 und Hilz 2013), Marketing (Jungwirth 2010) aber auch CSR und Digitalisierungsstrategien (u. a. Rietmann 2021a, 2021b, 2022b; Jungwirth & König 2019; Simon 2020). Häufig werden diese Themen im Kontext der Internationalisierungs- und/oder Innovationsstrategie der HCs betrachtet.

4.2.1 Internationalisierung

Die in Kapitel 3 beschriebene Nischenstrategie der HCs erfordert die internationale Vermarktung der Produkte und Leistungen für deren Erfolg. Exemplarisch werden im Folgenden einige Erkenntnisse aus den Untersuchungen zu den Internationalisierungsstrategien der HCs aufgeführt. Einige der Arbeiten beschäftigen sich insbesondere mit den konkreten Internationalisierungsstrategien auf dem asiatischen Markt (u. a. Tiwari & Buse 2014 Venohr & Bruche 2015; Venohr & Kamp 2019; Saginova et al. 2019; Herstatt et al. 2017; Simon 2021). Tiwari und Buse (2014) untersuchen die Strategien von deutschen HCs auf dem BRIC-Markt (Brasilien, Russland, Indien, China und Südafrika). Durch ihre Befragung stellen sie fest, dass viele der Unternehmen beim Export auf Produkte aus dem Premiumsegment setzen und den entsprechenden Markt dominieren. Die Autoren beschreiben die Gefahr der Marktengung, wenn die HCs nicht auch erschwingliche Spitzenprodukte in den BRIC-Ländern anbieten (Tiwari & Buse 2014, S. 11). Dazu empfehlen sie ein mehrstufiges Produktkonzept, um z. B. den indischen Markt zu erschließen. Der Preisdruck in Indien ist immens, weshalb es gilt, den ausländischen Markt zu verstehen, um eine erfolgreiche Internationalisierungsstrategie umzusetzen (Herstatt et al. 2017, S. 234; Tiwari & Buse 2014, S. 11).

Einen weiteren Forschungsblickwinkel nehmen Landau et al. (2016, S. 303) in ihrer Arbeit ein. Sie analysieren die Internationalisierungsstrategien deutscher HCs konkreter in dem Kontext der Charakteristika des deutschen Mittelstands. Dieser legt in der Regel einen Fokus auf innereuropäische Märkte. Die Autoren stellen die Chancen und Herausforderungen der Internationalisierungsinvestitionen der BRIC dar.

Saginova et al. (2014) untersuchen die Charakteristika russischer HCs. Die Autorinnen stellen fest, dass die russischen HCs ebenfalls durch Internationalisierung erfolgreich sind. Ein Grund ist unter anderem, dass die internationale Nachfrage nach den entsprechenden Nischenprodukten höher ist als im Heimatland des HCs selbst. Sie unterscheiden zwischen zwei Perspektiven der Internationalisierungsforschung. Zum einen Forschung zu Unternehmen, welche seit ihrer Gründung international agieren und zum anderen solchen, die bereits länger bestehen und im Zeitverlauf Internationalisierungsstrategien entwickeln. Die Autorinnen nutzen die Datenbasis aus 2013, in welcher sie im Rahmen der Veröffentlichung erste Erkenntnisse hierzu in einem Sammelband von McKiernan und Purg (2013) verfassen. Dieser umfasst diverse Analysen zentral- und osteuropäischer sowie türkischer und russischer HCs.

Venohr und Kamp (2019) analysieren anknüpfend die Auswirkungen der Internationalisierung in asiatischen Schwellenländern für deutsche HCs. Da sie das Hiddenness-Kriterium (Simon 2012) nicht berücksichtigen, verwenden sie den Begriff "Global Nice Market Leaders" (GNML) für ihre Untersuchung. Sie stellen fest, dass, anders als von Tiwari und Buse (2014) oder Herstatt et al. (2017) empfohlen, viele der GNML kein Insiderwissen auf dem asiatischen Markt, auf dem sie agieren, haben. Sie betonen abermals, dass dies langfristig zur Schwächung der Marktpräsenz führt.

Eine große quantitative Analyse zu den Internationalisierungsstrategien von HCs führen Audretsch et al. (2018, S. 5-6) durch. Ihr Ziel ist es, herauszufinden, wodurch die deutschen HCs internationalen Erfolg erreichen und nachhaltig den Nischenmarkt beherrschen. HCs folgen, wie beschrieben, der Differenzierungs- und Schwerpunktstrategie nach Porter (2013, S. 74). Durch ein wissensintensives, oft technologisches Nischenprodukt verfolgen sie erfolgreich die Differenzierungsstrategie (Audretsch et al. 2018, S. 5). Durch Export und Internationalisierung ist das Modell der Nischenstrategie ausgedehnt. Witt (2015) analysiert in ihrer Dissertation deutsche und britische HCs in Bezug auf ihre Internationalisierungsstrategien und Markteintritte. Diesbezüglich erstellt sie verschiedene HCs-Kategorien und betrachtet deren Eintritt in den internationalen Markt (Witt 2015, S. 10). Gemeinsame Erkenntnis in den Studien ist, dass es, um den internationalen Erfolg weiter beizubehalten, notwendig ist, dass die Unternehmen interne Fähigkeiten ausbauen (Audretsch et al. 2018, S. 5; Witt 2015, S. 271). Fachkräfte gilt es anzuwerben, zu generieren und zu halten. Investitionen in F&E und neue Technologien sowie internationale Mitarbeitende tragen zu höheren Exportwerten bei als die Unternehmensgröße oder das -alter (Fryges 2006, S. 24).

Venohr und Meyer (2007) analysieren die von Simon in den 1990er Jahren identifizierten HCs zehn Jahre nach ihrer „Entdeckung“. Im Jahr 2009 fassen sie ihre Ergebnisse noch einmal prägnant zusammen. Durch die Analyse ihrer Stichprobe können sie feststellen, dass die HCs im Vergleich zum Rest der deutschen Wirtschaft um 5,7 Prozent pro Jahr stärker wuchsen (Venohr & Meyer 2009, S. 40). Über 80 Prozent der betrachteten HCs behielten in den zehn Jahren ihre Marktposition und bauten diese teilweise sogar aus. Die Autoren stellen fest, dass die Unternehmen, unabhängig davon, ob sie als Familienunternehmen gelten oder durch ein „klassisches“ externes Management geführt wurden, weiterhin erfolgreich sind. Sie bestätigen diese Strategie der Konzentration auf Schwerpunkte gepaart mit Differenzierung (siehe Porter 2013, S. 74).

Für den internationalen Markteintritt bevorzugen HCs sog. kontrollierte Eintrittsformen, wie Witt und Carr (2013, S. 103-105) feststellen. Dazu zählen beispielsweise hundertprozentige Tochtergesellschaften und Exporttätigkeiten, aber auch Lizenzvergaben. Die Autor:innen untersuchen eine HC-Stichprobe und stellen fest, dass die internationalen Markteintritte der HCs überwiegend nachfragegesteuert abliefen. So orientieren sie sich teilweise (15 Prozent der Stichprobe) an den Stufen des Uppsala Modells (Witt & Carr 2013, S. 105). Dies beinhaltet, dass nach dem Export der Export über Handelsvertreter folgt, dann die hundertprozentigen Tochterunternehmen (Vertrieb) und abschließend die Produktion im Ausland. Durch die internationale Dominanz ihres Produktes, unterscheidet sich der Markteintritt der HCs in der Regel jedoch von diesem Vorgehen. Beispielsweise wurde festgestellt, dass einige HCs einzelne oder mehrere Stufen übersprangen (knapp 50 Prozent der Studie). Sie stellen fest, dass die Art des Markteintritts auch von dem Markt selbst abhängt. So unterscheiden sich die Vorgehensweisen beispielsweise nach Zielort oder Zielbranche. Während „*born globals*“ junge Unternehmen sind, die sehr schnell nach der Gründung ihr Geschäft internationalisieren, stellen sog. „*born-again globals*“ Unternehmen dar, die zunächst auf ihrem Heimatmarkt die Marktführerposition einnehmen und wenn diese gesichert ist oder die Nachfrage es ermöglicht, beschleunigt internationalisieren. Witt und Carr (2013, S. 106) stellen fest, dass HCs überwiegend in dieser Kategorie zu verorten sind.

4.2.2 Innovation

Aus dem Kapitel der Internationalisierungsstrategien von HCs wird bereits deutlich, dass diese nicht ohne die Kombination mit den Innovationstätigkeiten der Unternehmen möglich sind. Die zwei Säulen der Erfolgsstrategie tragen gemeinsam den unternehmerischen Erfolg. Viele Forschungsarbeiten widmen sich aus diesem Grund den Innovationsstrategien der HCs.

Simon (2017, S. 3) beschreibt in seinem Beitrag in einem Fallstudienkompodium (Büchler 2017) die übergeordnete Innovationsorientierung der HCs. Ziel und Antriebskraft der Innovation ist, den Kund:innen einen ggf. neuen, nachhaltigen, möglichst günstigen Nutzen zu bringen. Weitere externe Impulsgeber für Innovationen sind mögliche Wettbewerber, Lieferant:innen, externe Forschungserkenntnisse oder auch Unternehmen, die mit den HCs in Verbindung stehen. Interne Antriebskräfte sind neben der F&E-Abteilung neue, andere Unternehmensbereiche oder das Management. Durch Simons Zugang zu einer umfangreichen Datensammlung der HCs in Deutschland, veröffentlicht er einen Vergleich von F&E-Ausgaben in Prozent vom Umsatz. Er stellt fest, dass HCs, verglichen mit Unternehmen im Allgemeinen, die F&E betreiben, einen knapp doppelt so hohen Anteil des Umsatzes investieren. Als Innovationsoutput beschreibt er die

Patenttätigkeit der HCs. Der Autor vergleicht patentintensive Großunternehmen und HCs. So stellt er fest, dass HCs fast fünf Mal so viel patentieren wie Großunternehmen (je 1.000 Mitarbeitende) und das zu einem Fünftel der Kosten (Simon 2012, S. 259). Zusammenfassend beschreibt Simon die in Kapitel 3 bereits beschriebene Strategie der Fokussierung und Tiefe parallel zur kontinuierlichen Internationalisierung und damit einhergehenden konsequenten Innovationsorientierung, denn die Produktqualität steht für die HCs an primärer Stelle der Wettbewerbsstrategie. Ziel ist es, den Kontakt zu den Kund:innen konstant zu pflegen, die Nachfrage nach Spezialisierung, Spitzenqualität und -technologie zu erfüllen und dazu zu nutzen die Markteintrittsbarrieren für Wettbewerber hochzuhalten.

Kirner und Zenker (2011), Kaudela-Baum et al. (2014) und Garaus et al. (2016) bearbeiten Fragestellungen und Konzepte im Kontext der Verbindung von Personal und Innovation. Kirner und Zenker (2011) beschreiben in ihrer Arbeit die Konzepte der Knowledge Angels und der HCs. Knowledge Angels (Muller et al. 2009, S. 1-2) sind Personen, die Innovationen in wissensintensiven Dienstleistungen schaffen. Sie agieren als interne und externe Wissensvermittler:innen, haben die Fähigkeit, Strategien für das Unternehmen zu entwickeln und besetzen eine Position in ihrem Unternehmen, in welcher sie diese Strategien auch umsetzen können. Kirner und Zenker (2011, S. 5) vergleichen die beiden Ansätze und schaffen damit die Basis für verschiedene Fragestellungen, unter anderem, inwieweit Knowledge Angels für die Innovationstätigkeiten und Erfolgsstrategien von HCs verantwortlich sind.

Kaudela-Baum et al. (2014) analysieren in ihrer qualitativen Studie interne innovationsfördernde Strategien von HCs. Wie Freiräume für Mitarbeitende die Innovationstätigkeit eines Unternehmens beeinflussen, steht hier im Vordergrund der Untersuchung. Finanzielle und personelle Reserve- und Pufferbestände beschreiben die Autor:innen als innovationssteigerndes ökonomisches Potenzial und als Grundlage von Freiräumen (S. 75-77). Genauer stellen sie die Frage nach der Gestaltung von Freiräumen bei HCs in der Führungsebene sowie von Verhaltensmustern der Führenden und Geführten. Erkenntnis ist, dass HCs ihren Mitarbeitenden größere Freiräume bieten und flexible Lösungen befürworten. Sie empfehlen eine strategiegeleitete, innovationsfördernde Kultur auf den verschiedenen Unternehmensebenen.

Die Erkenntnisse von Garaus et al. (2016) lassen sich in Verbindung mit den Erkenntnissen von Kirner und Zenker (2011) bringen. Sie untersuchen die Fähigkeiten des HC-Personalmanagements bestehende Kompetenzen zu nutzen und parallel neue zu entwickeln als mögliches Werkzeug der Stabilisierung dieses Konflikts anhand unterschiedlicher Fallstudien. Eine große Herausforderung für HCs ist die Bewerkstelligung des Spannungsverhältnisses

zwischen Flexibilität und Effizienz (S. 374-375). Ziel ist es, anhand der hochinnovativen und effizienten HCs ein beidhändiges Personalmanagementsystem zu entwerfen, welches den Mitarbeitenden ausreichend Flexibilität in ihrem Tun und Effizienz durch ihr Tun ermöglicht.

Frietsch (2015, S. 9) vergleicht internationale Konzerne und KMU im Innovationswettbewerb. Er unterscheidet zwischen Global Champions und HCs. Durch die in Kapitel 4.1 beschriebene umfangreiche Datenverfügbarkeit der Untersuchung kann er einige innovationstreibende Kennzahlen analysieren. Er stellt fest, dass die von ihm identifizierten HCs ca. fünf Prozent der gesamten F&E-Ausgaben der deutschen Wirtschaft ausmachen. Weiter sind HCs für 15 Prozent des Neuproduktumsatzes mit Weltmarktneuheit in Deutschland verantwortlich. Frietsch (2015) stellt fest, dass KMU insgesamt nur ca. 20 Prozent der Patentanmeldungen Deutschlands ausmachen (S. 19). Wie viele davon von HCs stammen, lässt sich nicht zurückverfolgen.

Rietmann (2021a) überprüft in seiner Arbeit die Integration von HCs in ländliche regionale Innovationssysteme. Dazu untersucht er firmeninterne und -externe regionale Einflussfaktoren. Auf Grundlage von 57 Expert:inneninterviews stellt er fest, dass es stark von internen Unternehmenscharakteristika abhängt, inwieweit es regional integriert ist (S. 12-13). Beispielsweise sind Familienunternehmen im Durchschnitt stärker integriert als nicht im Familienbesitz befindliche Unternehmen. Tochterunternehmen von (internationalen) Großkonzernen, genauso wie überdurchschnittlich große Unternehmen. Bezüglich der unternehmensexternen Einflussfaktoren auf die ländliche regionale Eingebundenheit in RIS gelten der Standort und der Urbanisierungsvorteil als zentral. Nach Rietmanns (2021a, S. 12) Erkenntnissen nehmen die Industrie, der technologische Fokus, der Grad der Ländlichkeit, die Faktoren der Technologie- und Innovationspolitik oder Richtlinien der Region wenig bis keinen Einfluss auf die Integration in das ländliche RIS.

Blackburn et al. (2001, S. 3) untersuchen die Rolle von Strategie und Innovation für den Erfolg von HCs anhand von drei kanadischen Fallbeispielen. In ihrem Framework eines Strategiemodells für HCs heben sie hervor, dass eine globale Vision gemeinsam mit F&E-Aktivitäten, In-Sourcing, Anpassungsfähigkeiten und bestimmtem unternehmerischem Verhalten die Grundlage für die strategischen Antriebskräfte Innovation und Beziehungsmarketing darstellen. Erst aus dem wechselseitigen Einfluss dieser entsteht ein Wertbeitrag in Form eines Service oder Produktes, welches die Nachfrage der Kundschaft beantwortet.

Eine Analyse von produktbezogenen globalen Innovationsstrategien deutscher HCs wird von Tiwari und Buse (2014, S. 11) durchgeführt. Wie in Kapitel 4.2.1 beschrieben, untersuchen sie die Strategien von deutschen HCs auf dem BRIC-Markt. Die Notwendigkeit zu innovieren, sehen die

Autor:innen vor allem durch den indischen Preisdruck. Sie schlagen ein frugales Innovieren für den BRIC-Markt vor, um vereinfachte anwendungsorientierte Lösungen auf den neuen Markt zu bringen und große Kund:innengruppen bedienen zu können. Sie gehen von wohlständigen Käufer:innengruppen der HCs aus und schlagen in Bezug auf die "klassische" HC-Innovationsstrategie einen Perspektivwechsel vor.

Rammer und Spielkamp veröffentlichen 2015 ihre erste HC-Studie. Sie beschreiben zunächst drei Handlungsebenen für KMU in Anlehnung an den theoretischen Ansatz der "Dynamic Capabilities of Firms" (Rammer & Spielkamp 2015, S. 37-38). Das Ziel der drei Ebenen "Positionierung", "Kompetenzbasis" und "Prozessmanagement" ist es, durch Innovationsmanagement allgemeine Wettbewerbsvorteile zu erarbeiten. Die Autoren kommen zu der Erkenntnis, dass insbesondere das Management der unternehmerischen Innovationsprozesse neben den strategischen Maßnahmen und den Führungsqualitäten im Allgemeinen als Erfolgsfaktor der HCs zu verbuchen ist. Das Vereinen von technologischem Wissen, Marktkenntnis und Kund:innenbedürfnissen trägt hier maßgeblich zum Erfolg bei.

Im Jahr 2019 aktualisieren Rammer und Spielkamp ihre Studie und stellen erneut fest, dass HCs eine höhere Gewinnspanne und Produktivität haben als Nicht-HCs. Zu diesen Ergebnissen kommen sie, obwohl die HCs nicht mehr in F&E investieren als die untersuchten Nicht-HCs (S. 65). Hohe Effizienz in der Generierung von Produkt- und Prozessinnovationen ist hier der Schlüssel zum Erfolg. Dazu identifizieren die Autoren vier Lektionen (S. 83). Zunächst investieren die HCs interne stark in F&E, basierend auf den kommunizierten Kund:innenbedürfnissen. Dazu verwenden sie offene Innovationsstrategien, immer mit dem Fokus, die Oberhand in der Innovationsentwicklung beizubehalten. An dritter Stelle steht ein komplexes Management des geistigen Eigentums der Unternehmen selbst und an vierter Stelle die vergleichsweise hohen Investitionen in Fachkräfte. Rammer und Spielkamp (2019, S. 83-84) bestätigen ihre Ergebnisse aus 2015 und stellen fest, dass der Nischenmarkt, in dem HCs tätig sind, häufig weniger durch Preisdruck oder Wettbewerber bestimmt wird.

Rant und Černe (2017) widmen sich der Frage, inwieweit HCs ihre Nischenführerschaft durch Produktführerschaft und Kund:innennähe gestalten. Dazu verwenden sie die Daten von 93 Nischenführern in mittel- und osteuropäischen Ländern (MOEL) (S. 91). Im Ergebnis stellen sie fest, dass die Beziehung zwischen Unternehmensattraktivität und Leistung durch die Produktführerschaft negativ moderiert wird. Währenddessen ist die Auswirkung von Produktführerschaft und Kund:innenvertrautheit zusammen auf die Beziehung zwischen Unternehmensattraktivität und -leistung nicht eindeutig (S. 99).

Schlepphorst et al. (2016) stellen sich, wie andere Arbeiten zuvor, die Frage, welche Determinanten einen deutschen HC ausmachen, genauer, wie sie sich von anderen Unternehmen unterscheiden. Sie stellen fest, dass die Wahrscheinlichkeit, zu den HCs zu gehören, durch bestimmte Firmeneigenschaften wie F&E, weltweite Geschäftstätigkeit und das Ziel der Marktanteilsmaximierung erheblich erhöht wird (S. 10-12). Weiter fragen sie, welche Handlungsempfehlungen an andere Länder auszusprechen sind, sodass diese ihre Unternehmen dabei unterstützen können, HCs zu werden (S. 16-17). Hier nennen sie beispielhaft unter anderem kooperationsfördernde Maßnahmen der deutschen Politik zwischen Unternehmen und Universitäten oder Forschungseinrichtungen. Weiter kann die Politik dazu beitragen, dass der Wissenstransfer vereinfacht und Synergien zwischen den Akteuren geschaffen werden, um positive externe- und Spillover-Effekte hervorzurufen (S. 15). Da insbesondere das Humankapital der HCs die Innovationen und das Wachstum generiert, setzen die Autor:innen in ihren Empfehlungen für ausländische Maßnahmen auch hier an. Ziel der Länder kann es sein, ein ähnliches Bildungssystem zu erarbeiten wie Deutschland, beispielhaft das duale Studium mit seiner unternehmensspezifischen Verbindung zwischen Praxis und Theorie (S. 16). Schlepphorst et al. (2016) bearbeiten in ihrer Studie eine Analyse der internen wachstumstreibenden Faktoren für den Erfolg der HCs, aus denen sie schließlich Handlungsempfehlungen für externe Determinanten formulieren.

Zastempowski (2011) stellt in seiner Analyse polnischer HCs die Globalisierung und Innovation als Säulen der Unternehmensstrategie dieser dar. Er fokussiert sich in seinem Papier auf die Innovationsbemühungen der HCs und wie diese der polnischen Wirtschaft als Chance zur Entwicklung dienen. Nach seinen Erkenntnissen haben immaterielle Ressourcen das größte Innovationssteigerungspotenzial inne (S. 53; 56). Dazu zählen insbesondere die menschlichen und intellektuellen Ressourcen, gefolgt von organisatorischen, finanziellen und physischen. Die Schlüsselrolle zur Innovationssteigerung bei den polnischen HCs spielt das Wissen.

Muñoz (2017, S. 205) stellt fest, dass HCs in Zeiten wirtschaftlicher Rezession widerstandsfähiger sind als die Nicht-HCs. Er analysiert in seiner Arbeit Schlüsselentscheidungen des Managements. Es gelingt ihnen in wirtschaftlich schweren Zeiten neben dem Umsatz auch das Beschäftigungsniveau zu halten und teilweise sogar zu verbessern. Muñoz (2017, S. 192) analysiert Managemententscheidungen einer 75 unternehmensgroßen Fallstudie. Die Ergebnisse spiegeln die klassische HC-Strategie nach Simon (2012) wider. Die spanischen HCs unterscheidet von anderen spanischen Unternehmen neben dem engen Kund:innenkontakt die konstante Investition in die Weiterentwicklung und Generierung von Produkten und Dienstleistungen (S.

196). Innovation ist die zweite Stufe des Erfolgs. An dritter Stelle ist die internationale Ausrichtung der Unternehmen zu erkennen.

Petraite und Dlugibirskyte (2017, S. 115) analysieren die Entstehung von HCs aus der Perspektive der unternehmerischen Netzwerktheorien. Wesentliche unternehmerische Merkmale sind hier Risikotoleranz und Proaktivität der Unternehmen, um HCs zu bilden (S. 102). Besondere Fähigkeiten im organisationalen Bereich müssen gegeben sein. Dazu gehören Wissensintensität, Lernorientierung, Innovationsaufbaufähigkeiten und solche, diese zu halten. Weiter müssen technologische Vorteile bestehen oder entwickelt werden. Spezialisierung, globale Nischenstrategien und Produktdifferenzierung sind nach den Erkenntnissen der Autor:innen unabdingbar. Die untersuchten HCs nutzen intensiv Partnerschaften und Netzwerke zur Generierung von neuen Geschäftsmodellen. HCs müssen außerdem einen strategischen Fokus auf Internationalisierung legen. Die Autor:innen stellen fest, dass die Fokussierung auf Innovation nicht ausschließlich als kritischer Faktor zur HC-Bildung aufzuführen ist, sondern auch als strategische Erkenntnis im Unternehmensalltag wiederzufinden ist. Während Unternehmen mit überwiegend viel internem Wissen weniger in Partnerschaften investieren, gilt für Unternehmen, denen Wissen „fehlt“, ein Fokus auf Investitionen in Wissensnetzwerke. Dies gilt insbesondere für Kund:innennetzwerke.

4.2.3 Räumliche Muster und Zusammenhänge

In der aktuellen HCs Literatur werden räumliche Muster und Einflussfaktoren bisher noch wenig betrachtet. Die Unternehmen sind überwiegend in ländlichen Räumen verortet (Ermann et al. 2011, S. 2; Simon 2012, S. 381). Genauer liegen zwei Drittel der Hauptsitze in der Peripherie. Auf Basis von Simons (2012) qualitativer Studie stellt er fest, dass Wechselwirkungen zwischen Raum und Unternehmen Effekte auf die Unternehmens- und Mitarbeitendenkultur haben, deren Auswirkungen den Erfolg des HCs beeinflussen. Der Autor beschreibt dies als gegenseitige Abhängigkeit. Der HC bietet die Arbeitsplätze, die Region die Arbeitnehmenden. Wobei hier die große Herausforderung ist, dass in peripheren Räumen die Zahl der entsprechend Qualifizierten häufig zu gering ist. Die Abhängigkeit prägt die Identifikation und die Motivation beider Seiten. Niedrige Fluktuation und fokussierte Fachkräfte sind ebenfalls ein Resultat der ländlichen Standorte. Die ländlichen Räume wiederum profitieren von HCs insbesondere dadurch, dass diese Unternehmen standorttreu sind und die Beschäftigung in der Peripherie gewährleisten, da zumeist regional rekrutiert und ausgebildet wird und die Fluktuationsrate bei HCs äußerst gering ist (Simon 2012, S. 13). Die Herausforderung liegt hier darin, Mitarbeitende aus urbanen Räumen initial für den Standort zu gewinnen. Denn die Expertise entsteht in der Regel an Universitäten

und Wissensstandorten in den Städten. Dass die Eigentümer häufig auch persönlich mit der Region verbunden sind, zum Beispiel dadurch, dass sie dort geboren sind und/oder seit vielen Generationen die Unternehmen an dem Standort verortet sind stärkt das Beziehungsgeflecht zur Bevölkerung (Simon 2012, S. 381; Block 2019, S. 14). Parallel dazu steigt auch die Verantwortung auf regionalpolitischer Ebene. Die politischen Akteur:innen sind dementsprechend wohlwollend mit „Ihren“ HCs, unter anderem wegen der durch die Unternehmen verbundenen regionalen Arbeitsplätze und Steuern. CSR gehört für viele HCs fest zu den unternehmerischen Zielvereinbarungen.

Block (2019, S. 14) macht in seiner Arbeit zu ländlichem Unternehmertum auf die Relevanz aufmerksam, nachhaltige politische Rahmenbedingungen zu schaffen. Eine weitere Erkenntnis seiner Forschung stellt die größere Bedeutung von Familienunternehmen und HCs sowohl für ländliche als für urbane Regionen dar. Die langfristige Beziehung zwischen HCs und ländlichen Regionen prägt beide und stärkt den Zusammenhalt.

Simon (2007, S. 294) benennt das Umfeld außerdem als Erfolgseigenschaft, da die räumliche Nähe zu HCs anderer Branchen eine anspornende Wirkung haben kann. Die räumliche Konzentration von HCs einer Branche ist diesen Erkenntnissen nach selten zu beobachten. Nach seinen Feststellungen spielen Industriecluster eine untergeordnete Rolle, da HCs sich in der Regel auf sich selbst konzentrieren.

Lehmann et al. (2019, S. 360) vergleichen HCs und wachstumsstarke Firmen im Silicon Valley (Unicorns). Ziel der Studie ist es, den Kontext der Humankapitalinvestitionen der Unternehmen zu analysieren. Unterschiede und Gemeinsamkeiten werden identifiziert, um Handlungsempfehlungen auf politischer Ebene zu entwerfen. Sie stellen fest, dass beide Unternehmenstypen durch den institutionellen Kontext geprägt werden und entsprechend investieren (S. 371-371). Sie empfehlen eine ausgiebige Analyse der Erfolgsstrategien.

Erste konkretere raumbezogene Fragestellungen stellt das BBSR (2019) mit seiner Studie zu HCs im Kontext von Stadtentwicklung. Die Autor:innen sammeln Erkenntnissen über die verantwortliches Unternehmertum von HCs in ländlichen Kleinstädten. Die wechselseitige Verbundenheit von Unternehmen mit der Region ist hier ausschlaggebend (S. 54). Die Analysen nehmen die Autor:innen anhand von drei Fallstudien vor. Final beschreiben sie den Bedarf an quantitativen Messansätzen zur Identifizierung von wirtschaftlichen Potenzialen im Zusammenhang mit der Anwesenheit von HCs durch lokale und regionales Engagement (S. 57).

Stand der Forschung: Hidden Champions

Rietmann (2021a) analysiert die Einbettung von HCs in ländliche RIS. Die qualitative Untersuchung kam zu dem Ergebnis, dass ein Großteil der Unternehmen in ländliche RIS integriert ist, wenn auch sehr heterogen (Rietmann 2021a, S.12). Bezugnehmend geht es bei der Integration um Wissensgenerierung und -verbreitung, und Wissensanwendung und -verwertung. HCs, die als Familienunternehmen kategorisiert sind, integrieren sich stärker. Die Größe der Unternehmen steht in einem negativen Zusammenhang und wenn es sich um Tochterunternehmen größerer Konzerne handelt, sind diese weniger häufig integriert. Jedoch nehmen die Industrie, der technologische Fokus, der Grad der Ländlichkeit oder die Faktoren der technologischen und Innovationspolitik und Richtlinien der Region wenig bis keinen Einfluss auf die Integration in ländliche RIS.

Zhu et al. (2023, S. 23) analysieren die räumliche Verteilung chinesischer sogenannter „Little Giant Enterprises“, die sie als potenzielle HCs identifizieren. Dazu nutzen sie ein geographisch gewichtetes Regressionsmodell. Ihre Ergebnisse beschreiben unter anderem, dass die von ihnen untersuchten Unternehmen überwiegend in städtischen Regionen anzutreffen sind und die Verkehrsströme einen positiven Einfluss auf die räumliche Verteilung der Unternehmen haben. Insbesondere die lokalen Verflechtungen und industriellen Synergien haben einen starken Einfluss. Auf globaler Ebene schwächt die Wirkkraft dieser Einflussgrößen ab. Weiter untersuchen Zhu et al. (2023) die Einflüsse von ausländischen Direktinvestitionen und die Bedeutung der inländischen Wertschöpfungskette vor dem Hintergrund der räumlichen Heterogenität der Untersuchungsregionen.

5 Forschungslücken und Fragestellungen

Ziel des vorliegenden Kapitels ist es, die Ausrichtung der Forschungslücken und -fragen basierend auf den vorangegangenen Kapiteln hervorzuheben. Dies dient der Übersichtlichkeit, bevor in die Methodik zur Bearbeitung der Forschungsfragen erläutert wird. Diese werden in Kapitel 13 zusammenfassend beantwortet. Die Forschungsfragen sind, wie in der Einleitung erläutert, in drei inhaltliche Teile gegliedert. Zunächst steht die *Identifizierung des Untersuchungsgegenstandes* im Fokus. Dazu galt es die aktuelle Literatur zu sichten und gängige Methoden und Datenquellen zu identifizieren:

1. *Wie werden HCs in der Literatur definiert und mit welchen Inhalten beschäftigt sich die HC-Forschung?*
2. *Wie werden HCs in wissenschaftlichen Arbeiten untersucht? Welche Methoden und Daten werden verwendet?*

Zur Beantwortung dieser Forschungsfragen dient die ausführliche Literaturbetrachtung aus Kapitel 4. Aus der Zusammenfassung aktueller Literatur zu HCs wird deutlich, dass zunächst eine operationalisierte Identifizierung der HCs fehlt. Eine solche ist jedoch notwendig, um nachvollziehbare quantitative Analysen durchzuführen. Die Forschungsfragen 3. und 4. beziehen sich auf das in dieser Arbeit adressiert die Methodik zur Operationalisierung des Untersuchungsgegenstands der Dissertation:

3. *Inwieweit besteht die Möglichkeit die Unternehmenskategorie HC zu operationalisieren?*
4. *Wie lässt sich die Summe der identifizierten HCs beschreiben?*

Einen maßgeblichen Beitrag zur deutschen Wettbewerbsfähigkeit und Wirtschaftsleistung leisten die HCs (Bundesministerium für Wirtschaft und Energie 2019, S. 7-10; Simon 2022, S. 5).

Die Innovationstätigkeit und -fähigkeit wird als ein entscheidender Aspekt angesehen, um eine gesteigerte Wirtschaftsleistung zu erreichen (Glückler & Bathelt 2017, S. 130). Regionale Unterschiede der Wirtschaftsstruktur sind dabei das zentrale Element. Um Innovation zu fördern, ist die erfolgreiche Kompensation von Standortnachteilen durch Unternehmen notwendig (Eder & Tripl 2019, S. 1512; Virkkala 2007, S. 515). Dazu zählen unter anderem eine effiziente Organisation, eine hohe Kompetenz und ein umfassender Wissensaufbau in den Unternehmen. Der in Kapitel 3 beschriebene unternehmerische Charakter der HCs spiegelt sich hier deutlich wider. Einer dieser Charakterzüge ist, dass sie ein Maximum an technischem Fachwissen und

Innovationsfähigkeit anstreben. In der vorliegenden Dissertation wird angenommen, dass wenn diese Fähigkeiten über die Unternehmensgrenzen hinaus regional verankert werden können, die Region durch die wandelfähige technologische Basis profitieren kann. Es lässt sich vermuten, dass sich die Anwesenheit von HCs positiv auf den regionalen Innovationsoutput auswirkt.

HCs handeln werteorientiert (Simon 2012, S. 12; Venohr & Meyer 2007, S. 13, 22; Schlepphorst et al. 2016, S. 6-7). Durch langfristig angelegte Investitionen zielen sie darauf ab, den Unternehmenserfolg nachhaltig zu steigern. Sie planen hier nicht in kurzen Zeiträumen, sondern in Generationen und verzichten auf schnellstmögliches Wachstum sowie kurzfristige Gewinnmaximierung. Trotz der internationalen Ausrichtung der Unternehmen gilt für HCs das regionale Umfeld, also Arbeitskräfte, Infrastruktur, lokale Wertschöpfungsketten und Regionalpolitik als entscheidender Faktor für ihren Erfolg. Diese Eigenschaften sprechen deutlich für die Chance der Entwicklung gemeinsamer oder an den Perspektiven der HCs orientierter Instrumente zur wirtschaftlichen Stabilisierung von strukturschwachen Regionen.

Räumliche Muster und Einflussfaktoren in der bestehenden HC-Literatur werden bisher kaum berücksichtigt. Eine Erkenntnis von Simons (2012) Analyse ist, dass die deutschen HCs hauptsächlich in ländlichen Räumen anzutreffen sind (Ermann 2011, S. 2; Simon 2012, S. 381-383). Diese Ergebnisse werden in der vorliegenden Arbeit überprüft. Darüber hinaus wird in dieser Dissertation die sozioökonomische Struktur von Gemeinden analysiert, um die räumlichen Muster in welchen HCs verortet sind beschreiben zu können.

Der regelmäßige Austausch mit wissenschaftlichen Instituten, dem eigenen Kund:innenstamm, sowie die damit einhergehende Zusammenarbeit in F&E sind für HCs unerlässlich (Simon 2012, S. 265, 293-294). Diese Netzwerke fördern Innovationen und versorgen die Kundschaft mit einer spezialisierten Vielfalt an Dienstleistungen und Produkten. Hierdurch bauen die HCs ihre Marktführerschaft aus. Im regionalen Kontext sind die Innovationsfähigkeit und die Formen der Innovation (inkrementell vs. radikal-disruptiv) der Unternehmen (insbesondere HCs) zu bewerten (Vonnahme & Lang 2019, S. 33-34; Glückler 2013, S. 888). Moulart und Sekia (2003, S. 291) sowie Glückler et al. (2022, S. 235) beschreiben, dass der Charakter einer Region ausschlaggebend für die Innovationsleistung dieser ist. Die Heterogenität in der Ausstattung ihrer innovationsbezogenen Vermögenswerte unterstreicht den Bedarf an kleinräumigen Analysen.

Um individuelle Schlussfolgerungen zu entwerfen, gilt es einen methodischen Ansatz zu verwenden, welche diese individualisiert zulässt. Ein Grundstein der vorliegenden Untersuchung ist dementsprechend die regionale Typisierung von Gemeinden, um deren Charakter erfassen zu können. Dies beinhaltet im Kontext der beschriebenen Erkenntnisse keine Stadt-Land-

Forschungslücken und Fragestellungen

Dichotomie, um individuelle Schlussfolgerungen und Handlungsempfehlungen zuzulassen (Eder 2019a, S. 137). Zur quantitativen Analyse des Forschungsgegenstands werden die im Folgenden ausformulierten Forschungsfragen zur *regionalen Typisierung* in Kapitel 11 untersucht:

5. *Wie sind die Regionen strukturiert, in denen viele bzw. wenige HCs angesiedelt sind?*

6. *Lassen sich räumliche, sozioökonomische Muster erkennen?*

Der dritte inhaltliche Schritt der Arbeit hat zum Ziel, die vermuteten *Wirkungszusammenhänge* zwischen den HCs und der jeweiligen Region zu untersuchen. Bisher wurden, wie in den Kapiteln 3 und 4 ausgeführt, verschiedene wissenschaftliche Untersuchungen durchgeführt, um einen Einblick in die unternehmerischen Erfolgsmerkmale von HCs zu erhalten. Der Bedeutung des Unternehmensstandorts wird für den wirtschaftlichen Erfolg in der Literatur bisher nur wenig Beachtung geschenkt. Es existieren keine konkreten empirischen Untersuchungen zur sozioökonomischen Struktur des Unternehmensstandorts als Erfolgsfaktor für die Ansiedlung von HCs (Langenscheidt & Venohr 2014, S. 13). Forschungsfrage 7 adressiert diese Forschungslücke:

7. *Inwiefern stehen regionale Strukturmerkmale mit der Anwesenheit von HCs in Verbindung?*

In der aktuellen wissenschaftlichen Literatur wird argumentiert, dass überregionale Wissensnetzwerke eine zentrale Rolle für den wirtschaftlichen Erfolg eines Unternehmens einnehmen (Allen et al. 2016, S. 639; Autio et al. 2018, S. 77-78; Brökel et al. 2014, S. 2-3). Durch die Ausführungen in Kapitel 3 wird deutlich, dass die wachstumsfördernden Wissensspillover über größere Distanzen insbesondere für internationalisierte, digitalisierte Unternehmen möglich sind (Autio et al. 2018, S. 79-80; Döring 2005, S. 96-97). Doch auch die Förderung von lokalem Unternehmertum, Wachstum von Kleinunternehmen oder technischer Innovation regt endogenes Wachstum an (Martin & Sunley, 1998, S. 219). Dieses ist von der endogenen Wachstumstheorie nach Romer (1990) zu differenzieren, welche wachstumsfördernde Faktoren nicht im räumlichen Kontext betrachtet (Margarian 2013, S. 7; Rietmann 2022b, S.9). Demnach lassen sich die hohen F&E-Ausgaben und die Innovationsstärke von HCs mit dem endogenen Wachstum von Regionen erneut in Verbindung bringen (Liefner & Schätzl 2017, S. 114; Rietmann 2022b, S. 9). Denn Sotarauta et al. (2012, S. 359-362) benennen private Akteur:innen neben sozialen Akteur:innen als Treiber für regionale Entwicklung. Ein Ziel dieser Arbeit ist entsprechend festzustellen, inwieweit die als Treiber der deutschen Wirtschaft betitelten HCs als Innovationstreiber in den unterschiedlichen Regionstypen gelten.

Forschungslücken und Fragestellungen

Bisher wurde kaum in empirischen Ansätzen untersucht, inwieweit HCs den wirtschaftlichen Erfolg einer Region beeinflussen. In seiner Analyse von HCs im Kontext von Stadtentwicklung fordert das BBSR flächendeckende Studien, um Unternehmens- als auch Wirtschaftsstrukturen zu identifizieren (BBSR 2019, S. 58). Es lässt sich eine erhebliche Forschungslücke zu den wechselseitigen Wirkungen von sozioökonomischer Lage und HCs sowie den damit einhergehenden wirtschaftlichen Vorteilen sowie Bedürfnissen auf beiden Seiten feststellen. Forschungsfragen 8 und 9 fassen diese Forschungslücke wie folgt zusammen:

8. *In welchem Zusammenhang steht die Anwesenheit von HCs mit dem Innovationsoutput einer Gemeinde?*
9. *Inwieweit sind regionale, ebenenübergreifende Effekte zwischen der Anwesenheit von HCs mit den regionalen Strukturmerkmalen und dem Innovationsoutput einer Region festzustellen?*

Darüber hinaus wird anhand des erläuterten unternehmerischen Charakters (Kapitel 3.2), der zugeordneten Wettbewerbsstrategien der HCs sowie des Forschungsstands zu den Erfolgsfaktoren Innovation und Internationalisierung (Kapitel 4.2.1, 4.2.2) deutlich, dass HCs der Theorie nach Spillover-Effekte verursachen könnten. Die in Kapitel 2.2 erläuterten Spillover-Effekte unterscheiden drei Mechanismen (Arbeitskräfte und Qualifikation, Kontakte zu lokalen Akteur:innen, Demonstrationseffekte), durch die Unternehmen auf ihre Region ausstrahlen oder mit ihr verbunden sind (Blomström & Kokko 2001; Liefner & Schätzl 2017, S. 182-183). Bezugnehmend gilt es nach Identifizierung der HCs sowie Analyse der räumlichen Muster ebenfalls festzustellen, inwieweit die Anwesenheit von HCs Spillover-Effekte in ihre Nachbarregionen verursachen:

10. *Inwieweit lassen sich durch die Anwesenheit von HC in einer Region Spillover-Effekte auf ihre Nachbarregionen feststellen?*

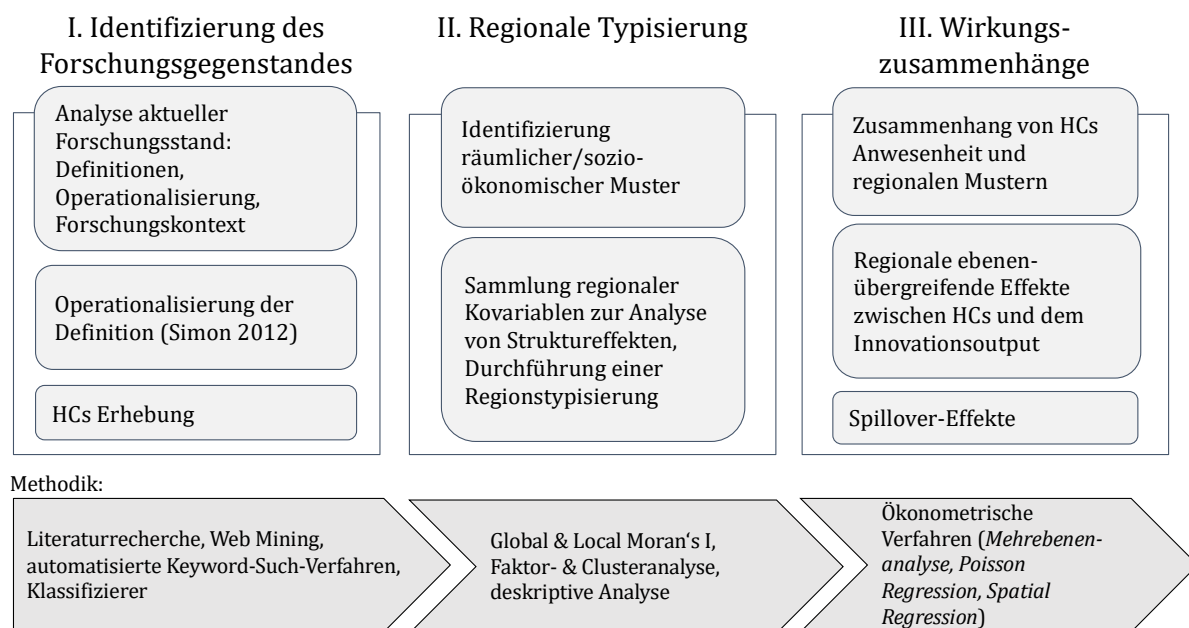
Die Fragestellungen basierend auf den drei eingangs formulierten und in diesem Kapitel weiter erläuterten Forschungszielen gilt es im Rahmen dieser Arbeit zu erarbeiten. Sie werden im Fazit zusammenfassend beantwortet. Hiermit soll das übergeordnete Ziel der Dissertation, die Identifizierung der HCs, die Testung im Zusammenhang mit regionalen Strukturen und die Wechselwirkungen im Innovationskontext von Regionen bearbeitet werden. Weiter ist es nicht das explizite Ziel dieser Arbeit kleinräumige Handlungsempfehlungen zu entwerfen. Viel eher wird ein Aufschlag gemacht, um Möglichkeiten zur Spezifizierung solcher Handlungsempfehlungen abzubilden.

II: Methodik

6 Methodisches Framework

Im Folgenden wird das methodische Vorgehen der Arbeit präsentiert. Die Wahl des Instrumentariums basiert auf den Forschungsfragen und Erkenntnissen der theoretisch-konzeptionellen Grundlagen, sowie den vorangegangenen Kapiteln bezüglich HCs. Zunächst wird das übergeordnete Forschungsdesign präsentiert. Darauf folgt die HC-Identifizierung, die Berechnung räumlicher Autokorrelation und das Vorgehen der Regionstypisierung. Es werden mehrere Regressionsmodelle zur Beantwortung der Forschungsfragen formuliert. Die genaue Herangehensweise wird in Kapitel 6 erläutert. In den Kapiteln 9.2 bis 9.5 werden die Methoden vorgestellt. Das methodische Forschungsdesign der vorliegenden Arbeit lässt sich in drei übergeordnete Schritte einteilen. Es basiert auf dem aus Kapitel 2 bis 4 abgeleiteten Forschungsbedarf (Kapitel 5). Dieser ist in den Forschungsfragen ausformuliert und in Abbildung 2 dargestellt.

Abbildung 2: Methodisches Framework



Quellen: Eigene Darstellung.

Der erste Schritt des methodischen Vorgehens ist die *Identifizierung des Forschungsgegenstandes*, um diesen im zweiten und dritten Schritt zu analysieren. Forschungsfragen 1 und 2 wurden in Kapitel 3 anhand einer ausführlichen Literaturanalyse bereits beantwortet. Wie dort eingehend betrachtet, nutzen die meisten Forschungsarbeiten die Definition Simons (2012) für ihre

Analysen von HCs. Deutlich wurde, dass es zwar einige Ansätze gibt, in denen die Unternehmenskategorie operationalisiert wurde, jedoch in der Regel mit starken Abweichungen von der Definition und den drei aufgeführten Kriterien zur Identifizierung. Durch die neuen Möglichkeiten, welche das Web Mining bietet, wird im ersten methodischen Baustein der Arbeit die Operationalisierung der Definition nach Simon (2012) durchgeführt. Anschließend werden die HCs identifiziert.

Im zweiten Schritt erfolgt die *Regionale Typisierung* mit besonderem Blick auf die sozioökonomische Struktur der Regionen, in welchen HCs angesiedelt sind. Dazu gehört zunächst die Identifizierung räumlicher sozioökonomischer Muster. Im ersten Schritt werden dazu der Global und Local Morans I berechnet, um die Verteilung der HCs in Deutschland auf räumliche Autokorrelation zu überprüfen. Im zweiten Schritt folgt die regionale Typisierung auf Gemeindeebene. Ziel ist es, die sozioökonomischen Strukturen deutscher Gemeinden abzubilden, um vor diesem Hintergrund die Lage der HC-Verteilung besser beschreiben zu können. Dazu werden durch eine Hauptkomponentenanalyse Faktorvariablen gebildet, welche die Strukturstärken und -schwächen der Regionen abbilden. Eine Modell-Based-Clusteranalyse (MBC) identifiziert anschließend verschiedene Raumtypen anhand dieser Faktoren.

Der dritte Baustein dient der Untersuchung nach vermuteten *Wirkungszusammenhängen* zwischen der Anwesenheit von HCs, räumlichen Mustern und Innovation. Dazu wird eine multiple Regressionsanalyse zur Untersuchung des Zusammenhangs zwischen unterschiedlichen sozioökonomischen Faktoren sowie der Anwesenheit von HCs und dem Innovationsoutput in einer Region gerechnet. Es folgt eine Regressionsanalyse mit Zählvariablen, um festzustellen, inwieweit sozioökonomische Merkmale Einfluss auf die Anzahl an HCs in einer Region haben. Den Einfluss von HCs auf Kreisebene auf den Effekt des Innovationsoutputs einer Gemeinde werden durch hierarchisch lineare Mehrebenenanalysen geschätzt (HLM). Abschließend erfolgt ein Test auf Nachbarschaftsbeziehungen und Spillover-Effekte anhand eines Spatial Lag Modells.

7 Identifizierung des Untersuchungsgegenstandes

In diesem Kapitel wird das methodische Vorgehen des ersten Untersuchungsschrittes *I. Identifizierung des Untersuchungsgegenstandes* präsentiert. Zunächst erfolgt dazu ein Einblick in die Methodik des Web Minings im Allgemeinen. Dies ist notwendig, um das Vorgehen der Identifizierung nachvollziehen zu können. Im Anschluss folgen die Unterkapitel, sortiert nach den drei Identifikationskriterien der HCs (siehe Einleitung). An erster Stelle die Ausgangsdatenbasis gemeinsam mit dem Umsatzkriterium, dann die Weltmarktführerschaft (Champions) und an letzter Stelle der Bekanntheitsgrad der Unternehmen (Hiddenness). Im finalen Unterkapitel wird die Methodik zur Lokalisierung der HCs sowie die Geokodierung der identifizierten Unternehmensadressen vorgestellt.

7.1 Web Mining

Ziel dieses Unterkapitels ist es, einen Einblick in diese Methodik zu erhalten, denn sie wird im Kapitel des Identifizierungskriteriums Weltmarktführerschaft (7.3 Champions) angewandt. Web Mining ist eine Unterkategorie des Text Minings (Miner et al. 2012, S. 30). Text Mining ist ein sehr weitgefasser Oberbegriff für die Verarbeitung und Analyse von semi- und unstrukturierten Textdaten. Je nach Blickwinkel der anwendenden Person kann es unterschiedlich definiert werden. Letztlich ist das Ziel des Text Minings, große Textdaten schnell und effizient zu untersuchen, indem diese in Vektoren umgewandelt werden. Zur Verarbeitung und Analyse werden Algorithmen entwickelt, welche die Analyse durchführen können. Text Mining umfasst insgesamt sieben sog. „Praxisbereiche“ aus unterschiedlichen verwandten Forschungs- und Methodikfeldern. Miner et al. (2012, S. 32) beginnen in ihrer Aufzählung mit der *Suche und Informationsbeschaffung*, sprich das Speichern und Abrufen von Textdokumenten. Das *Clustern von Dokumenten* beinhaltet die Kategorisierung von Begriffen, Absätzen oder gesamten Dokumenten. Die *Dokumentenklassifizierung* beinhaltet ähnliches wie das Clustern, jedoch auf der Grundlage von an Beispielen trainierten Modellen. Bei der *Informationsextraktion* werden aus unstrukturierten Texten sowohl relevante Fakten als auch Beziehungen identifiziert. Unstrukturierte Daten werden zu strukturierten Daten. Das sog. Natural Language Processing (NLP) bearbeitet Sprachverarbeitungs- und verstehensaufgaben. Die *Konzeptextraktion* kann Wörter und Sätze in semantisch ähnliche Gruppen einteilen.

Das *Web Mining* wird in drei verschiedene Kategorien unterteilt (Miner et al. 2012, S. 954). Dazu zählt das Web Structure Mining, das Web Usage Mining und das Web Content Mining. Bei der Durchführung des Web Structure Minings werden insbesondere die Links von einer Webseite zu

Identifizierung des Untersuchungsgegenstandes

anderen Webseiten analysiert. Li et al. (2018) nutzen die Methode des Web Minings, um den Einfluss der Triple Helix auf das Wachstum von KMU zu analysieren. Sie identifizieren verschiedene neue Maße zur Operationalisierung der Triple-Helix-Akteure und deren Kommunikation und Vernetzung miteinander, basierend auf den (Uniform Resource Locator) URL-Links der analysierten Webseiten (Li et al. 2018, S. 5). Hier werden beispielsweise die Beziehungen zwischen den Akteuren anhand der gegenseitigen Verlinkungen auf den Webseiten gemessen.

Die zweite Kategorie ist das Web Usage Mining (Miner et al. 2012, S. 954). Hier werden die Nutzungsdaten von Webseiten verarbeitet. Vaughan und Yang (2013) analysieren beispielsweise den sogenannten Web-Traffic, das Benutzeraufkommen, und den Zusammenhang zwischen Web-Traffic und wirtschaftlichen Leistungskennzahlen. Dazu testen sie verschiedene Web-Traffic-Datenquellen.

Beim Web Content Mining geht es um die Analyse von Webinhalten, die strukturiert werden sollen (Miner et al. 2012, S. 954). Dazu zählen Textdaten genauso wie multimediale Inhalte. Der in dieser Arbeit verwendete methodische Ansatz fällt in diese Kategorie. In aktuellen Studien werden häufig die Vorteile von Web (Content) Mining in Bezug auf Aktualität, Abdeckung und Verzerrung gegenüber herkömmlichen Datenbanken betont (siehe Youtie et al. 2012; Arora et al. 2013; Kinne & Lenz 2021). Gök et al. (2015, S. 653) untersuchen in ihrer Arbeit zum Beispiel die F&E-Aktivitäten von über 200 Unternehmen. Die Autoren wenden Web Content Mining an, um es mit traditionellen Datenquellen zu vergleichen. Sie kommen zu dem Schluss, dass Webdaten die Möglichkeit bieten, vertiefte Informationen zu sammeln und zeigen, dass Unternehmenswebseiten vielfältige relevante und aktuelle Inhalte präsentieren und somit als relevante Datenquelle betrachtet werden können. In ihrer Studie konnten sie deutlich mehr Unternehmen mit F&E-Aktivitäten identifizieren als mit traditionellen Datenquellen. Héroux-Vaillancout et al. (2020, S. 1601, 1625–1627) zeigen in ihrem Projekt ähnliche Ergebnisse. Sie identifizieren ebenfalls Innovationsindikatoren mit Hilfe ihrer Web-Inhaltsanalyse. Beide Projekte nutzen die sog. Schlüsselwortsuche, um Innovationsindikatoren zu generieren. Zu diesem Zweck wählen Gök et al. (2015, S. 656) themenbezogene Schlüsselwörter. Auf die genaue Vorgehensweise bei der Auswahl gehen sie nicht ein. Héroux-Vaillancout et al. (2020, S. 1604) verwenden für ihre Analyse die Schlüsselwörter von Gök et al. (2015, S. 658) und anderen früheren Innovationsstudien. Als drittes Beispiel ist die Arbeit von Kinne und Axenbeck (2020, S. 2028) zu nennen. Ihre Analysen finden ebenfalls im Bereich der Innovationsstudien statt. Sie erarbeiten, ebenfalls durch Web Content Mining, ein Innovationsmerkmal unter Verwendung von Schlüsselwörtern zum Thema künstliche Intelligenz (KI).

Identifizierung des Untersuchungsgegenstandes

Weitere Beispiele der aktuellen Forschung der Verwendung des Web Minings werden im Folgenden kurz aufgeführt. Beispielsweise ist die umfangreichste georeferenzierte Analyse deutscher Unternehmenswebseiten zu nennen. Sie umfasst 633.523 Unternehmen und wurde von Abbasiharofteh et al. (2023) durchgeführt. Die Datenbasis dieser Studie ist das Mannheimer Unternehmenspanel.

Kinne und Axenbeck (2020) identifizieren innovative Unternehmen, die auf ihren Webseiten Themen der Künstlichen Intelligenz diskutieren. Dörr et al. (2021) ermitteln Unternehmen, die auf den Webseiten COVID-19-Pandemie-Texte besprechen, und klassifizieren sie nach Inhalten (weitere Beispiele: Gök et al. 2015; Li et al. 2018; Youtie et al. 2012). Das sogenannte Web Content Mining und das damit verbundene NLP bieten neue Möglichkeiten der Textverarbeitung. Die Arbeit von Kriesch (2023) betrachtet und testet unter anderem Web Mining sowie NLP als neue methodische Komponente in der Wirtschaftsgeographie. Seine Ansätze und Erkenntnisse im Bereich des Web Minings dienen der Methodik dieser Arbeit unter anderem als Orientierung.

Der aktuelle Stand der Forschung zeigt auch, welchen Beitrag Webdaten leisten können, um die komplexen Wechselwirkungen zwischen Innovation und Raum besser zu verstehen. Kinne und Resch (2017) zeigen beispielsweise, dass Webdaten bzw. OSM-Daten genutzt werden können, um die Mikrostandortmuster von Softwareunternehmen zu identifizieren. Darüber hinaus analysieren Krüger et al. (2020) die Beziehungen von innovativen Unternehmen im Internet. Rammer et al. (2020) untersuchen die Beziehungen zwischen Wissensnähe und Unternehmensinnovation. Kinne und Lenz (2021) nutzen Webdaten, um innovative Unternehmen anhand ihrer Webseiten-Texte zu identifizieren. Die Ergebnisse dieser Studie weisen große Ähnlichkeiten mit Vergleichsdaten aus offiziellen Statistiken auf.

Daraus lässt sich schließen, dass Web Mining die Möglichkeit bietet, umfassende, aktuelle, schnell zugängliche und flexible Unternehmensdaten zu sammeln. Allerdings gilt diese Form der Datengewinnung und -verarbeitung auch als schwierig zu interpretieren und kann inkonsistent und verwirrend sein (Gök et al. 2015, S. 666). Bislang wurden vor allem Keywordsuchen oder Klassifikationsalgorithmen verwendet, um Themen in Webtexten zu klassifizieren und kategorisieren. Wie beschrieben, stammen die verwendeten Schlüsselwörter oft aus Literaturstudien, Lexika oder aus dem Wissen der Autor:innen. Die Studien gehen nicht darauf ein, inwieweit die Anzahl der Schlagwörter ausreicht, um die inhaltliche Breite des Themas vollständig abzudecken. Gök et al. (2015, S. 662) weisen lediglich darauf hin, dass die Verwendung von einfachen Keywords zu einer großen Anzahl falsch positiver Ergebnisse führen kann. Sie betonen, dass für eine zielführende Keyword Anwendung der Kontext der Wörter mit dem

Identifizierung des Untersuchungsgegenstandes

Forschungsziel übereinstimmen muss. Die Verwendung eines Klassifikationsalgorithmus ist üblich, um die themenspezifische Filterung von Webtextdaten zu verbessern. Dieser wird darauf hintrainiert, Texte auf der Grundlage ihrer semantischen Bedeutung zu kategorisieren. Im Falle eines unscharfen Themas wie der Marktführerschaft eines Unternehmens steht ein Klassifikationsalgorithmus vor einer Herausforderung. Hier geht es um eine sehr feine Differenzierung des Inhalts. Unternehmenswebseiten können im Allgemeinen sehr ähnlich sein (Branche, Unternehmensgröße, Standort, Geschichte, etc.). Sie können sich jedoch hinsichtlich des Kriteriums der Weltmarktführerschaft, wie es in dieser Arbeit gemessen werden soll, stark unterscheiden. Dörr et al. (2021) zeigen bereits ein ähnliches Vorgehen. Sie sind die ersten, die eine Kombination aus beiden Ansätzen anwenden. Sie identifizieren COVID-19-Themen auf Unternehmenswebseiten und klassifizieren die Inhalte weiter kontextuell. Die Vielseitigkeit von Unternehmenswebseiten, ihre Texte und Strukturen stellen eine Herausforderung für die Autor:innen jedes der hier vorgestellten Forschungsdesigns dar. Die Ergebnisse unterstreichen somit den aktuellen Stand der Forschung und weisen auf weitere große Potenziale der webdatenbasierten Innovationsforschung hin.

7.2 Ausgangsdatenbasis und Hidden Champions Umsatzgrenze

Wie in der Einleitung beschrieben, definiert Simon (2012) HCs nach drei Kriterien. Das erste Kriterium benennt den maximalen Jahresumsatz der HCs. Dieser soll unter fünf Milliarden Euro liegen (Simon 2012, S. 83). Dazu gilt es zunächst eine Liste aller deutschen Unternehmen zu recherchieren. Die MARKUS-Datenbank ist eine Unternehmensdatenbank aller wirtschaftsaktiven deutschen, österreichischen und luxemburgischen Unternehmen (Bureau van Dijk 2020). Diese Datenbank enthält für Deutschland knapp 3,2 Millionen Einträge. Da fast zwei Drittel aller HCs im verarbeitenden und produzierenden Gewerbe tätig sind, wurde dieser WZ als Filter im Datenabruf der Datenbank angewendet (Simon 2012, S. 86). Außerdem wurden alle Unternehmen über fünf Milliarden Euro Umsatz herausgefiltert. Das ergab eine Ausgangsdatenbasis von 130.000 Unternehmen. Neben dem Unternehmensnamen sowie der Rechtsform sind mithilfe der MARKUS-Datenbank zudem Informationen über die Postleitzahl, den Ort sowie das Gründungsdatum der Unternehmen verfügbar. Das Vorgehen wird in Abbildung 3 dargestellt.

Um die Unternehmenswebseiten zu analysieren, müssen diese zunächst recherchiert werden. Die Internetpräsenz eines Unternehmens wird Webseite genannt und besteht aus mehreren Webpages (Kinne & Axenbeck 2018, S. 7). Die sog. Homepage steht im höchsten Level des HTML-Codes und wird auch als Startpage bezeichnet. Von dieser wird der Scrapingprozess gestartet.

Identifizierung des Untersuchungsgegenstandes

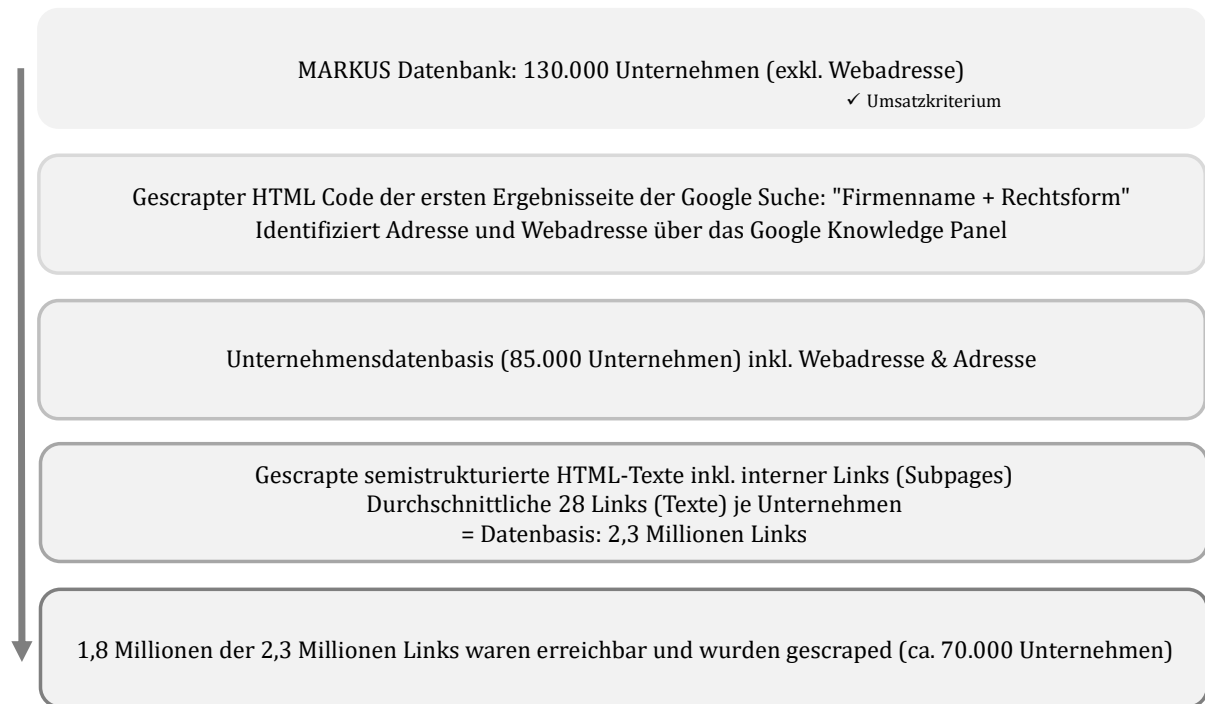
Unter *Scraping* versteht man das automatisierte Auslesen und in diesem Fall auch Speichern von Webinhalten. Alle im HTML-Code an die Startpage folgenden Webpages der Homepage werden in dieser Arbeit Subpages genannt.

Um die Unternehmenswebseiten zu erhalten, wurde der HTML-Code der ersten Ergebnisseite der Google Suche: „Firmenname + Rechtsform“ gescraped. Verwendet wurde in Python das Paket *Beautiful Soup* (Richardson 2007). Aus dem ebenfalls im HTML-Code enthaltenen Google Knowledge Panel konnten dann die Firmennamen, Webadressen und Adressen der Unternehmen abgelesen werden. Es wurden 85.000 Unternehmenswebseiten gescraped. Bei den restlichen 45.000 handelt es sich entweder um Unternehmen, für die kein Google Knowledge Panel verfügbar ist, oder um Unternehmen, denen Webseiten nicht eindeutig zuzuordnen sind. Dies trifft beispielsweise zu, wenn der Unternehmensname im Google Knowledge Panel nicht mit dem aus der MARKUS-Datenbank übereinstimmt. Es wurden die Unternehmen weiter berücksichtigt, die eindeutig den recherchierten Webseiten über den Unternehmensnamen und die Postleitzahl im Google Knowledge Panel zuzuordnen sind.

Im nächsten Schritt wurden die Webseiteninhalte, die Web Contents, gescraped. Beispielsweise haben viele Unternehmen, insbesondere im verarbeitenden und produzierenden Gewerbe, große Downloadbereiche oder auch Shops. Außerdem sind Verlinkungen zu den Webseiten in anderen Sprachen. Diese Informationen sind in der Regel nicht relevant zur Identifizierung der (Welt-) Marktführerschaft der Unternehmen. Um große Datenmengen zu vermeiden, setzen Kinne und Axenbeck (2018, S. 22) beispielsweise einen Webscraper ein, der das Scrapen nach 100 Webpages beendet. Dies machen die Autor:innen am Median der Hyperverlinkungen je Webseite fest. In der vorliegenden Arbeit wird vermieden, dass mit einem konkreten Seiten-Scraping-Limit die Informationen „abgeschnitten“ werden. Daher wurde sich dazu entschieden, die gesamte Startseite, sowie die erste Subpage-Ebene zu scrapen, da diese in der Regel über eine sehr heterogene Anzahl an Subpages verfügen. Dementsprechend wurden alle von der Startseite aus verlinkten Subpages gescraped. Dies ergibt eine Datenbasis von 2,3 Millionen Links. Für die ca. 85.000 Unternehmen sind das im Schnitt 28 Links je Unternehmen. Von diesen Links waren 1,8 Millionen erreichbar und konnten gescraped werden. Bei den restlichen nicht erreichbaren/nicht gescrapten Links handelte es sich beispielsweise um PDFs oder Downloadlinks. Gespeichert wurden die Daten zusammen mit den daran korrespondierenden Unternehmensinformationen aus dem Google Knowledge Panel sowie der MARKUS-Datenbank in einer SQLite-Datenbank.

Identifizierung des Untersuchungsgegenstandes

Abbildung 3: Datenbasis Webseiten



Quelle: Eigene Darstellung.

7.3 Champions

Das zweite Identifizierungskriterium der HCs wird im Rahmen dieser Arbeit als Champions-Kriterium betitelt. Ein HC muss zu den „*Top-3-Unternehmen auf dem Weltmarkt oder Nr. 1 auf einem Kontinent*“ (vgl. Simon 2012, S. 83) gehören. Simon (2012) beschreibt in seinen Ausführungen, dass die Marktstellung durch den (relativen) Marktanteil eines Unternehmens erklärt wird. Liegen keine Informationen zu den Marktanteilen vor, muss sich auf die Aussage des Unternehmens verlassen werden. Diese Aussagen wurden bis dato nur in qualitativen Analysen erhoben. Die Höhe des relativen Marktanteils der Unternehmen ist selten öffentlich zugänglich. Auch durch die Nischenmarktpräsenz ist eine vollständige Identifizierung des Marktes und potenzieller Wettbewerber aus externer Perspektive nicht eindeutig messbar.

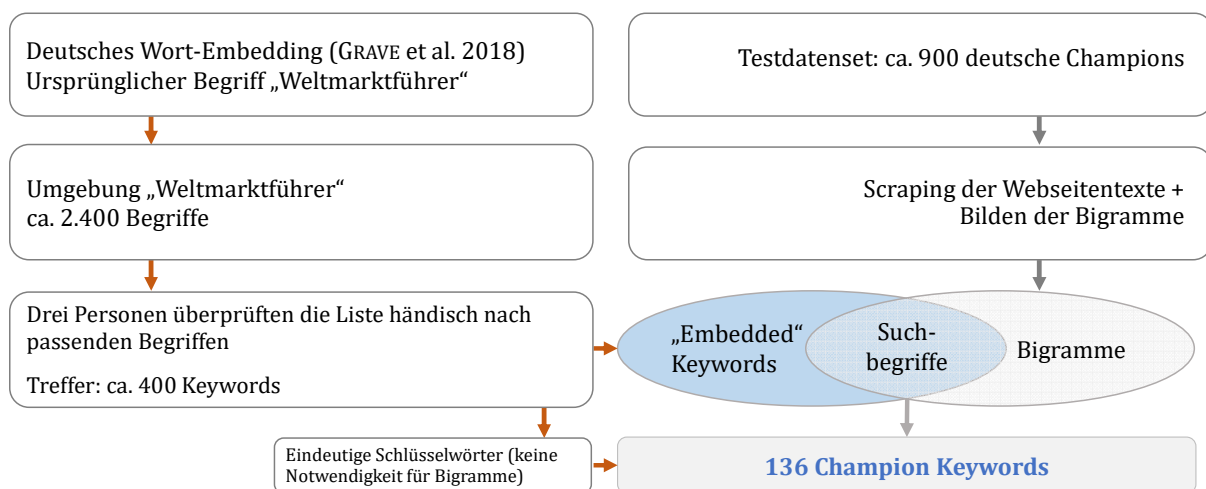
Die vorliegende Arbeit verlässt sich, ähnlich wie von Simon (2012, S. 83), auf die Aussagen der Unternehmen. Es wird davon ausgegangen, dass ein Unternehmen, das Marktführer ist, dies auch weiß und kommuniziert (Johann et al. 2021, S. 887). Es wird davon ausgegangen, dass ein Unternehmen, das davon spricht, Marktführer in seiner Branche zu sein, die Wahrheit sagt. Diese Information wird auf den Webseiten der Unternehmen „gesucht“. Dazu wurde ein top down Web Mining-Ansatz entwickelt.

Identifizierung des Untersuchungsgegenstandes

Die Keywordsuche wird dazu genutzt, die als HC in Frage kommenden Champions zu ermitteln. Unternehmen, die ein solches Keyword auf ihrer Webseite führen, werden mit der Championship der Unternehmen in Zusammenhang gesetzt. Ob dieser kausal ist, bleibt jedoch unklar. Entsprechend sollte der Kontext des Keywords mit einbezogen werden. Im Gegensatz zur traditionellen literaturbasierten Keywordauswahl, die durch den Wissenshorizont der Forschenden eingeschränkt ist, wurde ein feinkörniges Verfahren eingesetzt, um geeignete Keywords für die Erkennung der Erfüllung des Champions-Kriteriums in Webseiten-Texten zu identifizieren (Grave et al. 2018). Die vortrainierten, generischen Worteinbettungen waren ein effektives Grundelement bei der Erstellung einer vollständigen Keywordsammlung. So wurden für den Begriff „Weltmarktführer“ automatisiert Wortrepräsentationen zusammengestellt. Das Ergebnis war eine Wortumgebung von 2.400 Begriffen. Diese wurden dann von drei mit dem Forschungsgegenstand der HCs vertrauten Wissenschaftler:innen auf Relevanz überprüft. Das Ergebnis sind 136 Keywords aus dem Wortumfeld der Weltmarktführerschaft.

Um den Kontext des Begriffs „Weltmarktführerschaft“ mit einzubeziehen, wurden Bigramme verwendet. In der vorliegenden Arbeit sind Bigramme wie folgt definiert. Es handelt es sich um zwei Wörter, welche häufig gemeinsam auftreten und voneinander abhängig sind bzw. in einem inhaltlichen Kontext stehen. Dazu wurde ein Testdatensatz manuell zusammengestellt (Ca. 900 HCs). Die Webseitentexte der Unternehmen wurden, wie im vorangehenden Kapitel beschrieben, gescraped. Auf Basis der Texte wurden dann Bigramme gebildet. Alle Bigramme, die mindestens eins der 400 Keywords beinhalteten, wurden mit in die Analyse einbezogen. Beispielhaft zu nennen sind hier „weltweit_führend“ oder „europäischer_Marktführer“. Das Vorgehen ist in Abbildung 4 dargestellt.

Abbildung 4: Keyword-Extraktion



Quelle: Eigene Darstellung.

Identifizierung des Untersuchungsgegenstandes

Im folgenden Schritt galt es, die identifizierten Champion-Keywords in den 1,8 Millionen Webseitentexten zu suchen. Es wurden 65.000 Sätze mit den Keywords gefunden. Dies betraf knapp 14.000 Unternehmen. Wie oben beschrieben, kann eine solche Keywordsuche zu falsch positiven Ergebnissen führen. Um dies zu überprüfen, wurde ein Testdatensatz aus den 14.000 durch die Keywords identifizierten Champions entnommen. 809 Unternehmen, auf deren Webseiten eines der 400 Champion-Keywords gefunden wurde, wurden genauer betrachtet. Bei 394 Unternehmen ließ sich aus dem schriftlichen Kontext, in dem das Keyword stand, erschließen, dass es sich tatsächlich um einen sog. Champion handelt. Bei den anderen Unternehmen wurde beispielsweise davon gesprochen, mit einem solchen zusammenzuarbeiten oder solche in der Region zu haben. Entsprechend konnte die sehr umfangreiche Keywordsuche nur eine Genauigkeit von 49 Prozent aufweisen. Es lässt sich also eine leichte Korrelation zwischen dem Unternehmen und dem Keyword annehmen. Jedoch besteht keineswegs ein kausaler Zusammenhang. Die hier angewandte Methode hat den Vorteil, dass durch das Word-Embedding und die Bigramm-Methode echte Negative erkannt wurden. Es wird davon ausgegangen, dass die 71.000 Unternehmen, die keine der Champion-Keywords aufweisen, auch keine solchen sind. Inwieweit bei den übrigen Unternehmen noch falsche Positive enthalten sind, gilt durch den Klassifizierungsalgorithmus zu spezifizieren.

Bei der Kontrolle der Ergebnisse wurde deutlich, dass ein weiterer Zwischenschritt zur Identifizierung der Champions erfolgen muss. Bei Betrachtung der Webseiteninhalte wie „Wir arbeiten zusammen mit weltmarktführenden Unternehmen“ oder „europäische Marktführer vertrauen auf unsere Produkte“ sind hier als sog. falsch Positive Ergebnisse zu nennen. Die Begriffskombinationen allein bilden nicht die gesuchte Championship ab. Dazu muss der Kontext der Keywords erfasst werden. Ziel dieses Zwischenschritts war es, die falsch positiven Champions herauszufiltern. Dazu wird die Keywordsuche mit einem Klassifikationsalgorithmus kombiniert und das vortrainierte Sprachmodell „XLM-RoBERTa“ verwendet. Das Modell verfügt über ein gutes Sprachgrundverständnis, da es mit großen Datenmengen trainiert worden ist (Malte & Ratadiya 2019, S. 10). Es verfügt über die Fähigkeit, anhand kleiner Datenmengen, wie sie hier vorliegen, erfolgreich auf Klassifikationsprobleme trainiert werden zu können.

Zur Vorbereitung für den Klassifikationsalgorithmus wurden aus den 809 Unternehmenswebseiten manuell 1.377 Sätze identifiziert, welche mindestens ein Champion-Keyword beinhalten. Die Texte wurden gereinigt, indem Zahlen, Sonderzeichen und Buchstaben, die nicht im deutschen Alphabet vorkommen, entfernt wurden. Dieser Datensatz wurde dann genutzt, um das Sprachmodell zu trainieren. Dieses Training nennt sich „Transferlernen“ (Malte

& Ratadiya 2019, S. 1-2). 55 Prozent des Datensatzes wurden für das Training, 30 Prozent der Daten zum Testen und 15 Prozent zur Validierung des Klassifikationsalgorithmuses verwendet.

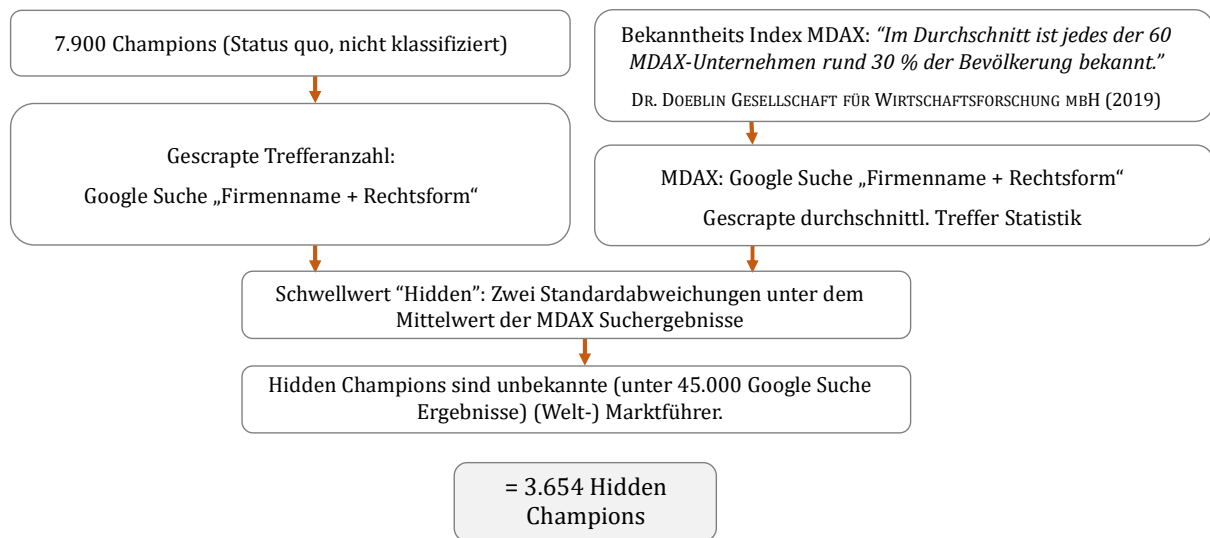
Nach dem Training war der Klassifikationsalgorithmus dazu in der Lage, auf Satzebene zu entscheiden, ob ein Unternehmen ein Champion ist. Bei der Validierung konnte der Klassifikationsalgorithmus 82 Prozent der Fälle identifizieren. Die Klassifizierung wurde auf Subpageebene durchgeführt. So kann auf dieser Ebene der Klassifikationsalgorithmus für ein Unternehmen zu unterschiedlichen Entscheidungen kommen. Entsprechend kann davon ausgegangen werden, dass ein Unternehmen als Champion gilt, wenn der Klassifikationsalgorithmus auf einer Subpage einer Unternehmenswebseite dieses als Champion identifiziert. Durch diese Entscheidungsmaxime konnte die Genauigkeit auf 83 Prozent erhöht werden. Bei der Anwendung auf den Gesamtdatensatz der knapp 65.000 Subpages konnten ca. 7.900 Unternehmen als Champions identifiziert werden.

7.4 Hiddenness

Im finalen Schritt der HC-Identifizierung galt es, das dritte Identifizierungskriterium der HCs zu operationalisieren. HCs sind der breiten Öffentlichkeit unbekannt. Simon (2012) beschreibt dieses Kriterium als subjektiv und situationsbezogen. Daher ist ein Ziel der vorliegenden Arbeit, einen ersten Ansatz zu schaffen, das Kriterium zu operationalisieren. Dazu wurde weiteres Web Content Mining durchgeführt. In diesem Fall wurden die Google Suche-Treffer der Unternehmen gescraped. Die Google Suche stellt neben konkreten Inhalten zu dem Suchbegriff Informationen darüber bereit, wie oft der Unternehmensname im Internet vorkommt. Diese Variable stellt in der vorliegenden Arbeit die gesuchte Information über den Bekanntheitsgrad des Unternehmens, bzw. den Interessensgrad der Bevölkerung dar. Bei der Literaturrecherche zur Bekanntheit von Unternehmen konnte anhand einer Studie zur Bekanntheit von MDAX-Unternehmen ein Schwellenwert festgesetzt werden: *“Im Durchschnitt ist jede der 60 MDax-Gesellschaften rund 30 Prozent der Bevölkerung bekannt”* (vgl. Dr. Doebelin Gesellschaft für Wirtschaftsforschung mbH 2019, S. 1). Darauf aufbauend wurde parallel der HTML-Code mit den Google Suche-Treffern der 60 MDAX-Unternehmen und der 7.900 Champions gescraped. Ziel war es einen ähnlichen Zeitpunkt der Google Suche-Ergebnisse zu berücksichtigen. Vom Mittelwert der Treffer der MDAX-Unternehmen wurden zwei Standardabweichungen dieser subtrahiert. Das Ergebnis stellt den Schwellenwert für die *Hiddenness* eines Unternehmens dar. Dieser liegt bei knapp 45.000 Google Suche-Treffern. Ergebnis sind ca. 3.654 HCs. Das Vorgehen ist in Abbildung 5 dargestellt.

Identifizierung des Untersuchungsgegenstandes

Abbildung 5: Vorgehensweise der Operationalisierung des Hiddenness Kriteriums



Quelle: Eigene Darstellung.

7.5 Geokodierung der Hidden Champions

Nachdem im vorigen Kapitel die Identifizierung der HCs vorgestellt wurde, folgt nun die Verarbeitung der neuen Daten. Um die Verteilung der HCs zu untersuchen, war der erste Schritt der deskriptiven Analyse die Geokodierung der Unternehmensadressen. Dazu wurde das Geokodierungssystem Nominatim genutzt. Dabei handelt es sich um ein Open Source Geokodierungssystem, welches auf OpenStreetMap-Daten basiert (Clemens 2015, S. 1). Das System ist in der Lage, die Informationen von Adressen, um Geokoordinaten zu ergänzen. Dazu durchsucht es die OpenStreetMap-Daten nach den Adressen der, in diesem Fall, Unternehmen. Es werden sog. synthetische Adressen der OpenStreetMap-Punkte erzeugt (OpenStreetMap Contributors 2023). Dieses Vorgehen wird als sog. *Reverse Geocoding* bezeichnet. Die Koordinaten der synthetischen Adressen können dann für räumliche Analysen verwendet werden. Für die vorliegende Arbeit wurden durch das lokal installierten Geokodierungssystem die Adressen der HCs via Python geokodiert.

8 Regionstypisierung

In diesem Kapitel wird das methodische Vorgehen des Untersuchungsschrittes *II. Regionale Typisierung* vorgestellt. Zunächst erfolgen Tests auf räumliche Autokorrelation zur ersten Analyse der räumlichen Verteilung der HCs. Die Regionstypisierung erfolgt dann auf Gemeindeebene (Wieland & Fuchs 2018, S. 152). Dazu werden die Gebiete in Gruppen zusammengefasst, die möglichst homogenen Klassen bezüglich verschiedener sozioökonomischer Faktoren entsprechen (Schätzl 2000, S. 94). Ziel der Regionstypisierung ist die Identifizierung unterschiedlicher Strukturen (Glückler & Bathelt 2017, S. 130). Zunächst werden die Untersuchungsebene und die Methodenauswahl vorgestellt. Dann wird der Datensatz präsentiert, woraufhin die Beschreibung des Vorgehens bei der HKA sowie der Clusteranalyse erfolgt.

8.1 Räumliche Autokorrelation

Um die Analyse der räumlichen Verteilung der identifizierten HCs durchzuführen, wurde in dieser Arbeit ein Test auf räumliche Autokorrelation durchgeführt, um zu untersuchen, inwieweit die Verteilung der HCs zufällig ist. Räumliche Autokorrelation beschreibt die zusätzliche räumliche Abhängigkeit zwischen benachbarten Regionen. Beispielsweise bildet sie sich in regionalen Netzwerken durch Spillover-Effekte ab. Räumliche Autokorrelation liegt häufig bei Regressionsmodellen vor, welche räumliche Untersuchungseinheiten analysieren (Eckey et al. 2006, S. 549-550) und lässt sich dadurch identifizieren, dass die Residuen der benachbarten Regionen abhängig voneinander sind. Residuen sind die Abweichungen vom tatsächlichen Beobachtungswert der Regressionslinie. Demnach haben räumliche Ballungen ähnliche Residuen und korrelieren demzufolge miteinander. Entsprechend sind die Signifikanzen nicht räumlicher Regressionsmodelle bei einer räumlichen Analyse nicht gültig oder die Koeffizienten sind verzerrt (Anselin 1988, S. 57). Die regionale Abhängigkeit ist in Regressionsmodellen mit räumlichen Untersuchungseinheiten zu berücksichtigen. Feststellen lässt sich die räumliche Autokorrelation sowohl über lokale als auch globale Maße. Eine positive räumliche Autokorrelation beschreibt einen Sachverhalt, in dem ähnliche Werte räumlich nah beieinander auftreten, ungeachtet dessen, ob es sich um hohe oder niedrige Werte handelt (Eckey et al. 2006, S. 4; Rey et al. 2020; Schulze 2008, S. 70). Negative räumliche Autokorrelation beschreibt hingegen, dass ähnliche Werte weiter voneinander entfernt liegen.

Globale räumliche Autokorrelation ist messbar durch den sog. Global Moran's I (Rey et al. 2020). Der Indikator beschreibt die Stärke der Clusterung der Daten. Er beschreibt, inwieweit die Werte insgesamt positiv oder negativ autokorreliert sind, und zeigt den allgemeinen Trend, welcher

durch die untersuchten Wertepunkte beschrieben wird. Der Global Moran's I betrachtet den Datensatz insgesamt, was Nachteile mit sich bringen kann. Beispielsweise gibt er keine Hinweise auf interne Clusterungen oder Streuungen eines Datensatzes und deren Positionen. Lokale Maße der räumlichen Autokorrelation können diese Informationslücke füllen (Anselin 1995, S. 94). Dazu zählt der Local Moran's I. Er misst die Nachbarschaftsbeziehungen für jede einbezogene Region, nicht für alle im Mittel. Dadurch lassen sich die potenzielle heterogene Abhängigkeit der einbezogenen Regionen bewerten und räumliche Konzentrationen identifizieren. Anhand der Indikatoren lässt sich die zufällige Verteilung der HCs überprüfen. Es können Cluster der Unternehmenskategorie identifiziert werden und auf dieser Basis im Rahmen von Regressionsmodellen die Wirkung der identifizierten Nachbarschaftsbeziehungen mit einbezogen werden. Die Berechnung wurde in Python mit *geopandas* und *pysal* durchgeführt. Die einbezogenen Daten sind transformiert.

8.2 Methodenauswahl und Untersuchungsebene

In der vorliegenden Untersuchung wurde die Gemeindeebene als datenseitig kleinräumige Einheit gewählt, da nach dem Modifiable Areal Unit Problem (MAUP) bei Verwendung unterschiedlicher Gebietszuschnitte eine Veränderung der Analyseergebnisse deutlich wird (Wieland & Fuchs 2018, S. 155). Dies kann insbesondere bei Vergrößerung zu großen Ergebnisunterschieden und Fehlinterpretationen führen. Es wird empfohlen, die kleinräumig verfügbaren Daten zu verwenden, um die Veränderung der Ergebnisse durch die homogeneren Eigenschaften der zusammengefassten größeren Regionen (Kreise) zu umgehen (Dapena et al. 2016, S. 186). Eder und Trippel (2019, S. 1517) beschreiben in ihrer Analyse, dass der Charakter der Peripherie ausschlaggebend für die Innovationsleistung einer Region sein kann. Naheliegender ist hier zunächst die Ländlichkeit oder Urbanität einer Region als Charaktereigenschaft anzuwenden. Doch Regionen sind selten entweder urban oder peripher (Eder 2019, S. 42-43). Es gibt stattdessen viele Nuancen, welche selten einheitlich sind. Es gilt in der Analyse also entsprechend nicht nur nach ländlich und urban zu unterscheiden.

In der vorliegenden Arbeit wurde eine multivariate Regionstypisierung durchgeführt. Zur Typisierung und Analyse der Gemeindecharakteristika wurden Sekundärstatistiken hinzugezogen. Dazu wurden zunächst aus der Literatur abgeleitete relevante Variablen vorgestellt. Weiter erfolgte eine Faktorenanalyse in Form einer Hauptkomponentenanalyse (HKA) zur Extraktion der wichtigsten Informationen und Reduktion der Variablenanzahl. Diese fasst die untereinander korrelierenden Variablen zu Faktoren zusammen. Anhand der identifizierten Faktoren folgte eine Clusteranalyse zur Identifizierung der Regionstypen. Es wurde

sich für die Methode des MBC entschieden (McNicholas 2016, S. 335). Die Methode bietet die Identifizierung der Einteilung der Raumstruktur für die gegebenen Daten auf Gemeindeebene.

8.2.1 Indikatorenauswahl

Die Auswahl der Indikatoren zur Regionstypisierung erfolgte literaturbasiert anhand des Vorgehens der Arbeit von Wieland und Fuchs (2018, S. 156). Die Autoren wählen Indikatoren aus vier sozioökonomischen Themenbereichen. Dazu zählt Demographie und Wohnen, Wirtschaft und Arbeitsmarkt, Nahversorgung und Erreichbarkeit sowie private und öffentliche Haushalte. Da einige der von Wieland und Fuchs (2018, S. 158) verwendeten Variablen nicht für Deutschland auf Gemeindeebene vorlagen, wurden passende Alternativen ausgewählt. Zum Basisjahr 2017 konnten insgesamt 17 verschiedene sozioökonomische Variablen auf Gemeindeebene einbezogen werden. Diese sind in Tabelle 2 aufgelistet.

Tabelle 1: Variablen zur sozioökonomischen Charakterisierung der Gemeinden

| Demographie | Wirtschaft und Arbeitsmarkt |
|--|---|
| V1 Anteil der Siedlungsfläche an der Gesamtfläche | V5 Breitbandverfügbarkeit von 100 Mbit/s |
| V4 Einwohnendendichte | V6 Koeffizient der regionalen Spezialisierung |
| V10 Studierende an Hochschulen je 1.000 EW | V14 Beschäftigtendichte |
| V11 Studierende an Fachhochschulen | V15 Wohnort gleich Arbeitsort |
| V17 Baugenehmigungen (Wohnungen) je 1.000 EW | V16 Einpendelnde je 1.000 EW |
| Nahversorgung und Erreichbarkeit | Private und öffentliche Haushalte |
| V2 Anteil der Verkehrsfläche an der Gesamtfläche | V12 Steuereinnahmekraft je 1.000 EW |
| V3 Anteil der Freizeitfläche an der Gesamtfläche | |
| V7 PKW Fahrtzeit zu internationalen Verkehrsflughäfen (in Minuten) | |
| V8 PKW Fahrtzeit zum IC/EC/ICE Halt (in Minuten) | |
| V9 PKW Fahrtzeit zur Bundesautobahnanbindung (in Minuten) | |
| V13 Krankenhausbetten je 1.000 EW | |

Quellen: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020).

Während die Variablen V1, V4, V10, V11 und V17 in die Kategorie Demographie einzuordnen sind, zählen die Variablen V5, V6, V14, V15 und V16 zu Wirtschaft und Arbeitsmarkt. V6 ist der Gini-Koeffizient der regionalen Spezialisierung. Berechnet wurde er für die Unternehmen nach WZ auf Gemeindeebene. Zur Berechnung wurde sich am Vorgehen von Farhauer und Kröll (2009, S. 8-9) orientiert. Der Koeffizient stellt die Verteilung der WZ dar, indem er einen Wert zwischen 0 und 1 einnimmt. Null bedeutet hier die völlige Gleichverteilung und eins die höchste Konzentration. Anhand des Koeffizienten lässt sich entsprechend feststellen, inwieweit eine Gemeinde spezialisiert oder diversifiziert ist (Farhauer & Kröll 2009, S. 8-9). Die benötigten Daten waren die

Beschäftigten nach WZ auf Gemeindeebene 2017 (Statistik der Bundesagentur für Arbeit 2017). Die Nahversorgung und Erreichbarkeit spiegeln die Variablen V2, V3, V7, V8, V9, V13 wider, während die privaten und öffentlichen Haushalte über V12 dargestellt werden.

8.2.2 Hauptkomponentenanalyse

Die Faktorenanalyse kann zum einen zur Reduktion der Variablenanzahl beitragen (Backhaus et al. 2011, S. 414). Korrelieren diese untereinander ermöglicht die Faktorenanalyse die Reduktion auf wenige Faktoren. Zum anderen kann sie dazu beitragen, Daten zu strukturieren, Anhängigkeiten zu erkennen und auf Ursachen hin zu überprüfen. Die HKA ist einer von vielen Ansätzen der Faktorenanalyse (Backhaus et al. 2011, S. 435; Cleff 2015, S. 221-222). Sie reduziert die untereinander korrelierten Variablen hin zu einer kleinen Gruppe an Variablen, ohne zu viele Informationen zu verlieren. Es werden sog. Hauptkomponenten gebildet, welche eine maximale Varianz der Variableninformation abbilden. Im Kern geht die HKA davon aus, dass sich die verwendeten Variablen sich durch die Linearkombination der entstandenen Faktoren darstellen lassen. Hierbei wird unterstellt, dass die Varianzen der Variablen durch die Varianz des gesamten Faktors, dem sie zugeordnet sind, abbildbar sind. Die Zusammenfassung zu Faktoren erfolgt unter der Prämisse, dass dadurch so wenig Informationsverlust wie möglich stattfindet.

Die Problematik bei größeren Variablensets besteht darin, dass diese untereinander korrelieren können (Wieland & Fuchs 2018, S. 159-160), insbesondere, wenn mehrere Variablen beispielsweise kausal auf denselben Ursprung zurückzuführen sind und oder zusammenhängen. Zu untersuchen ist dies in einer Korrelationsmatrix. Liegen hier hohe positive oder negative Korrelationen vor bietet sich eine Variablenreduktion an. Empfohlen ist daher eine HKA, welche vorgelagert vor der Raumtypisierung diese Verzerrungen verhindern kann. Ergebnis der HKA sind dann stochastisch unabhängige neue Variablen, sog. *Hauptkomponenten*, im Folgenden dieser Arbeit *Faktoren* genannt (Schätzl 2000, S. 96).

Die HKA in dieser Arbeit wurde in SPSS durchgeführt. Es wurden zunächst verschiedene Kriterien berechnet, welche als Voraussetzung für eine HKA auszuwerten sind. Dazu wurde zunächst eine Korrelationsmatrix der Variablen erstellt, um festzustellen, ob Variablen mit Werten über 0,9 vorliegen (Cleff 2015, S. 219; Backhaus et al. 2011, S. 339). Diese sollten aufgrund von Multikollinearität ausgeschlossen werden. Zudem wurde das Kaiser-Meyer-Olkin-Kriterium berechnet. Dieses gibt Auskunft darüber, ob eine HKA anhand der vorliegenden Daten überhaupt möglich ist. Das Kriterium liegt zwischen null und eins und je höher es ausfällt, desto eher eignet sich die Datenstruktur für eine HKA. In der Literatur wird der Schwellwert unterschiedlich

Regionstypisierung

eingeorndet. Ein Minimum von 0,5 sollte das Kriterium erreichen um als gut eingestuft zu werden (Cleff 2015, S. 220). Abschließend wurde der Bartlett-Test auf Sphärizität durchgeführt, um zu prüfen, ob eine Beziehung zwischen den Variablen besteht. Wenn diese nicht vorliegen würde, würde eine Zusammenfassung zu Faktoren nicht möglich sein.

Im nächsten Schritt wurde die erklärte Gesamtvarianz der Analyse ausgewertet. Die SPSS-Ausgabe bewertet hier, in wie viele Faktoren die Variablen zusammengefasst werden. Die Zusammenfassung zu Faktoren erfolgt im Allgemeinen unter der Prämisse, dass so wenig Informationsverlust wie möglich stattfindet (Cleff 2015, S. 222). Die vorliegende Arbeit orientiert sich am sog. Kaiser-Guttman-Kriterium, um die Anzahl der Faktoren festzulegen (Guttman, 1954; Kaiser 1960). Dazu werden nur Eigenwerte betrachtet, welche größer als eins sind. Eigenwerte kleiner als eins bedeuten, dass der Varianzerklärungsanteil des entsprechenden Faktors kleiner als der einer einzelnen Variable ist (Cleff 2015, S. 224).

Im folgenden Schritt wurde die rotierte Komponentenmatrix betrachtet. Dort werden die Ladungen der einzelnen Variablen auf die Faktoren (Komponenten) abgebildet (Cleff 2015, S. 225-226). Die Rotation erleichtert die Interpretation der Matrix, da sie die Ladungen durch die Rotation des Koordinatensystems intensiviert (in beide Richtungen). Die hier verwendete Rotation nennt sich *Varimax Rotation*. Es handelt sich um eine rechtwinklige (orthogonale) Rotation. Cleff (2015) beschreibt den Vorteil dieser speziellen Rotation dahingehend, dass dabei die statistische Unabhängigkeit der Faktoren beibehalten wird. Die Faktorladungen bilden die Zuordnung der Variablen zu den entstandenen Faktoren ab. Dies geschieht nach Höhe der Faktorladungen. So wird die Variable dem Faktor zugeteilt, auf welchen sie am stärksten lädt.

Die Ergebnisse der HKA sind sechs Faktoren mit einer erklärten Gesamtvarianz von 68,44 Prozent. Diese werden genauer in der Ergebnispräsentation in Kapitel 11 erläutert, sind an dieser Stelle jedoch bereits zu nennen, um das methodische Vorgehen in der nachfolgenden Clusteranalyse besser zu verstehen. In Tabelle 3 sind die sechs sozioökonomischen Faktoren in der linken Spalte aufgeführt und die Variablen, welche diese beinhalten, in der rechten Spalte notiert.

Regionstypisierung

Tabelle 2: Faktoren Regionalstruktur

| Faktoren | Variablen |
|---------------------------------------|---|
| F01: Siedlungs- und Branchenstruktur | V1 Anteil der Siedlungsfläche an der Gesamtfläche; V2 Anteil der Verkehrsfläche an der Gesamtfläche; V3 Anteil der Freizeitfläche an der Gesamtfläche; V4 Einwohnerdichte; V5 Breitbandverfügbarkeit von 100 Mbit/s; V6 Koeffizient der regionalen Spezialisierung |
| F02: Mobilität und Erreichbarkeit | V7 PKW Fahrtzeit zu internationalen Verkehrsflughäfen (in Minuten); V8 PKW Fahrtzeit zum IC/EC/ICE Halt (in Minuten); V9 PKW Fahrtzeit zur Bundesautobahnanbindung (in Minuten) |
| F03: Lokale Beschäftigung | V14 Beschäftigtendichte; V15 Wohnort gleich Arbeitsort |
| F04: Hochschulbildung | V10 Studierende an Hochschulen je 1.000 EW; V11 Studierende an Fachhochschulen |
| F05: Lokale Arbeitsplatzattraktivität | V12 Steuereinnahmekraft je 1000 EW; V16 Einpendelnde je 1.000 EW |
| F06: Soziale Infrastruktur | V13 Krankenhausbetten je 1000 EW; V17 Baugenehmigungen (Wohnungen) je 1000 EW |

Quelle: Eigene Darstellung.

8.2.3 Clusteranalyse

Anhand der durch die HKA identifizierten Faktoren erfolgte im nächsten Schritt eine Clusteranalyse zur Identifizierung der Regionstypen. Hierfür wurde die MBC angewandt (McNicholas 2016, S. 335). Die Methode, auch *Gaussian Mixture Model (GMM) Clustering* genannt, vergleicht 14 statistische Modelle auf Basis der Gaußschen Wahrscheinlichkeitsverteilung der Variablendatenpunkte (McNicholas 2016, S. 335-338). Die 14 Modelle werden kalkuliert und die Daten mit den Kovarianzen zu den entstandenen Clustern verglichen. Im Anschluss wird das Modell zur Clusteranalyse ausgewählt, welches die Verteilung am besten repräsentiert. In der MBC wird durch die GMM eine Wahrscheinlichkeit für die Einteilung in bestimmte Cluster berechnet so eignet sich das Modell zur Differenzierung von räumlichen Datenstrukturen (He et al. 2010, S. 2). Gemessen und eingeordnet wird dies über das Bayesian Information Criterion (BIC) (Schwarz 1978). Die 14 Modelle werden in einer Kovarianz-Matrix verglichen. Sie unterscheiden sich nach Volumen, Form und Ausrichtung der Cluster (McNicholas 2016, S. 338). Das Modell mit dem geringsten BIC repräsentiert die Wahrscheinlichkeitsverteilung der Daten und Clusterverteilung am effektivsten (McNicholas 2016, S. 335). Ein weiterer Vorteil der Methode ist, dass sie die optimale Clusteranzahl für die Verteilung der Datenpunkte der Variablen berechnet. Anhand dieser Methode können die Gemeinden auf Basis der Faktoren in Regionstypen unterschiedlicher sozioökonomischer Charakteristika zusammengefasst werden. Die Methodik

Regionstypisierung

bietet die Identifizierung der bestmöglichen Einteilung der Raumstruktur für die gegebenen Daten auf Gemeindeebene. Das MBC für die Regionstypisierung in dieser Arbeit wurde in *R* durchgeführt. Mit der Programmiersprache konnte das vorgefertigte Paket *mclust* zur Anwendung der Methode verwendet werden (Scrucca et al. 2016). In der vorliegenden Arbeit wurde eine Clusteranzahl von neun Clustern als optimale Verteilung berechnet.

9 Räumliche Wirkungszusammenhänge

In diesem Kapitel wird die Methodik des Untersuchungsschritts III vorgestellt. Dazu erfolgt zunächst die Vorstellung der Datenbasis bzw. der Untersuchungsvariablen. Dann folgen die Regression mit Zählvariablen, die multiple Regression bevor die HLM und die räumliche Regression das Kapitel schließen.

9.1 Datenbasis und Untersuchungsvariablen

Die Datenbasis dieser Arbeit besteht aus Primär- und Sekundärdaten. Im Folgenden werden die für dieses Kapitel relevanten Variablen vorgestellt. Zur Analyse im Innovationskontext wurde die Variable *Innovationsoutput auf Gemeindeebene* als abhängige Variable ausgewählt. Dargestellt wird dieser in den Patentanmeldungen je 1.000 Einwohner:innen (EW) (im Folgenden Patente genannt). Die Daten stammen von Patentsview.org (2020) und beinhalten die verfügbaren Patente für das Jahr 2017, welche über die zugehörigen Inventor:innen den Gemeinden zugewiesen werden. Für Patente, welche in verschiedenen Sektionen vorkommen, jedoch dieselbe Patent-ID aufweisen, wurde der Anteil der Sektionen am Patent insgesamt (im Datensatz Variable *sum*) berechnet, sodass diese im späteren Verlauf nicht mehrfach gezählt werden. Wenn Patente an unterschiedlichen Orten vorkommen, wurde ebenfalls ein Anteil berechnet. Dieser wird mit dem zuvor berechneten Anteil verrechnet und unter demselben Namen im Datensatz hinterlegt (im Datensatz Variable *sum*). Die Patentzahlen wurden auf die EW der Gemeinde skaliert.

Um den regionalen Strukturraum zu typisieren, wurden in der HKA sechs Faktoren als unabhängige Variablen extrahiert. Die konkrete Ergebniserläuterung ist in Kapitel 11.2 formuliert. Neben den sechs Faktoren gilt außerdem die *Digitalisierung* als weitere unabhängige Variable mit einzubeziehen. Orientiert an den in Kapitel 2.1 beschriebenen Kompensationsstrategien peripherer Regionen wird angenommen, dass eine gesteigerte digitale Kommunikation auf Unternehmensebene für eine allgemein höhere Digitalisierung der Region spricht (Eder & Trippel 2019, S. 1516). Denn periphere Unternehmen streben nach einem konstanten Zufluss von externem Wissen, welches sie beispielsweise in langfristigen sowie digitalen Netzwerken finden (Eder & Trippel 2019, S. 1516; Grabher & Ibert 2014, S. 105-106; Bathelt & Schludt 2010, S. 1958). Um die Digitalisierung der Unternehmen auf Gemeindeebene zu analysieren, wurde ebenfalls auf Sekundärdaten zurückgegriffen. Die Daten der Digitalisierung stammen aus der Arbeit von Kriesch (2023). Abgebildet wird dieser durch einen Webseiten-Ratio,

berechnet aus der Zahl der Unternehmenswebseiten je Gemeinde, anteilig an allen Unternehmen der Gemeinde. Der Ratio liegt zwischen 0 und 1.

Als weitere Variable wird in einigen Modellen der *Ländlichkeitsindex* des Thünen-Instituts mit einbezogen. Der Index wurde anhand einer HKA aus fünf Faktoren gebildet (Küpper 2016, S. 5). Dazu zählt die Siedlungsdichte, der Anteil land- und forstwirtschaftlicher Flächen an der Gesamtfläche, der Anteil der Ein- und Zweifamilienhäuser an allen Wohngebäuden, das regionale Bevölkerungspotenzial sowie die Erreichbarkeit großer Zentren. Der Index liegt auf Kreisebene vor. Die Ländlichkeit auf Gemeindeebene zu berechnen konnte im Rahmen dieser Arbeit aufgrund der begrenzten Datenverfügbarkeit nicht abgebildet werden. Entsprechend wurden der Ländlichkeitsindex auf Gemeindeebene disaggregiert. Anhand der Indexwerte lässt sich die Interpretation einer Dummy-Variable zur Ländlichkeit vermeiden, da Regionen selten in entweder urban oder ländlich eingeteilt werden können. Es gibt stattdessen viele Nuancen, welche durch die Differenzierung des Indexes abgebildet werden. Der Index nimmt eine Spannweite von -1,56 bis 1,12 ein (Küpper 2016, S. 5). Je höher (positiver) der Wert, desto ländlicher ist ein Landkreis. Negative Werte stellen urbane Regionen dar. Werte, die um Null liegen stellen den deutschen Durchschnitt bezüglich der Ländlichkeit aller Kreise dar. Die *HC-Anzahl* dient in der Regression mit Zählvariablen als abhängige Variable. Zur Analyse der regionalen Wechselwirkungen werden die *HCs je 1.000 EW* als unabhängige Variable mit in die Modelle aufgenommen.

9.2 Regression mit Zählvariablen

Eder und Tripl (2019, S. 1517) beschreiben, dass der Charakter ländlicher Räume ausschlaggebend für die Innovationsleistung einer Region sein kann. Um die Wirkungen der sozioökonomischen Struktur auf die Anwesenheit von HCs zu untersuchen und festzustellen, inwieweit diese überhaupt einen Einfluss auf die Ansiedlung der Unternehmenskategorie hat, wurde in der vorliegenden Arbeit eine Regressionsrechnung durchgeführt. In diesem methodischen Schritt der Identifizierung struktureller Muster (Forschungsfrage 2.3) galt es, die Zusammenhänge der HC-Anzahl mit den sozioökonomischen Faktoren aus der Regionstypisierung zu testen. Ergänzt wurde das Modell um die Digitalisierung (Webseiten-Ratio, siehe Kriesch 2023, S. 85) und die Ländlichkeit (Küpper 2016) als weitere Prädiktoren.

Hier ein klassisches lineares Regressionsmodell anzuwenden, bringt einige Herausforderungen mit sich (Tutz 2010, S. 887). Um Zählraten wie die HCs-Anzahl in den Gemeinden zu analysieren, sind generalisierte Regressionsmodelle zu verwenden. Dies liegt unter anderem daran, dass die

abhängige Variable nicht normalverteilt ist, da sie nur ganzzahlige Werte annehmen kann (Tutz 2010, S. 888). Auch die Dimension der Zahlen ist für die Methodenwahl relevant. Wären die Werte der Zählvariable entsprechend größer als 30, könnte eine Normalverteilung vorliegen. Jedoch sind Werte für die HCs-Anzahl niedriger als dieser Schwellwert. Der Mittelwert aller betrachteten Gemeinden liegt bei 0,325, die Standardabweichung bei 1,345. Bei der Entscheidungsfindung für ein geeignetes Modell kommt hinzu, dass die Zählwerte nur positive Werte annehmen können. Dies wird in einer linearen Regression nicht beachtet.

In der vorliegenden Arbeit wurde eine Regression mit Zählvariablen durchgeführt (Tutz 2010, S. 887-888). Als passendes Analysemodell wird je nach Erfüllung der Voraussetzungen der Werte entweder die Poisson-Verteilung oder die negative Binomialverteilung verwendet. Diese Methoden können beide einen weiteren Hinweis darauf geben, wie die Anwesenheit von HCs auf Gemeindeebene gesteuert werden kann und somit aus welchen Gründen die Verteilung nicht zufällig ist. Das Regressionsmodell wurde zunächst für den gesamten Untersuchungsraum durchgeführt. Dieser umfasst 10.534 deutsche Gemeinden, für die alle Variablenwerte zur Verfügung stehen. Im nächsten Schritt erfolgte die Analyse für jeden der identifizierten Regionstypen. Zunächst galt es, festzustellen, ob je nach Datensatz die Voraussetzungen, für die Poisson- oder die negativ binomiale Regression (NBR) gegeben sind. Beide Regressionsanalysen konnten in SPSS durchgeführt werden.

Die erste Voraussetzung der Analyse ist das die abhängige Variable aus Zählwerten besteht (Tutz 2010, S. 887-888). Dies ist für die HC-Anzahl zu bestätigen. Die zweite Annahme ist, dass die unabhängigen Variablen kontinuierliches und ordinales Skalenniveau besitzen oder nominal und dichotom sind. Weiter muss Autokorrelation ausgeschlossen werden (Allen 1997, S.). Ob die Residuen unabhängig voneinander sind, war durch einen Durbin-Watson-Test zu prüfen. Die finale Voraussetzung ist die Poisson-Verteilung (Tutz 2010, S. 888). Sind der Mittelwert und die Varianz des Modells identisch, liegt eine solche vor. Es handelt sich um eine sog. Überdispersion, wenn eine Streuung vorliegt, welche höher ist als vom Modell erwartet. Hierbei kann zur Schätzung auf die NBR ausgewichen werden. Ist die Streuung geringer, handelt es sich um die eher seltene sog. Unterdispersion (Tutz 2010, S. 888; 902). Hier sind die Standardfehler kleiner als die des Poissonmodells und die Signifikanzen fallen stärker aus. Jedoch bleibt es bei der Bewertung der Einflussgrößen. Die NBR kann nur Überdispersion modellieren (Tutz 2010, S. 903). Es wurde zunächst für den gesamten Datensatz ($n=10.534$) ein Regressionsmodell aufgestellt. Außerdem folgten Schätzmodelle für jeden einzelnen identifizierten Regionstyp.

9.3 Multiple lineare Regressionsmodelle

Im nächsten methodischen Schritt wird der Einfluss der als hoch innovativ deklarierten HCs auf die Wissensentstehung und Innovation einer Region getestet (Simon 2012, S. 259). Innovation gilt als prozessuale Grundlagen der Weiterentwicklung und Veränderung von Wirtschaft und Gesellschaft (Bathelt et al. 2017, S. 8-9). Die Triebkräfte führen nicht nur zu Wachstum auf unternehmerischer, sondern auch auf geographischer, struktureller Ebene zu Weiterentwicklungen. Durch eine multiple lineare Regression lassen sich diese Kausalitätszusammenhänge testen (Backhaus et al. 2016, S. 79). Die Modellfunktion lautet wie folgt:

$$(1) \hat{y} = b_0 + b_1 x_{HC \text{ je } 1.000 \text{ EW}} + b_2 x_{F01} + b_3 x_{F02} + b_4 x_{F03} + b_5 x_{F04} + b_6 x_{F05} + b_7 x_{F06} \\ + b_8 x_{Digitalisierung} + b_9 x_{Ländlichkeit}$$

Dabei stellt \hat{y} die (geschätzte) abhängige Variable (Innovationsoutput) dar, während b_0 die Regressionskonstante abbildet. b_i sind die Regressionskoeffizienten des entsprechenden Prädiktors und x_i der (tatsächliche) Messwert auf dem entsprechenden Prädiktor. Neben der Digitalisierung und der Ländlichkeit bilden die Faktoren, welche aus der HKA stammen, die unabhängigen Variablen ab.

Zur Durchführung einer multiplen linearen Regression müssen die Daten einige Voraussetzungen erfüllen (Backhaus et al. 2016, S. 97-98). Dazu gehört ein linearer Zusammenhang zwischen den Variablen, metrisches Skalenniveau, keine Multikollinearität, Normalverteilung der Residuen, Homoskedastizität und keine Autokorrelation. Ausreißer sind zu eliminieren und fehlende Werte zu definieren. Je nachdem, inwieweit die Daten die Voraussetzungen erfüllen, müssen einige der Variablen transformiert werden.

Die Durchführung der Regressionsanalyse fand durch die *lm()* Funktion in der Statistiksoftware *R* statt. Die Ergebnisse der Funktionsgleichung beinhalten die Modellgüte durch das zu interpretierende korrigierte Bestimmtheitsmaß (Backhaus et al. 2016, S. 85). Das oben aufgeführte Modell wurde zunächst für Gesamtdeutschland (n=10.534) und im folgenden Schritt für jeden der durch die Clusteranalyse identifizierten Regionstypen berechnet.

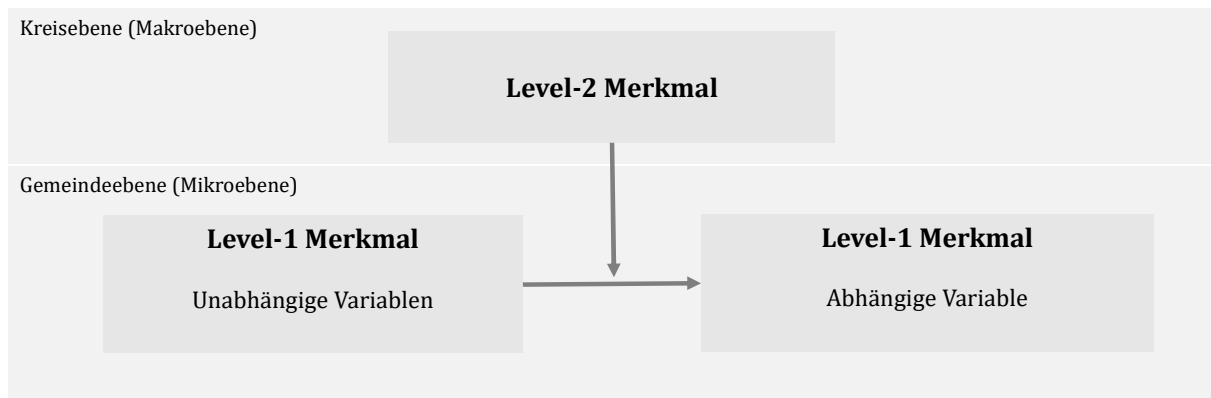
9.4 Hierarchisch lineare Mehrebenenanalyse

Die Innovationstätigkeit gilt als wesentlicher Faktor für den wirtschaftlichen Erfolg einer Region. Empirischen Untersuchungen zufolge werden der technische Fortschritt und die Innovationskraft einer Region durch die geographische Komponente der Wissensgenerierung beeinflusst (Audretsch & Feldmann 2004, S. 2715). Betrachtet man diese Wechselwirkungen auf unterschiedlichen Ebenen, nennt man sie ebenenübergreifende Moderationen. Diese nehmen an, dass die Innovationsprozesse auf Gemeindeebene nicht unabhängig voneinander, sondern eingebettet in ein größeres Umfeld sind (Hundt & Holtermann 2020, S. 8). Die HLM ermöglicht es den vermuteten Einfluss von der Anwesenheit der HCs auf Kreisebene auf den Effekt des Innovationsoutputs einer Gemeinde zu messen.

Im Folgenden wird die Methodik der HLM vorgestellt. Dazu erfolgt nach der Einführung der Ablauf der Modellschätzungen mit den in dieser Arbeit durchgeführten Modellen und den zu beantwortenden Hypothesen. Dieses flexible Forschungsdesign erlaubt die optimale Untersuchung der (heterogenen) regionalen Ausstrahleffekte der HCs und integriert verschiedene regionale Abgrenzungsmöglichkeiten (z. B. Landkreise, Gemeinden), um eine ex-ante Beeinflussung der Ergebnisse durch den regionalen Zuschnitt auszuschließen.

Eine HLM bietet die Möglichkeit, individuell verfügbare Informationen auszuwerten und deren Variationen in und zwischen Gruppen, denen die Individuen angehören, zu analysieren. Passende Beispiele sind hier Schüler:innen und Schulklassen, Kinder und Familien oder, wie in dieser Arbeit untersucht, Gemeinden und Kreise. Durch die HLM lässt sich prüfen, inwieweit individuelle Merkmale (hier: Gemeindemerkmale; Level-1 Merkmal) mit den Makromerkmalen (hier: Kreismerkmale; Level-2 Merkmal) interagieren und auf unterschiedlichen Ebenen gemeinsame Auswirkungen auf die abhängige Variable haben (Guo 2005, S. 639). Durch die HLM lässt sich feststellen, welchen Effekt das Level-2 Merkmal auf den Zusammenhang zwischen den Level-1 Merkmalen hat. Abbildung 6 verdeutlicht diese Fragestellung, die zunächst für Gesamtdeutschland und anschließend für jeden der in der Clusteranalyse identifizierten Regionstypen angewandt wurde.

Abbildung 6: Ebenenübergreifende Interaktionen in der HLM



Quelle: Eigene Darstellung.

Vor der Umsetzung der HLM müssen die Daten, wie oben beschrieben, einige Voraussetzungen erfüllen (Urban 2022, S. 5). Dazu zählt zunächst, dass die Level-1 Werte verschiedenen Clustern zuzuordnen sind. Sie müssen abhängig voneinander sein, da sie von den Clustern beeinflusst werden. Urban (2022) beschreibt dies anhand eines Beispiels des Leistungsniveaus eines Schulkinds. So kann es sein, dass wenn dieses Kind einer Klasse mit einem bestimmten Leistungsniveau zugeordnet ist, dieses das individuelle Niveau auf Schüler:innenebene beeinflusst. Entsprechend sind die Leistungsniveaus der Schüler:innen abhängig voneinander. Als zweites Kriterium wird beschrieben, dass auch die Cluster Level-2-Werte vorzuweisen haben. So liegen zwei geschachtelte Analyseebenen vor. Zum Beispiel Schüler:innen und Klassen, oder in dieser Analyse Gemeinden und Kreise. Das dritte Kriterium ist, dass der Anteil der sog. *Between*-Varianz, also die Varianz zwischen den betrachteten Kreisen, mindestens 10 Prozent von der Gesamtvarianz der abhängigen Variable zählen muss. Zusammengefasst bedeutet dies, dass HLM bei entsprechend hohem *Interklassenkoeffizient* (ICC) untersuchen können, wie individuelle Level-1-Variablen mit Level-2-Variablen interagieren (Guo 2005, S. 639). Dadurch lassen sich gemeinsame Auswirkungen auf die abhängige Variable (Individualmerkmal, Level-1) testen.

Im Rahmen der Anwendung einer HLM ist es in manchen Fällen sinnvoll, einige der Variablen zu zentrieren. Gründe dafür können die Interpretation des Intercepts, die Unterscheidung des Effekts einer Variable auf verschiedenen Ebenen oder die Interpretierbarkeit bei Cross-Level-Interaktionen sein (Enders & Tofighi 2007, S. 121). Fokussiert sich die Fragestellung auf Cross-Level-Interaktionen, also zwischen den Mikro- und den Makrovariablen, empfehlen die Autor:innen die Zentrierung via *Center Within Cluster* (CWC) (Enders & Tofighi 2007, S. 132; Urban 2022, S. 29). Dazu wird sich am Mittelwert der jeweiligen Gruppe (in dem hier vorliegenden Fall des Kreises) orientiert. Genauer bedeutet das, dass von der Prädiktorvariable der Gemeinde,

der Mittelwert des zugehörigen Kreises dieser Variable subtrahiert wird. Für die Zentrierung wurde das Paket *misty* in *R* angewandt.

Die Voraussetzungen für die Durchführung der HLM sind Normalverteilung der Daten, Homoskedastizität, Linearität, Abwesenheit von Multikollinearität und Identifikation von Ausreißern. Alle Voraussetzungstests wurden für die Daten auf Level-1 und Level-2 durchgeführt (Hox et al. 2017). Folgende R-Pakete wurden dazu verwendet: *lme4* (zur Schätzung der HLM), *lmerTest* (für die p-Werte der HLM-Schätzung), *HLMdiag* (für die Residuen der HLM-Schätzung), *ggplot2* (für graphische Darstellungen), *dplyr* (zur Datenaufbereitung), *lmtest* (für den Linearitätstest) und *jtools* (für den Test auf Multikollinearität) (Bates et al. 2015).

Weisen die Daten eine hierarchische Struktur auf, dann bietet sich die Durchführung einer HLM an (Urban 2022, S. 35 – 36). Dazu gilt es vier Modelle zunächst für Gesamtdeutschland und dann für die Regionstypen zu schätzen. Im Folgenden werden die für diese HLM ausgewählten vier Modelle vorgestellt. Die Zusammensetzung der Modellformeln wird erläutert, die Durchführung in *R* wird beschrieben sowie die zu beantwortenden Fragestellungen werden in Form von vier Hypothesen vorgestellt. Im Folgenden wird zur besseren Lesbarkeit die Level-1-Ebene Gemeindeebene genannt und die Level-2-Ebene Kreisebene.

9.4.1 Modell 1: Random-Intercept-Only-Modell

Modell 1 (M1) ist ein *Random-Intercept-Only-Modell*, auch *Nullmodell* genannt (Urban 2022, S. 49-50). Die Ergebnisse des Nullmodells zeigen auf, inwieweit eine HLM überhaupt mit den vorliegenden Daten durchzuführen ist. In dem *Nullmodell* selbst stehen keine unabhängigen Variablen, sondern es werden die durchschnittlichen Y-Werte geschätzt. Die Gesamtvarianz wird aufgeteilt - zum einen in die *Within*-Varianz auf Gemeindeebene und zum anderen in die *Between*-Varianz auf Kreisebene. Ziel ist es, durch diese Varianzen festzustellen, wie hoch der ICC ist und wie groß der Anteil der Kreisebenenvarianz an der Gesamtvarianz ist. Die zu testende Hypothese ist wie folgt ausformuliert:

H1: Der Innovationsoutput unterscheidet sich signifikant zwischen den Gemeinden.

Die entsprechenden Formeln setzen sich wie folgt zusammen: Y_{ij} stellt die abhängige Variable, den Innovationsoutput der Gemeinden, und β_{01} den Intercept (Achsenabschnitt) dar. Dies ist für jede Gemeinde der Mittelwert aller Gemeinden des Kreises. Die Gemeindeebenen-Residuen werden beschrieben durch die jeweilige Differenz vom Kreismittelwert (r_{ij}). Der einbezogene Fixe Effekt ist der durchschnittliche Innovationsoutput aller Gemeinden und Kreise (y_{00}). Die

Residualvariable auf der Kreisebene ist die Abweichung des Kreismittelwerts vom Gesamtmittelwert (u_{0j}).

$$\text{Gemeindeebene (Level-1-Modell): } Y_{ij} = \beta_{0j} + r_{ij}$$

$$\text{Kreisebene (Level-2-Modell): } \beta_{0j} = \gamma_{00} + u_{0j}$$

$$\text{Gesamtmodell: } Y_{ij} = \gamma_{00} + u_{0j} + r_{ij}$$

$i = 1, 2, \dots, n$ Gemeinde-Einheiten, $j = 1, 2, \dots, m$ Kreis-Einheiten

Durch das Modell kann festgestellt werden, wie hoch der ICC ist und ob der Anteil der Kreisebenen-Varianz an der Gesamtvarianz ausreicht, um eine HLM anzuwenden. Der ICC gibt an, wie groß der Anteil der Kreisebene an der Gesamtvarianz ist. Er wird in R durch die Funktion `performance::icc()` aus dem Paket `performance` berechnet. Der ICC gibt den Anteil der Kreisebenenvarianz an der Gesamtvarianz der abhängigen Variable an (u_{0j} = Kreisebenenvarianz, r_{ij} = Gemeindeebenenvarianz) (Urban 2022, S. 50):

$$(2) \rho = \frac{\text{var}(u_{0j})}{\text{var}(u_{0j}) + \text{var}(r_{ij})}$$

Nach der Schätzung des Modells erfolgt ein Signifikanztest für den Random Effekt mittels eines Likelihood-Ratio-Tests. Ziel ist ein Modellvergleich mit einem Modell, welches keinen Random Effekt beinhaltet. Dieser wurde anhand dem R-Paket `nlme` durchgeführt. Die Modellgüte beider Modelle wurde dann miteinander verglichen. Ist der p-Wert des Tests signifikant, ist ein Random-Effekt-Modell zu verwenden, da es eine signifikant bessere Anpassung an die Daten bietet.

9.4.2 Modell 2: Random-Intercept-Modell

Modell 2 wird *Fixed-Slope* oder auch *Random-Intercept-Modell* (M2) genannt und enthält mehrere unabhängige Variablen auf der Gemeinde- (x) sowie Kreisebene (z) (Urban 2022, S. 55-56). Mit einbezogen wurden in dieser Arbeit acht feste (Fixe) Regressionsgewichte, welche für alle Kreise gleich sind. Dazu gehören auf Gemeindeebene die sechs sozioökonomischen Faktoren F01 bis F06, die Digitalisierung und die Ländlichkeit als Kreisebenenvariable. Durch die Modellschätzung wird ermittelt, wie viel der Gemeindevarianz sowie welchen Anteil der Gesamtvarianz durch die unabhängigen Variablen erklärt wird. Anhand der folgenden Hypothesen lässt sich die Fragestellung inhaltlich nachvollziehen:

Räumliche Wirkungszusammenhänge

H2.1: Je stärker die sozioökonomische Struktur (F01-F06) und die Digitalisierung der Gemeinde, desto höher ist der Innovationsoutput.

Für den Effekt der Kreisebenenvariable (Ländlichkeit) auf die abhängige Variable (Innovationsoutput) der Gemeindeebene gilt folgende Annahme:

H2.2: Unter Kontrolle der Gemeindeebenenvariablen (F01 – F06; Digitalisierung) gilt, dass je ländlicher ein Kreis ist, desto niedriger ist der Innovationsoutput der dazugehörigen Gemeinden.

Die dazugehörige Formel lautet wie folgt:

$$(3) Y_{ij} = y_{00} + y_{10}x_{1ij} + \dots + y_{70}x_{7ij} + y_{01}z_{1j} + u_{0j} + r_{ij}$$

Anhand dieses Modells lässt sich feststellen, welchen Anteil der Gesamtvarianz (beider Ebenen) durch die Ländlichkeit (Kreisebenenvariable) erklärt werden kann. Außerdem ist festzustellen, inwieweit sich das Modell durch die Hinzunahme der unabhängigen Variablen verbessert. Den Erklärungsgehalt bieten Fixed Slopes, die für alle Kreise gleich sind. In dem vorliegenden Modell existierten acht Fixed Slopes. Dazu gehören die sozioökonomischen Faktoren (F01 – F06) und die Digitalisierung als Effekte auf der Gemeindeebene sowie die Ländlichkeit als Effekt auf der Kreisebene.

Die Schätzung des Modells findet mit dem Paket *lme4* und der *lmer*-Funktion in *R* statt. Die Ausgabe des Modells beinhaltet die Random Effekte, welche im Anschluss mit dem Nullmodell verglichen werden. Die Fixen Effekte geben eine Aussage darüber, welchen Effekt die einzelnen Variablen über alle Kreise hinweg haben und ob diese Effekte signifikant sind.

Außerdem ist der ICC zu berechnen, um festzustellen wie groß der Anteil an der Gesamtvarianz ist, der von höheren Ebenen (hier von den Kreisen) ausgeht. Er gibt an wie viel unerklärte Varianz übrig bleibt, wenn man diese für bestimmte Variablen bereits kontrolliert hat (d.h. Differenz aus ICC und Residual ICC = Erklärungsanteil der Gemeindeebenenvariablen).

9.4.3 Modell 3: Random-Slope-Modell

Bei dem dritten durchgeführten Modell (M3) handelt es sich um ein *Random-Slope-Modell*. Im Kontext dieser Arbeit kann anhand der Modellergebnisse festgestellt werden, inwieweit sich die Effekte zwischen den unabhängigen und abhängigen Variablen auf Gemeinde- oder Kreisebene überhaupt unterscheiden. Dieser Unterschied ist Voraussetzung, um die HLM weiter durchführen zu können. Gibt es keinen Unterschied zwischen den Effekten auf den Ebenen ist Modell 4 nicht anwendbar.

In M3 werden die Effekte der Prädiktoren als variabel betrachtet (Urban 2022, S. 36). Je nach Kreis können die sogenannten Random Slopes (zufälligen Steigungen) also unterschiedlich sein. Die erklärende Variable kann bei dem Modell in jedem Kreis anderen Effekten ausgesetzt sein. Das Modell untersucht, inwieweit der Einfluss von F01-F06 und der Digitalisierung auf die Innovationskraft sich zwischen den Kreisen unterscheidet. Die dazu formulierte Hypothese lautet wie folgt:

H3: Die Effekte der sozioökonomischen Struktur und der Digitalisierung der Gemeinden unterscheiden sich zwischen den Kreisen.

Die zu dem in dieser Arbeit berechneten Random-Slope-Modell gehörige Formel setzt sich wie folgt zusammen. $u_{1j}x_{1ij}$ etc. sind die Random Effekte auf Kreisebene. Diese sagen aus, dass das Intercept und die Effekte der Prädiktoren auf die abhängige Variable des Innovationsoutputs schwanken können. Da auf der obersten Modellebene kein Random Effekt geschätzt werden kann ist für den Kreisebenenprädiktor der Ländlichkeit kein Random Effekt möglich.

$$(4) Y_{ij} = \gamma_{00} + \gamma_{10}x_{1ij} + \dots + \gamma_{70}x_{7ij} + u_{0j} + u_{1j}x_{1ij} + \dots + u_{7j}x_{7ij} + r_{ij}$$

Für den Fall, dass einige der Gemeindeebenenvariable eine sehr geringe Varianz des Random Effekts vorweisen, werden diese Variablen aus dem Modell entfernt. Dazu gibt R eine Warnung aus, sobald das Modell nicht konvergiert ist und den Ergebnissen entsprechend nicht zu trauen wäre. Wenn nur noch Variablen mit ausreichend starker Varianz involviert sind, wird das Modell gerechnet. Dieses Vorgehen wiederholt sich für jeden der acht Regionstypen. In der Ausgabe der Berechnung des Modells erfolgt ein Vergleich der Varianzen der Random Slope sowie der Fixed Slope. Fixe Effekte sind im Rahmen der HLM-Effekte, die über alle Kreise hinweg geschätzt werden. Random Effekte hingegen sind solche, die sich zwischen den Kreisen unterscheiden. Sie zeigen das Ausmaß der Schwankungen in den Effekten zwischen den verschiedenen Kreisen an.

Wenn man einen Random Effekt in das Mehrebenenmodell aufnimmt, dann in der Regel zusammen mit dem dazugehörigen Fixen Effekt – umgekehrt ist dies nicht möglich. Man kann also einen Fixen Effekt ohne dazugehörigen Random Effekt im Modell haben. Dies bedeutet, dass dieser Effekt zwischen den Kreisen nicht schwankt, sondern in allen Kreisen ungefähr gleich stark ausfällt.

9.4.4 Modell 4: Cross-Level-Interaktion

Das finale Modell der HLM in dieser Arbeit ist eine *Cross-Level-Interaktion* (M4). Die in diesem Modell untersuchten verstärkenden Effekte von HCs auf die Innovation von Gemeinden, abhängig von deren sozioökonomischer Struktur und Digitalisierung, werden durch Aussagen aus Politik und Wissenschaft gestützt. HCs gelten trotz ihrer geringen Anzahl (ca. 0,04 Prozent aller Unternehmen) als wichtige Triebkraft der deutschen Wirtschaft (Simon 2012; Witt & Carr 2013; Rasche 2003, S. 220). Da die Innovationstätigkeit als ein ausschlaggebender Faktor für die Steigerung der Wirtschaftsleistung einer Region eingeordnet wird, ist die Frage nach den ebenenübergreifenden Effekten der HC-Anwesenheit naheliegend.

Zunächst wird überprüft, ob bei der Schätzung des Modells 3 eine Schwankung des Effekts der Gemeindeebenenvariablen auf den Innovationsoutput zwischen den Kreisen festzustellen ist. Anders ausgedrückt, ob eine substanzielle Varianz für die Random Slope der sozioökonomischen Struktur und Digitalisierung gefunden wird. Ist dies der Fall, wird mit Modell 4 geprüft, ob dieser Effekt auf den Innovationsoutput der Gemeinden teilweise von dem Kreisebenen Prädiktor der HCs-Anzahl je 1.000 EW abhängt. Das könnte die Schwankung dieses Effekts zwischen den Kreisen erklären. Die Annahme der Arbeit lässt sich wie folgt ausdrücken:

H4: Die Anzahl der HCs hat eine verstärkend positive Wirkung auf den Effekt der sozioökonomischen Struktur und der Digitalisierung auf die Ausprägung des Innovationsoutputs der Gemeinden.

$$(5) Y_{ij} = y_{00} + y_{01}z_{1j} + y_{10}x_{1ij} + y_{11}x_{1ij}z_{1j} + \dots + y_{70}x_{7ij} + y_{71}x_{7ij}z_{7j} + u_{0j} \\ + u_{1j}x_{1ij} + \dots + u_{7j}x_{7ij} + r_{ij}$$

Wie schon bei Modell 1 erklärt, stellt y_{00} den einbezogenen Fixen Effekt, den durchschnittlichen Innovationsoutput aller Gemeinden und Kreise, dar. Der Haupteffekt des Prädiktors auf Kreisebene ist $y_{01}z_{1j}$ und auf der Gemeindeebene die sieben Prädiktoren $y_{10}x_{1ij}$ bis $y_{70}x_{7ij}$. Der letzte Abschnitt des Fixen Teils der Formel wird durch den ebenenübergreifenden Effekt

$y_{11}x_{1ij}z_{1j}$ dargestellt. Der zweite Teil der Formel besteht aus dem zufälligen Teil. Dazu gehört zunächst die Residualvariable auf der Kreisebene. Sie ist die Abweichung des Kreismittelwerts vom Gesamtmittelwert (u_{oj}). Danach folgen die in Modell 3 identifizierten Random Effekte $u_{1j}x_{1ij}$ etc. Generell gilt, dass hier nur die Random Effekte aufgenommen werden, welche in Modell 3 eine ausreichend starke Varianz vorweisen. Die Gemeindeebenen-Residuen (r_{ij}) werden beschrieben durch die jeweilige Differenz vom Kreismittelwert und stellen den Random Effekt auf Gemeindeebene dar. Auch Modell 4 der HLM wird in R durchgeführt. Dazu wird das Paket *lmer* verwendet. Die Schätzungsmethode der Parameter ist REML, welche sich für Modellvergleiche, große Stichproben und die Schätzung von Random Effekten eignet (Dedrick et al. 2009, S. 81).

9.5 Räumliche Regressionsanalyse

Die letzte in dieser Arbeit vorzustellende Methodik ist die bereits im Kapitel zur räumlichen Autokorrelation angesprochene räumliche Regressionsanalyse. Durch räumliche Regressionsmodelle lässt sich testen, welchen Effekt räumliche Nähe auf die verwendeten Daten ausübt. Entsprechend ist es möglich, anhand der Analyse festzustellen inwieweit die sozioökonomischen Faktoren (F01 – F06), die Digitalisierung und die Anwesenheit von HCs in einer Gemeinde Spillover-Effekte auf ihre Nachbarregionen mit sich bringt.

Durchgeführt wurde die Analyse für den Gesamttraum Deutschland auf Gemeindeebene unter Einbezug von 10.534 Gemeinden. Die abhängige Variable ist, wie bei der multiplen Regressionsanalyse zuvor, der Innovationsoutput. Die unabhängigen Variablen sind die HCs je 1.000 EW, die sechs sozioökonomischen Faktoren (F01 bis F06) sowie die Digitalisierung. Die Modellschätzungen wurde in R mit den Paketen *sp*, *sf* und *spdep* durchgeführt.

Für die räumliche Komponente wurde der, bereits bei der räumlichen Autokorrelation verwendete, Gemeindegebietsstand von 2016 verwendet. Die geometrischen Daten wurden mit den oben beschriebenen Prädiktoren verbunden. Der erste Schritt der Analyse war eine klassische OLS-Regression. Im nächsten Schritt folgte erneut der Test auf räumliche Autokorrelation - in diesem Fall mit der abhängigen Variable Innovationsoutput. Diese ist zu überprüfen, um die Relevanz einer räumlichen Regressionsanalyse zu bestätigen, sodass die Schätzer und entsprechende Signifikanzen nicht verzerrt werden. Dafür galt es, eine räumliche Gewichtungsmatrix zu berechnen. Nachbarschaften wurden über die sog. *Queen Kontiguitäten* festgestellt (Bivand et al. 2008, S. 267). Hier wird davon ausgegangen, dass alle sich berührenden Polygone Nachbar-Gemeinden sind. Im Anschluss an die Identifizierung der Nachbarschaften wurde eine Gewichtsmatrix mit räumlichen binären Gewichten kalkuliert (R Paket *spdep*). Weiter

wurde diese konvertiert in eine quadratisch räumliche Gewichtungsmatrix. Diese wurde für die Berechnung der Moran's I Teststatistik der Regressions-Residuen aus dem Modell der multiplen Regression benötigt (Bivand et al. 2013, S. 292). Damit wird berücksichtigt, dass der Innovationsoutput ein Residuum ist, welches aus einer Regressionsschätzung stammt. Liegt räumliche Autokorrelation vor, bedeutet dies, dass die Residuen systematisch zusammenhängen. Um eine Regressionsanalyse durchzuführen, galt es anschließend, ein räumliches Regressionsmodell zu verwenden.

Es existieren zwei Optionen, eine räumliche Regressionsanalyse durchzuführen (Eckey et al. 2006, S. 8). Es wird unterschieden zwischen einem Spatial-Lag-Modell (SLM) oder einem Spatial-Error-Modell (SEM). Spatial-Lag beschreibt den Durchschnittswert der benachbarten Regionen und stellt den Effekt von Nachbarregionen dar (Eckey et al. 2007A, S. 26). Beim SLM wird ein Spatial-Lag in der abhängigen Variable modelliert, um die räumliche Autokorrelation mit einzubeziehen (Eckey et al. 2006, S. 8). Dazu wird der Durchschnittswert der Y-Variablen der benachbarten Regionen verwendet. Im SEM wird die räumliche Autokorrelation über den Fehlerterm geschätzt. Dabei werden unberücksichtigte, aber relevante Einflussgrößen insbesondere als Spatial-Lags der unabhängigen Variablen oder die Verwendung von Verwaltungsgebieten statt funktionaler Räume als Begründung für das Spatial-Lag im Fehlerterm genutzt.

Zur Testung welches Modell, das geeignetere für die vorliegenden Daten ist, wurde ein Lagrange-Multiplier-Tests durchgeführt (Eckey et al. 2006, S. 9). Das Modell, welches im Test statistisch signifikant war, wird zur weiteren Analyse empfohlen. Sind das SLM und SER jeweils statistisch signifikant, sind die robusten Schätzungen des Lagrange-Multiplier-Tests auszuwerten (Bivand et al. 2013, S. 305). In dieser Arbeit wird zusätzlich zur Statistik in die Modellentscheidung die Zielsetzung der Fragestellung einbezogen. Das Ziel ist es festzustellen welchen Effekt die unabhängigen Variablen (HCs je 1.000 EW; F01 – F06; Digitalisierung) auf die abhängige Variable (Innovationsoutput der Gemeinde) haben. Entschieden wurde sich für ein SLM, denn hier werden neben dem direkten, lokalen Effekt der unabhängigen Variablen auch in indirekte Spillover-Effekte, anhand der Effekte innerhalb der Nachbarregionen, einbezogen.

III: Ergebnispräsentation und -diskussion

10 Lokalisierung und Deskription der Hidden Champions

In diesem Kapitel erfolgt zunächst die Vorstellung der identifizierten HCs. Dazu wird der Datensatz gemeinsam mit einigen relevanten Kennzahlen vorgestellt. Weiter wird die räumliche Verteilung ausgewertet und kartographisch dargestellt. Zum Abschluss werden einige Fallbeispiele von HCs aufgezeigt.

10.1 Identifizierte Hidden Champions

In diesem Kapitel wird der HCs-Datensatz als Ergebnis der Identifizierung vorgestellt, welcher den folgenden Analysen zugrunde liegt. Durch den webdatenbasierten Ansatz (Kapitel 7) konnten 3.654 HCs identifiziert und mittels der Geocodierung der Daten (6.3) lokalisiert werden. Das sind 44 HCs je 1 Millionen EW. Dabei wurden bei der Überprüfung des Champions-Kriteriums die 136 Champions-Keywords in Summe 12.155-mal auf den Unternehmenswebseiten gefunden. Im Durchschnitt sind dies 3,3 Keywords je Unternehmenswebseite (Standardabweichung 2,5). Für das Hiddenness-Kriterium galt ein maximaler Google-Suche-Trefferwert von ca. 45.000 Suchtreffern. Im Mittel sind das 9.118 Suchtreffer pro HC (Standardabweichung 7.997).

Folgend werden einige Charakteristika des Datensatzes und der identifizierten HCs sowie die räumliche und inhaltliche Verteilung dieser vorgestellt. Sechs der Unternehmen sind als börsennotiert aufgeführt (Bureau van Dijk 2020). Dazu zählt beispielsweise die Klepper Faltfootwerft AG, Marktführer für Faltfootboote seit 1929 aus Hamburg (Klepper Faltfootwerft AG 2023). Ferner sind die Dr. Hönle AG als eine der weltweit führenden Anbieter für industrielle UV-Technologie aus Gilching in Bayern (Dr. Hönle AG 2023) oder die GRAMMER AG, welche seit 1993 Marktführer im Bereich der Fahrzeuginnenausstattung ist (GRAMMER AG 2022), börsennotierte Unternehmen. Weitere sechs der identifizierten HCs waren einmal börsennotiert, sind dies aber nicht mehr. Die anderen 3.642 HCs sind keine börsennotierten Unternehmen.

Einige Kennzahlen zum Vergleich auf Bundesländerebene sind in Tabelle 4 abgebildet. Zur Einordnung der Größenverhältnisse sind die Flächengrößen der Bundesländer und Gemeindeanzahlen aufgeführt. Die Tabelle gibt außerdem einen Überblick über die Verteilung der absoluten und relativen Werte bezogen auf die HCs je Bundesland. Die in dieser Arbeit durchgeführten Analysen erfolgen mit dem Wert der HCs je 1.000 EW auf Gemeindeebene.

Lokalisierung und Deskription der Hidden Champions

Tabelle 3: Hidden Champions-Verteilung nach Bundesländern

| Bundesland | Fläche in km ² | Anzahl Gemeinden | Anzahl HCs insg. | Anteil HCs insg. | Anzahl HCs je Gemeinde | Anzahl HCs je 1.000 EW |
|------------------------|------------------------------|---------------------|---------------------|---------------------|---------------------------|---------------------------|
| Bremen | 419 | 2 | 29 | 0,79% | 14,5 | 0,043 |
| Hamburg | 755 | 1 | 48 | 1,31% | 48 | 0,026 |
| Berlin | 891 | 1 | 51 | 1,40% | 51 | 0,014 |
| Saarland | 2.571 | 52 | 22 | 0,60% | 0,423 | 0,022 |
| Schleswig-Holstein | 15.800 | 1.108 | 123 | 3,37% | 0,111 | 0,043 |
| Thüringen | 16.202 | 821 | 93 | 2,55% | 0,113 | 0,043 |
| Sachsen | 18.450 | 421 | 151 | 4,13% | 0,359 | 0,037 |
| Rheinland-Pfalz | 19.858 | 2.304 | 169 | 4,63% | 0,073 | 0,041 |
| Sachsen-Anhalt | 20.457 | 218 | 78 | 2,13% | 0,358 | 0,035 |
| Hessen | 21.116 | 427 | 255 | 6,98% | 0,597 | 0,041 |
| Mecklenburg-Vorpommern | 23.295 | 750 | 29 | 0,79% | 0,039 | 0,018 |
| Brandenburg | 29.654 | 417 | 55 | 1,51% | 0,132 | 0,022 |
| Nordrhein-Westfalen | 34.112 | 396 | 933 | 25,53% | 2,356 | 0,052 |
| Baden-Württemberg | 35.748 | 1.103 | 737 | 20,17% | 0,668 | 0,067 |
| Niedersachsen | 47.710 | 975 | 290 | 7,94% | 0,297 | 0,036 |
| Bayern | 70.542 | 2.235 | 591 | 16,17% | 0,264 | 0,045 |
| Deutschland insgesamt | 357.581 | 11.231 | 3.654 | 100% | 0,325 | 0,044 |

Quelle: Eigene Darstellung, Datenbasis: Eigene Erhebung; Statistisches Bundesamt (2023).


In Nordrhein-Westfalen (NRW) sind 25,53 Prozent (933 HCs) aller HCs im Bundesgebiet angesiedelt. Das Saarland hat währenddessen mit nur 0,6 Prozent (22 HCs) den niedrigsten Anteil. Bezogen auf HCs je 1.000 EW weist Baden-Württemberg mit 0,067 HC je 1.000 EW den höchsten Wert aller Bundesländer auf. Dann folgt NRW mit einem Wert 0,052 und Bayern mit 0,045. Den viert höchsten Wert bezüglich HCs je 1.000 EW haben Thüringen, Bremen und Schleswig-Holstein (0,043). Mit nur 0,014 HC je 1.000 EW bildet Berlin das Ende der skizzierten Skala. Bei den Werten je Gemeinde sind zunächst die drei Ausreißer Berlin (51 HCs je Gemeinde), Hamburg (48 HCs je Gemeinde) und Bremen (14,5 HCs je Gemeinde) aufgrund ihres Sonderstatus als Stadtstaat auszuklammern. Im Vergleich der restlichen 13 Bundesländer führt erneut Nordrhein-Westfalen deutlich mit 2,356 HCs je Gemeinde während Mecklenburg-Vorpommern mit nur 0,039 HCs je Gemeinde den letzten Platz belegt.

In den Daten der MARKUS Datenbank sind die jeweiligen Gründungsjahre der HCs enthalten. Die Verteilung der HCs-Unternehmensgründungen ist in der nachstehenden Abbildung 7 dargestellt. Vor dem Jahr 1800 wurden vier der 3.654 HCs gegründet. Der älteste HC ist die im Jahr 1647 gegründete MORSA Wachswarenfabrik Sallinger GmbH (MORSA Wachswarenfabrik Sallinger GmbH 2021). Das Unternehmen liegt im schwäbischen Krumbach und produziert Wachse und Kunststoffe für verschiedene Branchen. Die Eisenwerk Hansenclever & Sohn GmbH ist im Jahr 1773 gegründet worden. Seitdem hat sie sich als führend im Bereich der Fertigung hoch

Lokalisierung und Deskription der Hidden Champions

temperaturfester Abgaskomponenten entwickelt (Eisenwerk Hansenclever & Sohn GmbH 2020). Es ist bemerkenswert, dass die jüngsten HCs, beispielsweise die acht Unternehmen, die im Jahr 2020 gegründet wurden, bereits nach der kurzen Zeit als HCs gelten.

Abbildung 7: Verteilung der Unternehmensgründungsjahre der Hidden Champions




Quelle: Eigene Darstellung, Datenbasis: Eigene Erhebung, Bureau van Dijk (2020).

Abbildung 8 zeigt die Verteilung der HCs in Bezug auf die Unternehmensgröße und deren WZ. 7,45 Prozent der HCs sind kleine Unternehmen, die bis zu 49 Personen beschäftigen und bis zu 10 Millionen Euro Umsatz im Jahr machen (Statistisches Bundesamt 2023). 20,29 Prozent der HCs sind mittlere Unternehmen mit bis zu 249 Beschäftigten und bis zu 50 Millionen Euro Umsatz. 72,26 Prozent der HCs sind Großunternehmen mit über 249 Beschäftigten und einem Umsatz von mehr als 50 Millionen Euro.

Die identifizierten HCs sind alle dem WZ Abschnitt C, dem verarbeitenden Gewerbe zugeordnet. Hierzu wurde sich, wie in der Identifizierungsmethodik in Kapitel 7.4 beschrieben, entschieden, da bis dato über zwei Drittel der identifizierten HCs diesem WZ angehören. Dieser WZ gliedert sich in 23 Unterabschnitte. Diese sind in Abbildung 8 aufgeführt, wo neben den Abschnitten auch die Unternehmensgrößenordnung mit abzulesen sind. In 22 der Abschnitte konnten HCs identifiziert werden. Die Tabakverarbeitung ist der einzige Abschnitt, dem kein HC zuzuordnen ist (WZ C 12). 24,1 Prozent der identifizierten HCs sind im Maschinenbau (WZ C 28) tätig. Von den 859 Maschinenbau-HCs sind 68 Prozent große, 24 Prozent mittlere und 8 Prozent kleine Unternehmen. Den zweitgrößten Anteil der HCs machen Unternehmen aus WZ C 25 (Herstellung von Metallerzeugnissen) aus (ca. 18 Prozent).

Lokalisierung und Deskription der Hidden Champions

Abbildung 8: Hidden Champions nach Wirtschaftszweig und Unternehmensgröße

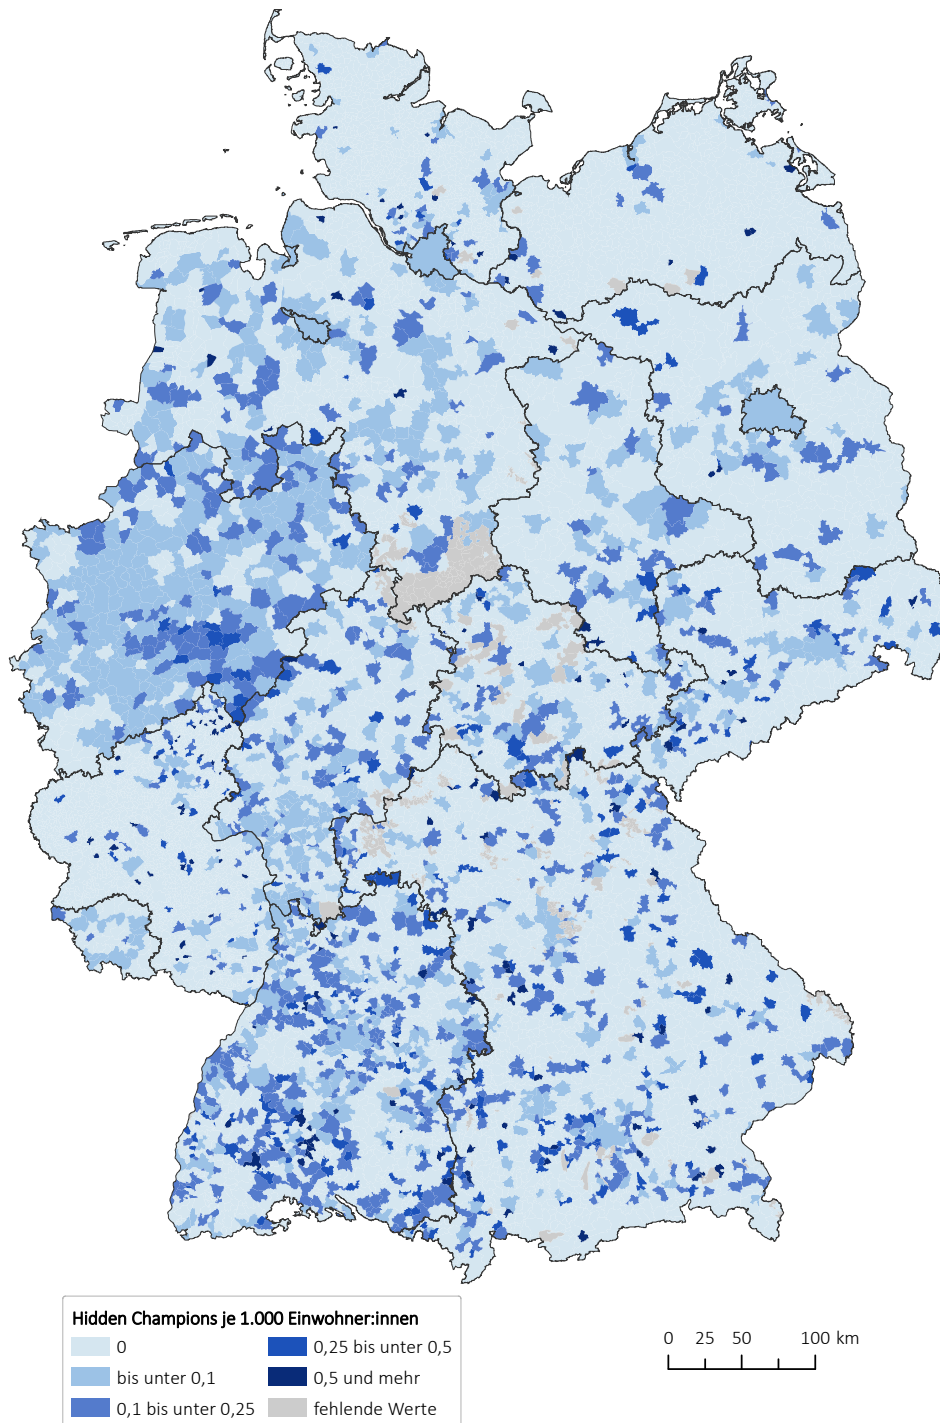


Quelle: Eigene Darstellung, Datenbasis: Eigene Erhebung; Bureau van Dijk (2020).

Lokalisierung und Deskription der Hidden Champions

Nachdem der Datensatz ausführlich beschrieben wurde, wird nun in Abbildung 9 die räumliche Verteilung der HCs (HCs je 1.000 EW) auf Gemeindeebene kartographisch dargestellt. Dies stellt die Untersuchungsvariable und den Untersuchungsraum der nachfolgenden Analysen dar. Bei der Betrachtung der Karte fällt auf, dass es in West- und Südwestdeutschland Cluster an HCs gibt. Weiter ist ersichtlich, dass im Norden und Nord-Osten Deutschlands keine Konzentration vorliegt.

Abbildung 9: Hidden Champions je 1.000 EW auf Gemeindeebene



Quelle: Eigene Darstellung und Berechnung, Datenbasis: Eigene Erhebung; Geodaten: BKG (2016).

10.2 Räumliche Autokorrelation

Einen ersten Eindruck der geographischen Verteilung der HCs ist bereits aus den in Kapitel 10.1 vorgestellten Deskriptionen bekannt. Die Ergebnisse des Global und Local Moran's I dienen unter anderem der Beantwortung der Forschungsfrage 1.6: *Wie lässt sich die Summe der identifizierten HCs beschreiben?* sowie der Forschungsfrage 3.2 *Inwieweit lassen sich räumliche, sozioökonomische Muster erkennen?*

Der Global Moran's I liegt bei 0,259 und der p-Wert ist statistisch signifikant (0,001). Damit ist die Nullhypothese abzulehnen. Dementsprechend weist die räumliche Verteilung Gruppierungen vor und lehnt eine zufällige Verteilung ab. Um festzustellen, in welchen Gebieten diese Gruppierungen oder Cluster stattfinden, wurde als lokales Maß der Local Moran's I berechnet. Das Ergebnis ist in der Karte in Abbildung 10 zu erkennen. Dargestellt sind die Werte in vier Kategorien (Hass & Arsanjani 2021, S. 5). Hotspots zeigen Cluster mit hohen HCs-Werten, welche signifikant autokorreliert sind. Coldspots sind demzufolge solche mit niedrigen Werten. Die Doughnuts repräsentieren Regionen mit hohen Werten, welche eine Region mit niedriger HCs-Dichte umgeben. Diamonds stellen Gemeinden mit hohen HCs-Werten dar, welche signifikant negativ mit den Nachbargemeinden korrelieren.

Insgesamt konnten 141 Gemeinden als lokale HCs-Hotspots identifiziert werden. Die meisten lokalen Hotspots sind vor allem fast flächendeckend im östlichen NRW und im südlichen Baden-Württemberg zu finden. Der einzige Hotspot Brandenburgs ist die Gemeinde Beelitz im Kreis Potsdam-Mittelmark. Für Niedersachsen wurde die Gemeinde Uplengen im Landkreis Leer als Hotspot identifiziert. Sachsen-Anhalt und das Saarland weisen keinen HCs-Hotspot vor. Bei den Hotspots handelt es sich ferner bei 66 um (Land-)Gemeinden und bei 75 um Städte. Im Durchschnitt haben die Hotspots ca. 16.000 EW und der Index zur Ländlichkeit des Thünen-Instituts (Küpper 2016) liegt im Mittel bei 0,36 (Spannweite -2,35 bis 0,98). Somit gelten die Hotspot Gemeinden als überdurchschnittlich ländliche Regionen.

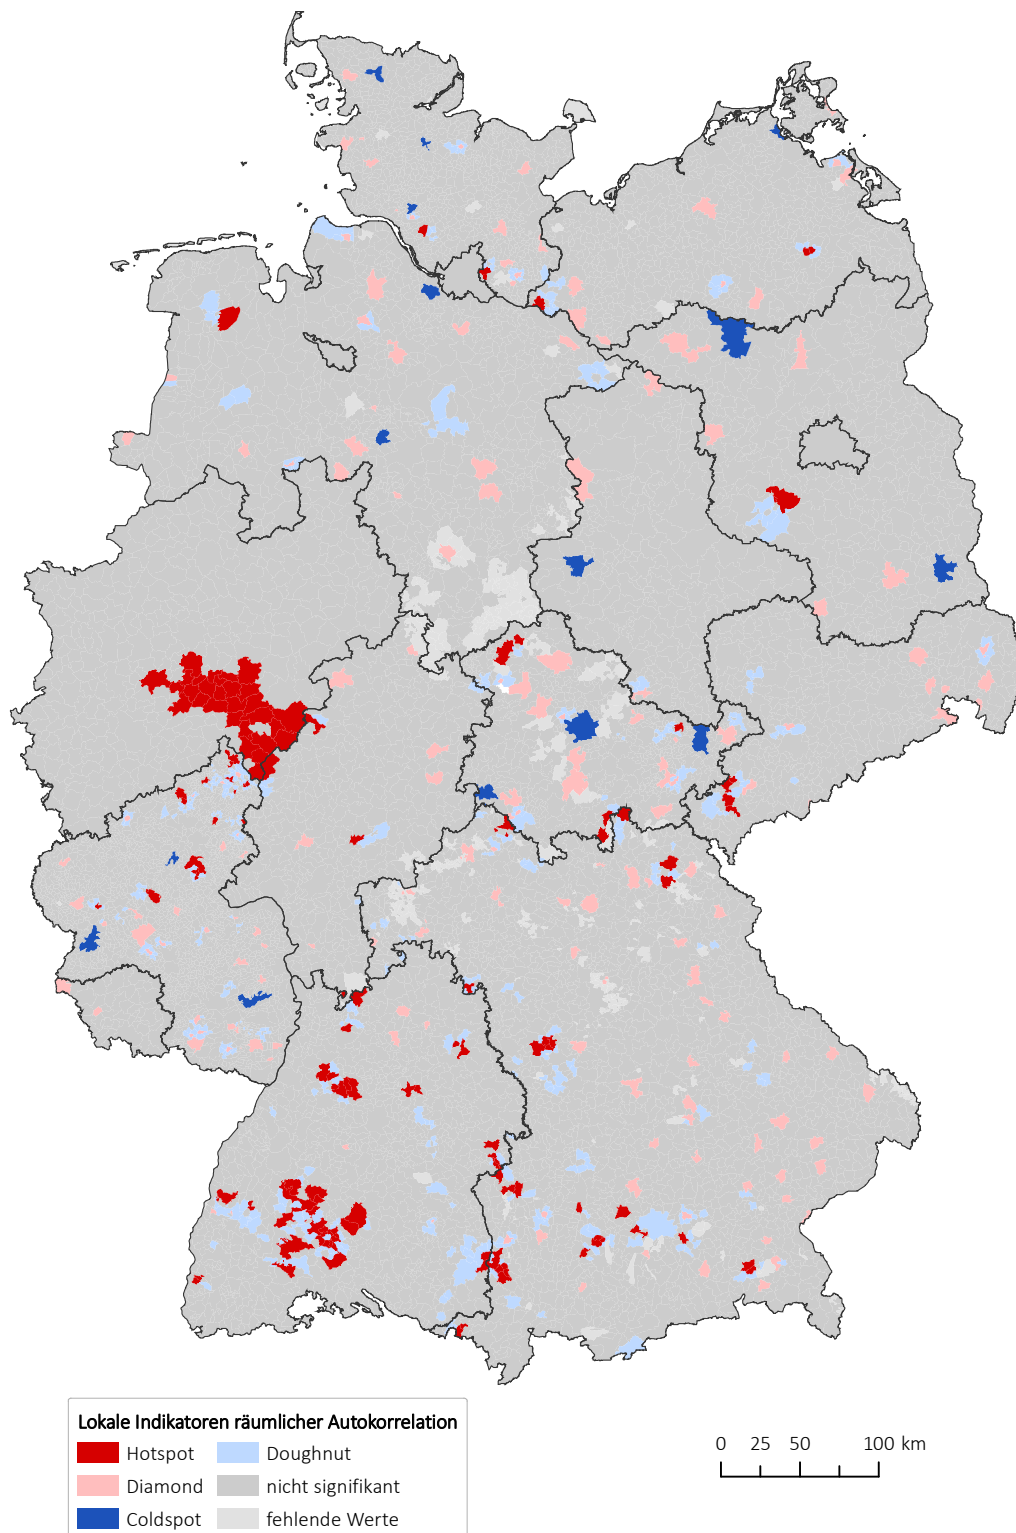
Als Coldspots sind 14 der Gemeinden identifiziert worden. Hier autokorrelieren die Regionen signifikant mit einer niedrigen HCs-Dichte. Diese Coldspots sind überwiegend im Nord-Osten Deutschlands, Thüringen und Rheinland-Pfalz zu finden. Dabei handelt es sich um 13 Städte und eine (Land-)Gemeinde mit einer durchschnittlichen Bevölkerungszahl von 53.000 EW. Unter anderem gelten Cottbus, Erfurt, Gera, Stralsund und Trier als Coldspots. Die Ländlichkeit liegt bei 0,31 (Spannweite -0,77 bis 0,82).

Lokalisierung und Deskription der Hidden Champions

Diamonds sind Gemeinden, welche hoch signifikant negativ mit ihren Nachbargemeinden korrelieren. Die Diamonds im gesamten Bundesgebiet weisen eine durchschnittliche Bevölkerungszahl von 8.337 EW vor. In Sachsen-Anhalt beispielsweise sind die Verbandsgemeinde Seehausen (Altmark) in Stendal und Oebisfelde Weferlingen im Kreis Börde solche Diamonds. Im Saarland sind dies die Gemeinde Perl (Landkreis Merzig-Wadern) sowie Dillingen (Landkreis Saarlouis). Die meisten Diamonds liegen in Bayern. Die Ländlichkeit aller Diamonds im Bundesgebiet liegt im Mittel bei 0,54 (Spannweite -0,91 bis 1,12). Es handelt sich um 90 (Land-)Gemeinden und 76 Städte.

Als Doughnuts sind 502 Regionen identifiziert worden. Darunter 449 Gemeinden und 43 Städte. Die höchste Anzahl an Doughnuts hat Bayern, wobei auch Baden-Württemberg und Rheinland-Pfalz verhältnismäßig viele vorzuweisen haben. Die durchschnittliche Bevölkerungszahl liegt bei 46.817 EW, die Ländlichkeit bei 0,33 mit einer Spannweite von -3,77 bis 1,12.

Abbildung 10: Local Moran's I



Quelle: Eigene Darstellung und Berechnung, Datenbasis: Eigene Erhebung; Geodaten: BKG (2016).

10.3 Fallbeispiele

Im Nachfolgenden werden beispielhaft einige der identifizierten Unternehmen vorgestellt, um einen besseren Eindruck der Unternehmenskategorie zu bekommen. Die Auswahl der Unternehmen erfolgte zufällig. Die minCam GmbH gilt als führendes Unternehmen in der Herstellung optischer Inspektion von Rohren und Kanälen (minCam GmbH 2023). Gegründet wurde sie im Jahr 2008 (Bureau van Dijk 2020). Mittlerweile hat das Unternehmen knapp 40 Mitarbeitende. Der HC ist im Allgäu angesiedelt. Das Unternehmen bietet ein modular und entsprechend nach den individuellen Bedürfnissen der Kundschaft anpassbares Anlagensystem an.

NOWOFOL ist Weltmarktführer im Bereich spezifischer Folienlösungen (NOVOFOL Kunststoffprodukte GmbH & Co KG 2023). Diese kommen in verschiedenen Anwendungsbereichen zum Einsatz. Dazu zählen die Verpackungsindustrie, Automobilindustrie und Luftfahrt, Elektronikindustrie und verschiedenste industrielle Anwendungen. Auch nachhaltige Folien bietet das Unternehmen mittlerweile an. Der HC konnte diese Marktposition seit der Gründung im Jahr 1971 durch hohe Innovationsambitionen erreichen (Bureau van Dijk 2023). NOWOFOL beschreibt auf seiner Unternehmenswebseite, dass sie Wert darauf legen Innovation nicht nur in der F&E-Abteilung anzutreiben. So bringt sich die gesamte 150 Personen große Belegschaft ein und treibt die Entwicklung des Unternehmens voran.

Im hessischen Oestrich-Winkel stellt KISICO Kircher, Simon und Co. GmbH (2023) ebenfalls Verpackungsmittel her. Seit über 75 Jahren führen Sie im Wettbewerb für spritzgegossene Kappen und Verschlüsse. Das 56 Mitarbeitende große Unternehmen bedient Kund:innen aus der Pharmazie, Diagnostik, Analytik und Labor, Chemie, Kosmetik oder Lebensmittelbranche mit seinen Diensten und Produkten. Hierfür konnte das Unternehmen zahlreiche weltweite Patente anmelden. Kontinuierliche Innovation ist als eines der Unternehmensziele deklariert. Dies bezieht sich auf Nachhaltigkeits- als auch Umsatz- und Innovationsziele.

Die Heinrich Wagner Sinto Maschinenfabrik GmbH in Bad Laasphe im Kreis Siegen Wittgenstein im östlichen NRW ist ebenfalls ein HC. Das Unternehmen ist international führender Anbieter für Anlagen und Maschinen der Gießereiindustrie. Über 300 Mitarbeitende arbeiten an der Herstellung von Formmaschinen und Vergießeinrichtungen. Das Unternehmen beschreibt eine Self-Made-Mentalität, welche dazu führt, dass sie die zentralen Komponenten der Produkte selbst herstellen und verbauen (Heinrich Wagner Sinto Maschinenfabrik GmbH 2023).

Lokalisierung und Deskription der Hidden Champions

Im niedersächsischen Wunstorf gelegen, gilt die Cyberbond Europe GmbH als Marktführer im Bereich Reaktionsklebstoffe. Der 1997 gegründete HC vertreibt seine Produkte weltweit und wirbt mit internationalem Service durch zielgerichtetes Anwendungs- und Produktions-Knowhow. In der Medizinbranche werden die Klebstoffe beispielsweise zur Verbindung von Plastik und Metall verwendet. In der Mühlen-, der Siebdruck- und der Filterindustrie werden sie zur Produktion von Siebrahmen genutzt (Cyberbond Europe GmbH 2023).

Die Ingenieurtechnik und Maschinenbau GmbH ist ein HC aus Rostock. Der HC stellt Anlagen und Transporttechnik her und beliefert Kundschaft aus der Schiffbau-, Maschinenbau-, Stahlbau- und Windenergiebranche sowie dem Bahnverkehr, Luft- und Raumfahrt oder Häfen (Ingenieurtechnik und Maschinenbau GmbH 2023). Auch sie bieten Speziallösungen für individuelle Anfragen an. 1990 gegründet beschäftigt das Unternehmen mittlerweile 120 Mitarbeitende.

11 Regionstypisierung

In diesem Kapitel werden die Ergebnisse der in Kapitel 8 beschriebenen Methodik zur Regionstypisierung vorgestellt. Zunächst geht es um die extrahierten sozioökonomischen Faktoren aus der HKA. Darauf folgen die Ergebnisse des MBC und die daraus kalkulierten Cluster, dargestellt als Regionstypen und deren deskriptive Analyse.

11.1 Hauptkomponentenanalyse

Die HKA wurde durchgeführt, um die 17 sozioökonomischen Variablen zu Faktoren zusammenzufassen. Die Daten erfüllen die Voraussetzungen für die Durchführung der HKA. Zunächst wird die Korrelationsmatrix der Variablen vorgestellt. Wie in Tabelle 4 zu erkennen kann Multikollinearität ausgeschlossen werden, da keine Werte über 0,9 vorliegen (Cleff 2015, S. 219; Backhaus et al. 2011, S. 339). Die einbezogenen Variablen können vollständig verwendet werden.

Regionstypisierung

Tabelle 4: Korrelationsmatrix

| | V3 | V2 | V1 | V5 | V9 | V8 | V7 | V10 | V11 | V12 | V16 | V14 | V6 | V13 | V17 | V15 | V4 |
|--|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| V3 Anteil Freizeitfläche an Gesamtfläche in Prozent | 1,00 | 0,43 | 0,63 | 0,33 | -0,28 | -0,19 | -0,30 | 0,15 | 0,08 | 0,12 | 0,24 | 0,03 | -0,37 | 0,09 | 0,07 | 0,16 | 0,62 |
| V2 Anteil Verkehrsfläche an Gesamtfläche in Prozent | 0,43 | 1,00 | 0,67 | 0,23 | -0,12 | -0,15 | -0,16 | 0,15 | 0,08 | 0,05 | 0,16 | 0,09 | -0,31 | 0,11 | 0,06 | 0,24 | 0,55 |
| V1 Anteil Siedlungsfläche an Gesamtfläche in Prozent | 0,63 | 0,67 | 1,00 | 0,43 | -0,24 | -0,26 | -0,27 | 0,19 | 0,11 | 0,15 | 0,27 | 0,08 | -0,55 | 0,15 | 0,07 | 0,24 | 0,86 |
| V5 Breitbandverfügbarkeit von 100 Mbit/s | 0,33 | 0,23 | 0,43 | 1,00 | -0,20 | -0,26 | -0,24 | 0,11 | 0,08 | 0,12 | 0,17 | 0,02 | -0,41 | 0,13 | 0,04 | 0,10 | 0,43 |
| v9 PKW-Fahrtzeit zur Autobahnanbindung (in Minuten) | -0,28 | -0,12 | -0,24 | -0,20 | 1,00 | 0,36 | 0,53 | -0,04 | -0,02 | -0,02 | -0,09 | -0,01 | 0,20 | -0,04 | -0,01 | -0,04 | -0,24 |
| V8 PKW-Fahrtzeit zum IC/EC/ICE Halt (in Minuten) | -0,19 | -0,15 | -0,26 | -0,26 | 0,36 | 1,00 | 0,27 | -0,08 | -0,04 | -0,07 | -0,08 | -0,03 | 0,20 | -0,01 | -0,07 | -0,08 | -0,29 |
| v7 PKW-Fahrtzeit zu internationalen Flughäfen (in Minuten) | -0,30 | -0,16 | -0,27 | -0,24 | 0,53 | 0,27 | 1,00 | -0,06 | -0,03 | -0,03 | -0,06 | -0,02 | 0,22 | -0,03 | 0,00 | -0,07 | -0,31 |
| V10 Studierende an Hochschulen je 1000 EW | 0,15 | 0,15 | 0,19 | 0,11 | -0,04 | -0,08 | -0,06 | 1,00 | 0,72 | 0,03 | 0,09 | 0,03 | -0,19 | 0,09 | 0,02 | 0,16 | 0,23 |
| V11 Studierende an Fachhochschulen | 0,08 | 0,08 | 0,11 | 0,08 | -0,02 | -0,04 | -0,03 | 0,72 | 1,00 | 0,02 | 0,06 | 0,02 | -0,14 | 0,06 | 0,02 | 0,08 | 0,13 |
| V12 Steuereinnahmekraft je 1000 EW | 0,12 | 0,05 | 0,15 | 0,12 | -0,02 | -0,07 | -0,03 | 0,03 | 0,02 | 1,00 | 0,50 | 0,00 | -0,11 | 0,03 | 0,10 | 0,03 | 0,13 |
| V16 Einpendelnde je 1000 EW | 0,24 | 0,16 | 0,27 | 0,17 | -0,09 | -0,08 | -0,06 | 0,09 | 0,06 | 0,50 | 1,00 | 0,00 | -0,27 | 0,16 | 0,10 | 0,04 | 0,19 |
| V14 Beschäftigtendichte | 0,03 | 0,09 | 0,08 | 0,02 | -0,01 | -0,03 | -0,02 | 0,03 | 0,02 | 0,00 | 0,00 | 1,00 | -0,04 | 0,01 | 0,01 | 0,84 | 0,16 |
| V6 Koeffizient der regionalen Spezialisierung | -0,37 | -0,31 | -0,55 | -0,41 | 0,20 | 0,20 | 0,22 | -0,19 | -0,14 | -0,11 | -0,27 | -0,04 | 1,00 | -0,23 | -0,06 | -0,18 | -0,56 |
| V13 Krankenhausbetten je 1000 EW | 0,09 | 0,11 | 0,15 | 0,13 | -0,04 | -0,01 | -0,03 | 0,09 | 0,06 | 0,03 | 0,16 | 0,01 | -0,23 | 1,00 | 0,01 | 0,06 | 0,14 |
| V17 Baugenehmigungen (Wohnungen) je 1000 EW | 0,07 | 0,06 | 0,07 | 0,04 | -0,01 | -0,07 | 0,00 | 0,02 | 0,02 | 0,10 | 0,10 | 0,01 | -0,06 | 0,01 | 1,00 | 0,01 | 0,03 |
| V15 Beschäftigte mit Wohnort gleich Arbeitsort | 0,16 | 0,24 | 0,24 | 0,10 | -0,04 | -0,08 | -0,07 | 0,16 | 0,08 | 0,03 | 0,04 | 0,84 | -0,18 | 0,06 | 0,01 | 1,00 | 0,38 |
| V4 Einwohnerdichte | 0,62 | 0,55 | 0,86 | 0,43 | -0,24 | -0,29 | -0,31 | 0,23 | 0,13 | 0,13 | 0,19 | 0,16 | -0,56 | 0,14 | 0,03 | 0,38 | 1,00 |

Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020).

Die erklärte Gesamtvarianz der HKA liegt bei 68,44. Die extrahierten Faktoren erklären die Gesamtvarianz zu 68,44 Prozent (Cleff 2015, S. 222). Die vorliegende Arbeit orientiert sich am sog. Kaiser-Guttman-Kriterium, um die Anzahl der Faktoren festzulegen (Guttman, 1954; Kaiser 1960). Bei der Betrachtung der Eigenwerte, welche größer als eins sind, konnten sechs Faktoren identifiziert werden. Bei der Betrachtung der rotierten Komponentenmatrix sind die Ladungen der einzelnen Variablen auf die Faktoren (Komponenten) festzustellen (Cleff 2015, S. 225-226). So werden die Variablen den Faktoren zugeteilt, auf welche sie am stärksten laden. Diese Ladungen sind in Tabelle 5 dargestellt.

Regionstypisierung

Tabelle 5: Rotierte Komponentenmatrix

| | Faktoren | | | | | |
|--|----------|--------|--------|--------|--------|--------|
| | 1 | 2 | 3 | 4 | 5 | 6 |
| V1 Anteil der Siedlungsfläche an der Gesamtfläche in Prozent | 0,915 | -0,138 | 0,063 | 0,052 | 0,101 | 0,005 |
| V4 Einwohnerdichte | 0,861 | -0,194 | 0,186 | 0,090 | 0,047 | 0,034 |
| V3 Anteil der Freizeitfläche an der Gesamtfläche in Prozent | 0,772 | 0,040 | 0,090 | 0,034 | -0,034 | -0,091 |
| V2 Anteil der Verkehrsfläche an der Gesamtfläche in Prozent | 0,721 | -0,224 | -0,010 | 0,030 | 0,093 | -0,067 |
| V6 Koeffizient der regionalen Spezialisierung | -0,598 | 0,175 | -0,026 | -0,123 | -0,202 | -0,305 |
| V5 Breitbandverfügbarkeit von 100 Mbit/s | 0,469 | -0,296 | -0,026 | 0,045 | 0,153 | 0,204 |
| V9 PKW-Fahrtzeit zur Bundesautobahnanbindung (in Min) | -0,108 | 0,833 | 0,004 | 0,011 | -0,011 | -0,034 |
| V7 PKW-Fahrtzeit zu internationalen Verkehrsflughäfen (in Min) | -0,181 | 0,771 | -0,010 | -0,001 | 0,034 | -0,054 |
| V8 PKW-Fahrtzeit zum IC/EC/ICE Halt (in Min) | -0,176 | 0,621 | -0,035 | -0,050 | -0,072 | 0,116 |
| V14 Beschäftigtendichte | 0,014 | -0,014 | 0,962 | -0,010 | 0,004 | 0,000 |
| V15 Beschäftigte mit Wohnort gleich Arbeitsort | 0,217 | -0,024 | 0,937 | 0,076 | 0,003 | 0,022 |
| V11 Studierende an Fachhochschulen | 0,049 | -0,018 | 0,006 | 0,926 | 0,013 | 0,005 |
| V10 Studierende an Hochschulen je 1000 EW | 0,146 | -0,026 | 0,054 | 0,910 | 0,021 | 0,027 |
| V12 Steuereinnahmekraft je 1000 EW | 0,040 | -0,027 | 0,022 | -0,009 | 0,840 | -0,094 |
| V16 Einpendelnde je 1000 EW | 0,195 | -0,033 | -0,015 | 0,036 | 0,819 | 0,093 |
| V13 Krankenhausbetten je 1000 EW | 0,141 | 0,040 | 0,008 | 0,067 | 0,186 | 0,769 |
| V17 Baugenehmigungen (Wohnungen) je 1000 EW | 0,093 | 0,000 | -0,012 | 0,049 | 0,294 | -0,532 |

Extraktionsmethode: Hauptkomponentenanalyse.
 Rotationsmethode: Varimax mit Kaiser-Normalisierung.
 Die Rotation ist in 5 Iterationen konvergiert.

Quelle: *Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020).*

Es wurden sechs Faktoren extrahiert. Der erste Faktor (F01) besteht aus sechs Variablen, welche unterschiedlich stark auf den Faktor laden. Er erhält aufgrund der Variablen die Bezeichnung *Siedlungs- und Branchenstruktur*. Auf Faktor 2 laden drei Variablen, welche alle im Kontext von *Mobilität und Erreichbarkeit* stehen. Dies ist daher die Bezeichnung für F02 in dieser Arbeit. Die Variablen 14 und 15 laden beide sehr stark auf Faktor 3. F03 wird im Weiteren als *lokale Beschäftigung* betitelt. Auf F04 laden die zwei Variablen im Bildungskontext sehr stark. Der Faktor wird dementsprechend als *Hochschulbildung* bezeichnet. Der fünfte Faktor heißt *Lokale Arbeitsplatzattraktivität* und wird aus den Variablen 12 und 16 gebildet. Der letzte extrahierte Faktor aus den Ergebnissen der HKA ist F06 *soziale Infrastruktur*, geladen aus den Variablen 13 und 17. In den weiteren Analysen werden die sechs extrahierten Faktoren als sozioökonomische Charaktereigenschaften auf Gemeindeebene untersucht und verwendet.

11.2 Deskriptive Analyse der sozioökonomischen Charaktereigenschaften


Die sechs Faktoren, welche durch die HKA identifiziert wurden, sind im Folgenden kartographisch dargestellt. Dazu wurden die Variablen an die Geometrien der deutschen Gemeindegebiete 2016 zusammengeführt. Faktorwerte über Null zeigen eine überdurchschnittliche Ausprägung. Die Standardabweichung der Werte ist 1, bzw. -1. Abbildung 11 zeigt die räumliche Verteilung der Ausprägungen der Siedlungs- und Branchenstruktur auf Gemeindeebene. Für die Siedlungs- und Branchenstruktur wird deutlich, dass sich die überdurchschnittlichen Werte auf den ersten Blick in den deutschen Metropolregionen wiederfinden (Metropolregionen Hamburg 2023). Die nordrhein-westfälische Rhein-Ruhr-Metropolregion zeigt hier eine deutlich überdurchschnittliche Ausprägung. Im Rhein-Main-Gebiet sowie im Kerngebiet-Stuttgart und Rhein-Neckar sind ebenfalls überdurchschnittliche Werte zu verzeichnen. Auch Nürnberg, München, Hamburg, Bremen und Hannover sind dunkelblau eingezeichnet, wenn auch mit weniger hohen Werten im Umland als in den zuvor genannten Metropolregionen. Die Metropolregion Mitteldeutschland ist heterogener in der Ausprägung des F01. Allgemein deutlich ist die lichtere Siedlungs- und Branchenstruktur im Norden und Nordosten Deutschlands sowie in Bayern und Rheinland-Pfalz. Ländlichere Regionen werden hier durch die niedrigere Siedlungs- und Branchenstruktur beschrieben. Jedoch ist dies nicht zu pauschalisieren, denn auch ländlichere Regionen außerhalb der Metropolregionen weisen teilweise überdurchschnittlich hohe F01 Werte auf. Die Karte aus Abbildung 11 veranschaulicht, dass bei der Betrachtung der Siedlungs- und Branchenstruktur auf Gemeindeebene diese eine sehr heterogene Verteilung aufzeigt. Tabelle 6 zeigt die Anzahl der Gemeinden, welche den Skalen der Karte zugehörig sind. Die Faktorwerte liegen zwischen -5,33 und 9,27 (Spannweite 14,6), der Median bei -0,27.

Tabelle 6: Anzahl der Gemeinden je Faktorausprägung F01

| Faktorwert | unter -1 | -1 bis unter -0,5 | -0,5 bis unter 0 | 0 bis unter 0,5 | 0,5 bis unter 1 | 1 und mehr |
|-------------------|----------|-------------------|------------------|-----------------|-----------------|------------|
| Anzahl | 345 | 3.173 | 3.319 | 1.692 | 832 | 1.191 |
| Anteil in Prozent | 3% | 30% | 31% | 16% | 8% | 11% |

Quelle: Eigene Darstellung und Berechnung.

Abbildung 11: Ausprägungen F01: Siedlungs- und Branchenstruktur (Gemeinden)



Quellen: Eigene Darstellung und Berechnung; Datenbasis: Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

Bezüglich des Faktors Mobilität und Erreichbarkeit (F02) ist zu beachten, dass die Ausprägungen gegensätzlich zu denen der anderen Faktoren zu interpretieren sind. Die Mobilität und Erreichbarkeit bildet die (V7) PKW-Fahrtzeit zu internationalen Verkehrsflughäfen, (V8) zum IC/EC/ICE Halt und (V9) zur Bundesautobahnanbindung jeweils in Minuten ab. Je höher dieser Wert ist, desto schlechter sind die entsprechenden Mobilitätsknotenpunkte zu erreichen. Die Farbgebung der Legende in Abbildung 12 wurde umgekehrt aufgestellt, sodass die Farbnuancen mit der Interpretation der anderen Karten übereinstimmen. Je dunkler das Blau, desto höher ist die Faktorausprägung.


Die Hauptverkehrsachsen Deutschlands sind sehr deutlich in der Karte zu erkennen. Autobahnen und Zugverbindungen sind hervorgehoben. Insbesondere in NRW, sowie dem südlichen Hessen und Rheinland-Pfalz ist eine sehr dichte Mobilität und gute Erreichbarkeit zu erkennen. Eine schlechtere Versorgung liegt insbesondere an den östlichen Grenzen vor. In Bayern, Sachsen, Brandenburg und Mecklenburg-Vorpommern ist die Erreichbarkeit an den Grenzen, vor allem im Vergleich mit den westlichen Grenzregionen, verhältnismäßig unterdurchschnittlich. Mecklenburg-Vorpommern und Sachsen-Anhalt sowie das östliche Niedersachsen weisen einige großflächige unterdurchschnittlich gut erreichbare Regionen auf. Tabelle 7 zeigt wiederum die Verteilung der Gemeinden auf die Faktorausprägungen der Mobilität und Erreichbarkeit. Der Median von F02 liegt bei -0,14. Der niedrigste Mobilitätswert liegt bei -2,16 und das Maximum bei 10,69. Die Spannweite beträgt somit 12,8.

Tabelle 7: Anzahl der Gemeinden je Faktorausprägung F02

| Faktorwert | unter -1 | -1 bis unter -0,5 | -0,5 bis unter 0 | 0 bis unter 0,5 | 0,5 bis unter 1 | 1 und mehr |
|-------------------|----------|-------------------|------------------|-----------------|-----------------|------------|
| Anzahl | 1.370 | 2.236 | 2.280 | 1.908 | 1.318 | 1.440 |
| Anteil in Prozent | 13% | 21% | 22% | 18% | 12% | 14% |

Quelle: Eigene Darstellung und Berechnung.

Abbildung 12: Ausprägungen F02: Mobilität und Erreichbarkeit (Gemeinden)



Quellen: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

Abbildung 13 verdeutlicht die räumlichen Ausprägungen der lokalen Beschäftigung auf Gemeindeebene. Die höchsten lokalen Beschäftigungsraten sind in den deutschen Großstädten vorzufinden. NRW weist insbesondere durch das Ruhrgebiet und das Rheinland diesbezüglich die meisten überdurchschnittlichen Gemeinden vor. Neben den Stadtstaaten sind bundesweit bezogen auf die lokale Beschäftigung Großstädte wie Frankfurt, München, Aachen, Lübeck oder Stuttgart überdurchschnittlich hoch einzuordnen.

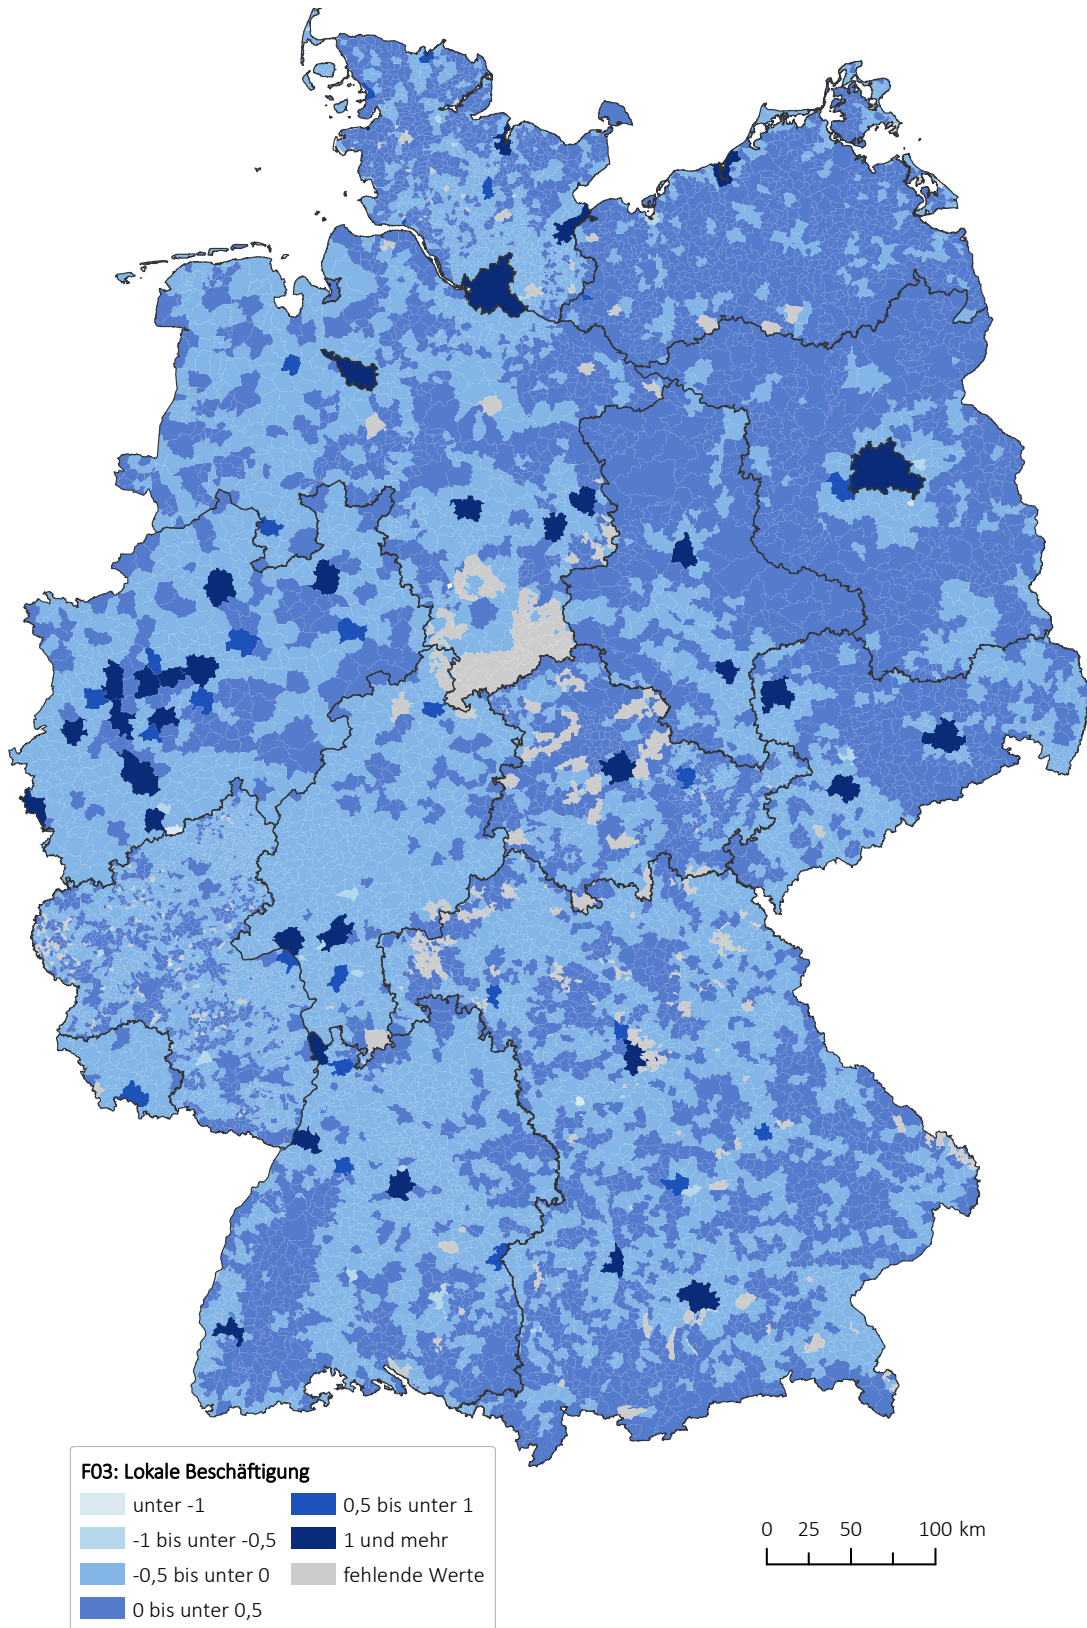
F03 ist der Faktor, welcher nach der in den Karten abgebildeten Skala, abgesehen von den Großstädten, viele deutlich homogene Flächen vorweist. Deutlich wird dies beispielsweise in Mittelhessen. Auch im nördlichen Sachsen-Anhalt sowie Brandenburg sind über viele Gemeindegrenzen hinweg überdurchschnittlich hohe Wert zu vermerken. Allgemein ist zu erkennen, dass die lokale Beschäftigung im Westen und Südwesten Deutschlands eher unterdurchschnittlich ist. Währenddessen liegt sie im Nordosten des Landes in großen Teilen über dem Mittelwert. Die Aufgliederung der Gemeindeanzahl auf die Skalenausprägungen der Karte in Tabelle 8 gibt einen weiteren Hinweis auf die Verteilung der lokalen Beschäftigung. Diese streut näher um die durchschnittliche lokale Beschäftigung als andere Faktoren. Die meisten Gemeinden haben einen Faktorwert der lokalen Beschäftigung zwischen -0,5 und 0,5. Der Median von F03 liegt bei -0,008. Die Spannweite beträgt 88,25 (Min: -1,48, Max: 88,25).

Tabelle 8: Anzahl der Gemeinden je Faktorausprägung F03

| Faktorwert | unter -1 | -1 bis unter -0,5 | -0,5 bis unter 0 | 0 bis unter 0,5 | 0,5 bis unter 1 | 1 und mehr |
|-------------------|----------|-------------------|------------------|-----------------|-----------------|------------|
| Anzahl | 5 | 31 | 5.508 | 4.943 | 27 | 38 |
| Anteil in Prozent | 0,05% | 0,29% | 52,2% | 46,84% | 0,26% | 0,36% |

Quelle: Eigene Darstellung und Berechnung.

Abbildung 13: Ausprägungen F03: Lokale Beschäftigung (Gemeinden)



Quellen: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

Abbildung 14 zeigt den Faktor Hochschulbildung (F04) auf Gemeindeebene. In Tabelle 9 wird die Verteilung der Gemeinden je Faktorausprägung der Hochschulbildung dargestellt. Die Verteilung hat eine Tendenz ins Negative und streut hauptsächlich zwischen -0,5 und 0,5. Der Median von F04 liegt bei -0,07. Der niedrigste Faktorwert der Hochschulbildung liegt bei -1,6, das Maximum bei 50,9 (Spannweite 52,61).

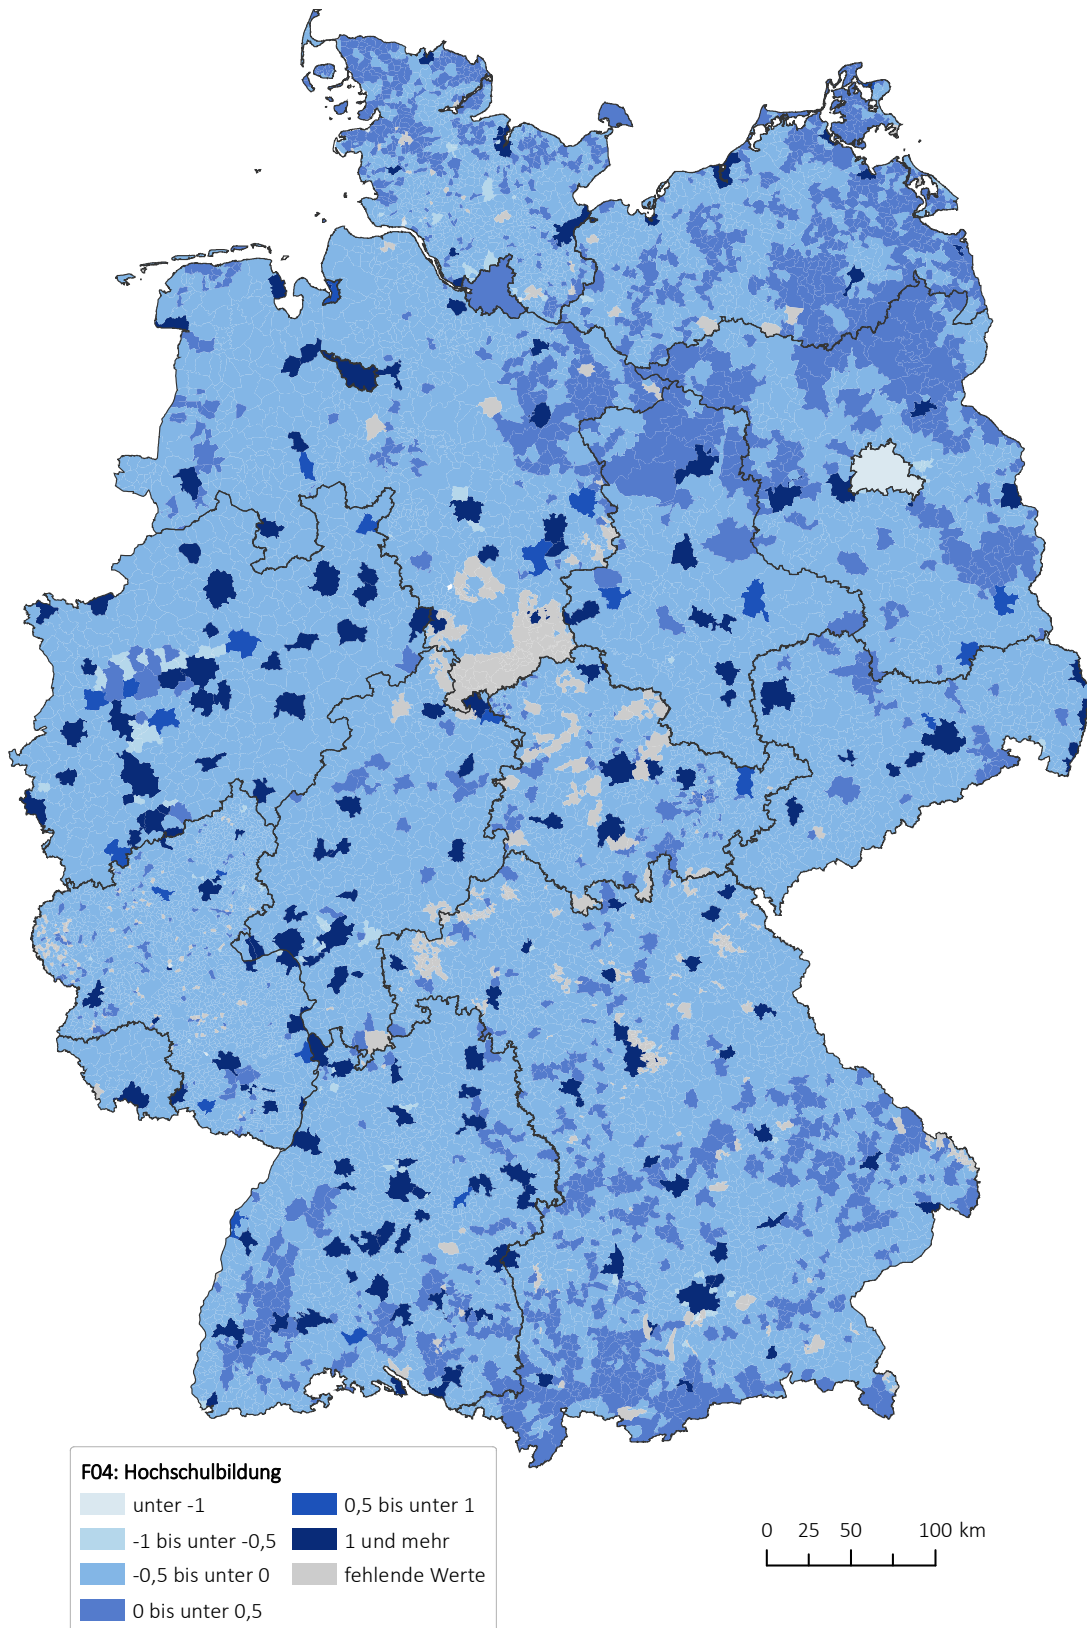
Tabelle 9: Anzahl der Gemeinden je Faktorausprägung F04

| Faktorwert | unter -1 | -1 bis unter -0,5 | -0,5 bis unter 0 | 0 bis unter 0,5 | 0,5 bis unter 1 | 1 und mehr |
|-------------------|----------|-------------------|------------------|-----------------|-----------------|------------|
| Anzahl | 7 | 100 | 8.476 | 1.755 | 26 | 188 |
| Anteil in Prozent | 0,07% | 0,95% | 80,33% | 16,63% | 0,25% | 1,78% |

Quelle: Eigene Darstellung und Berechnung.

Auffällig ist die gleichmäßige Verteilung von Werten über 1 beinahe über das gesamte Bundesgebiet hinweg. Groß- und Mittelstädte weisen deutlich überdurchschnittliche Werte für F04 vor. Ähnlich wie in F03 weisen die Gemeinden im Nordosten Deutschlands eine leichte Tendenz zu überdurchschnittlichen flächendeckenderen hohen Werten der Hochschulbildung vor. Im Nordwesten, Westen und im Zentrum Deutschlands sind die Werte abgesehen von vereinzelnden Spitzen in Groß- und Mittelstädten im Umland eher unterdurchschnittlich hoch. Für Bayern und Baden-Württemberg gilt eine Konzentration der überdurchschnittlichen Hochschulbildung auf die Städte, sowie im Süden der Bundesländer. In Schleswig-Holstein ist es umgekehrt. Während die nördlichen Gemeinden tendenziell einen höheren F04 vorweisen, gilt für die südlichen Gemeinden ein eher unterdurchschnittlicher Wert.

Abbildung 14: Ausprägungen F04: Hochschulbildung (Gemeinden)



Quellen: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

In der folgenden Karte ist die Ausprägung der lokalen Arbeitsplatzattraktivität dargestellt. Der F05 zeigt in Abbildung 15 auf den ersten Blick bereits die heterogene Verteilung des Faktors. Höhere Werte sind eindeutig im Süden Deutschlands zu erkennen. Bayern und Baden-Württemberg zeigen besonders hohe Werte auf, je südlicher die Gemeinde liegt. Auch im Nordwesten liegt die Arbeitsplatzattraktivität eher über dem Bundesmittel. Währenddessen weisen die Bundesländer im Norden des Landes niedrigere Werte auf. Flächendeckender lassen sich hier unterdurchschnittlich lokale Arbeitsplatzattraktivität identifizieren. Beispielsweise in Sachsen-Anhalt oder dem östlichen Niedersachsen sowie Mecklenburg-Vorpommern.


In Brandenburg und Rheinland-Pfalz beispielsweise sind besonders starke Differenzen der Konzentration des F05 zu erkennen. In Rheinland-Pfalz, dem Bundesland mit den meisten Gemeinden, wird für eine große Zahl dieser ein maximal überdurchschnittlicher Wert aufgezeigt. Durch die Betrachtung der Karte in Abbildung 15 sowie der Tabelle 10 wird deutlich, dass ein Großteil aller Gemeinden eine unterdurchschnittliche lokale Arbeitsplatzattraktivität zu vorzuweisen haben. Der Median der lokalen Arbeitsplatzattraktivität liegt bei -0,15. Der niedrigste Wert der lokalen Arbeitsplatzattraktivität liegt bei -4,02 und der höchste bei 46,32 (Spannweite 46,32).

Tabelle 10: Anzahl der Gemeinden je Faktorausprägung F05

| Faktorwert | unter -1 | -1 bis unter -0,5 | -0,5 bis unter 0 | 0 bis unter 0,5 | 0,5 bis unter 1 | 1 und mehr |
|-------------------|----------|-------------------|------------------|-----------------|-----------------|------------|
| Anzahl | 77 | 2.189 | 4.234 | 2.421 | 963 | 668 |
| Anteil in Prozent | 1% | 21% | 40% | 23% | 9% | 6% |

Quelle: Eigene Darstellung und Berechnung.

Abbildung 15: Ausprägungen F05: Lokale Arbeitsplatzattraktivität (Gemeinden)



Quellen: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

Final wird nun auf die Karte in Abbildung 16 eingegangen. Diese zeigt die räumlichen Ausprägungen des Faktors 06 der sozialen Infrastruktur. Für diesen Faktor lässt sich nicht feststellen, dass die stärkeren Ausprägungen eher in peripheren oder urbaneren Gebieten stattfinden. Sehr deutlich wird, dass auf Gemeindeebene eine heterogene Verteilung der sozialen Infrastruktur vorliegt. Überdurchschnittliche Werte weisen die Gemeinden an der östlichen Landesgrenze der Bundesländer Bayern, Brandenburg und Sachsen auf. Weitere Spitzen in Bezug auf die soziale Infrastruktur sind im östlichen NRW, während das zentrale Ruhgebiet und Rheinland hier eher unter dem Durchschnitt liegen. Deutlich wird dies ebenfalls für die Stadtstaaten Berlin und Bremen oder die Großstädte München, Köln, Dresden oder Frankfurt am Main.


Tabelle 11 zeigt die Verteilung der Faktorwerte der sozialen Infrastruktur der Gemeinden. Skaliert wie in den Faktoren davor anhand der Legendeneinteilung der Karte in Abbildung 16. Der Median von F06 liegt bei -0,02. Die soziale Infrastruktur streut zwischen -21,07 Standardabweichungen unter dem Durchschnitt und 33,59 über diesem (Spannweite 54,66).

Tabelle 11: Anzahl der Gemeinden je Faktorausprägung F06

| Faktorwert | unter -1 | -1 bis unter -0,5 | -0,5 bis unter 0 | 0 bis unter 0,5 | 0,5 bis unter 1 | 1 und mehr |
|-------------------|----------|-------------------|------------------|-----------------|-----------------|------------|
| Anzahl | 603 | 1.203 | 3.705 | 3.661 | 721 | 659 |
| Anteil in Prozent | 6% | 11% | 35% | 35% | 7% | 6% |

Quelle: Eigene Darstellung und Berechnung.

Abbildung 16: Ausprägungen F06: Soziale Infrastruktur (Gemeinden)



Quellen: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

11.3 Model Based Clustering

Im nächsten Schritt der Regionstypisierung wurde eine Model Based Clusteranalyse durchgeführt. Einbezogen wurden hierzu die sechs Faktoren aus der HKA. Als Ergebnis der Clusteranalyse wurde das VVV-Modell ausgegeben. Mit einem Wert von -12.719,1 weist es im Vergleich zu den anderen 13 Modellen das geringste BIC auf. Das Modell gibt neun Cluster als optimale Datenverteilung an. Diese sind als ellipsoidisch mit unterschiedlichem Volumen, Formen und Ausrichtungen zu beschreiben. Im Kontext heißt dies, dass das VVV-Modell die betrachteten Variablen bestmöglich der Datenverteilung zuordnet. Die Verteilung der Gemeindezahlen auf die neun Cluster ist in Tabelle 13 (S. 103) dargestellt. Die Werte von 10.552 Gemeinden konnten hier in die Clusteranalyse einbezogen werden. Das kleinste Cluster ist Cluster drei mit nur 40 Gemeinden. Das größte Cluster ist Cluster sechs mit 2.295 Gemeinden. Die Clusteranalyse war der letzte Schritt in der sozioökonomischen Typisierung der Gemeinden. Die Cluster werden im Folgenden *Regionstypen* genannt.

11.4 Deskriptive Analyse Regionstypen

In diesem Kapitel werden die neun identifizierten Regionstypen vorgestellt. Durch die Clusteranalyse konnten Gemeinden mit ähnlichen sozioökonomischen strukturellen Verhältnissen zusammengefasst werden. Tabelle 13 gibt einen ersten Überblick zu den Kennzahlen, welche nicht in die HKA mit einbezogen wurden, im Kontext der Analyse aber in den Modellschätzungen mit aufgenommen wurden. Tabelle 13 zeigt den Gesamtüberblick aller Regionstypen. Im zweiten Teil dieses Kapitels werden die Typen jeweils noch einmal einzeln vorgestellt.

Zum Überblick wird in Tabelle 12 zunächst die Verteilung von 10.552 deutschen Gemeinden auf die Regionstypen aufgelistet. Weiter ist abzulesen, zu welchen Anteilen die Gemeinden der jeweiligen Regionstypen als ländlich, eher ländlich oder urban gelten. Die Differenzierung erfolgt nach der in Kapitel 9.1 vorgestellten Ländlichkeit (Küpper 2016, S. 12). Demnach gilt Regionstyp 3 mit 52,5 Prozent urbanen Gemeinden als urbanster der Regionstypen. Ein Großteil der Gemeinden des Typs sind Städte. Die höchste Ausprägung an ländlichen Gemeinden weisen die Regionstypen 5 bis 9 auf. Hier variiert der Anteil der ländlichen Regionen zwischen 57,8 und 74,4 Prozent. Die als urban eingeordneten Gemeinden sind anteilig in allen fünf Typen unter 10 Prozent.

Regionstypisierung

Tabelle 12: Deskription der Regionstypen

| Regionstyp | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|--|--------------------------|----------|----------|----------|----------|---------|---------|---------|---------|---------|
| Gemeinden (10.552) | | 1260 | 247 | 40 | 1.418 | 242 | 2.295 | 2.054 | 2.227 | 769 |
| anteilig in Prozent | | 11,9 | 2,3 | 0,4 | 13,4 | 2,3 | 21,7 | 19,5 | 21,1 | 7,3 |
| Ländlichkeit (anteilig in Prozent) | ländlich | 43,5 | 31,6 | 30,0 | 33,7 | 62,4 | 57,8 | 74,5 | 73,1 | 64,8 |
| | eher ländlich | 41,6 | 33,6 | 17,5 | 52,3 | 28,5 | 40,0 | 25,4 | 25,7 | 32,4 |
| | urban | 14,9 | 34,8 | 52,5 | 14,0 | 9,1 | 2,1 | 0,1 | 1,3 | 2,9 |
| Bevölkerung (82.181.327) | insgesamt (Tausend) | 19.187,4 | 20.168,9 | 14.522,7 | 10.945,2 | 1.499,5 | 6.117,0 | 2.054,9 | 5.253,3 | 2.432,6 |
| | Anteilig in Prozent | 23,3 | 24,5 | 17,7 | 13,3 | 1,8 | 7,4 | 2,5 | 6,4 | 3,0 |
| | je Gemeinde (Tausend) | 15,2 | 81,7 | 363,1 | 7,7 | 6,2 | 2,7 | 1,0 | 2,4 | 3,2 |
| Hidden Champions (3.639) | insgesamt | 1091 | 851 | 323 | 635 | 84 | 201 | 27 | 217 | 210 |
| | Anteilig in Prozent | 30,0 | 23,4 | 8,9 | 17,4 | 2,3 | 5,5 | 0,7 | 6,0 | 5,8 |
| | je Gemeinde | 0,9 | 3,4 | 8,1 | 0,4 | 0,3 | 0,1 | 0,0 | 0,1 | 0,3 |
| Innovations- output | je 1.000 EW | 0,06 | 0,04 | 0,02 | 0,06 | 0,06 | 0,03 | 0,01 | 0,04 | 0,09 |
| | Patente* (Tausend) | 165,2 | 178,3 | 111,7 | 126,9 | 20,3 | 56,0 | 14,7 | 43,1 | 29,0 |
| | anteilig in Prozent | 22,2 | 23,9 | 15,0 | 17,0 | 2,7 | 7,5 | 2,0 | 5,8 | 3,9 |
| | je Gemeinde | 131,1 | 722,0 | 2791,7 | 89,5 | 83,8 | 24,4 | 7,2 | 19,4 | 37,7 |
| | je 1.000 EW | 8,6 | 8,8 | 7,7 | 11,6 | 13,5 | 9,1 | 7,2 | 8,2 | 11,9 |

Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d).

Bezogen auf die Bevölkerungsverteilung ist Regionstyp 2 mit knapp 20 Millionen Menschen (24,5 Prozent der Bevölkerung) der größte der neun. Im Verhältnis zur Gemeindezahl gilt Regionstyp 3 mit ca. 369.000 Menschen je Gemeinde als der am dichtesten besiedelte Regionstyp. Im Vergleich ist Regionstyp 7 je Gemeinde am dünnsten besiedelt. Hier leben ca. 1.000 Menschen je Gemeinde.

Es folgt in den nächsten Spalten die HC-Anzahl auf Regionstypenebene. Absolut betrachtet sind die meisten HCs in Regionstyp 1 verortet. Anteilig sind hier 30 Prozent der identifizierten Unternehmen situiert. Wird die HC-Anzahl je Gemeinde in den Vergleich einbezogen liegt sie mit 8,1 HCs je Gemeinde Regionstyp 3 auf Platz eins. Die geringste HC-Zahl je Gemeinde ist in Regionstyp 7 zu finden und liegt bei knapp 0,01. Im Verhältnis zur Bevölkerung ändert sich die Rangfolge erneut. Der Bundesdurchschnitt HCs je 1.000 EW liegt bei 0,04. Die meisten HCs je 1.000 EW nach Regionstypen sind in Regionstyp neun (0,09). Danach folgt Regionstyp 4 (0,06), Regionstyp 1 (0,06) und dann Regionstyp 5 (0,06). Die wenigsten HCs je EW weist Regionstyp 7 vor. Auf 1.000 EW kommen hier knapp 0,1 HCs.

Regionstypisierung

Der Innovationsoutput der Regionstypen variiert hier wiederum mehr. Die meisten Patentanmeldungen finden in Regionstyp 2 (ca. 180.000) und Regionstyp 1 (ca. 165.000) statt. Dies macht zusammen knapp 45 Prozent aller Anmeldungen aus. Bezogen auf die Gemeindezahl führt Regionstyp 3 mit ca. 2.800 Patentanmeldungen je Gemeinde klar die Tabelle an. Der niedrigste Durchschnittswert an Patenten je Gemeinde liegt in Regionstyp 7 vor. Bezogen auf die Bevölkerungszahl führt Regionstyp 5 mit knapp 13,5 Patenten je 1.000 EW. Die wenigsten Patente je 1.000 EW werden in Regionstyp 7 (7,2) angemeldet.

Tabelle 13 zeigt die deskriptiven Statistiken der neun Regionstypen an. Berücksichtigt werden in der Tabelle die sechs sozioökonomischen Faktoren aus der Hauptkomponentenanalyse sowie die Digitalisierung und die Ländlichkeit-Variablen. Aufgeführt werden die Mittelwerte, die Standardabweichungen und die Varianz. Außerdem wurden Minimal- (Min.) und Maximalausprägungen (Max.) erfasst. Auffällig sind die hohen Ausprägungen der einzelnen Variablen in Regionstyp 3. Dieser ist wie in Tabelle 13 erfasst der bevölkerungsreichste Regionstyp. 50 Prozent seiner Gemeinden liegen in urbanen Kreisen, was die hohen Ausprägungen und die starke Varianz und Standardabweichungen erklären kann.

Regionstypisierung

Tabelle 13: Deskriptive Statistik der Regionstypen

| | | F01 | F02 | F03 | F04 | F05 | F06: | Digitalisierung | Ländlichkeit |
|----------------------------|---------|-------|-------|--------|--------|-------|--------|-----------------|--------------|
| Deutschland (10.552) | Min. | -5,33 | -2,16 | -1,48 | -1,69 | -4,02 | -21,07 | -4,54 | 0,00 |
| | Max. | 9,27 | 10,69 | 86,77 | 50,92 | 42,30 | 33,59 | 1,12 | 1,00 |
| | MW | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,47 | 0,20 |
| | SAB | 1,00 | 1,00 | 1,00 | 1,00 | 1,00 | 1,00 | 0,43 | 0,13 |
| | Varianz | 1,00 | 1,00 | 1,00 | 1,00 | 1,00 | 1,00 | 0,18 | 0,02 |
| Regionstyp 1 (1.260) | Min. | -1,21 | -1,79 | -0,72 | -0,91 | -1,95 | -2,47 | -1,78 | 0,00 |
| | Max. | 7,31 | 3,49 | 0,24 | 0,10 | 1,90 | 4,84 | 1,12 | 0,61 |
| | MW | 1,29 | 0,01 | -0,14 | -0,23 | 0,15 | 0,61 | 0,30 | 0,24 |
| | SAB | 1,23 | 0,89 | 0,14 | 0,15 | 0,63 | 1,15 | 0,51 | 0,09 |
| | Varianz | 1,50 | 0,80 | 0,02 | 0,02 | 0,39 | 1,32 | 0,26 | 0,01 |
| Regionstyp 2 (247) | Min. | -1,75 | -1,56 | -0,60 | -0,98 | -1,71 | -1,50 | -3,00 | 0,00 |
| | Max. | 8,43 | 2,58 | 2,46 | 13,07 | 2,89 | 3,19 | 0,96 | 0,43 |
| | MW | 2,19 | -0,23 | 0,21 | 2,47 | 0,18 | 0,72 | -0,14 | 0,27 |
| | SAB | 1,77 | 0,78 | 0,59 | 2,54 | 0,68 | 0,76 | 0,91 | 0,06 |
| | Varianz | 3,12 | 0,60 | 0,34 | 6,47 | 0,46 | 0,58 | 0,84 | 0,00 |
| Regionstyp 3 (40) | Min. | -5,33 | -1,74 | -1,48 | -1,69 | -1,34 | -21,07 | -4,54 | 0,04 |
| | Max. | 9,27 | 10,36 | 86,77 | 50,92 | 42,30 | 33,59 | 0,89 | 0,64 |
| | MW | 1,89 | 0,40 | 5,12 | 7,12 | 4,71 | -0,59 | -0,76 | 0,31 |
| | SAB | 3,80 | 2,00 | 15,43 | 11,55 | 9,93 | 8,27 | 1,55 | 0,13 |
| | Varianz | 14,44 | 3,99 | 237,97 | 133,33 | 98,52 | 68,45 | 2,41 | 0,02 |
| Regionstyp 4 (1.418) | Min. | -1,26 | -1,90 | -0,33 | -0,34 | -1,21 | -1,69 | -1,37 | 0,00 |
| | Max. | 2,08 | 0,63 | 0,15 | 0,05 | 1,12 | 1,38 | 1,12 | 1,00 |
| | MW | 0,36 | -0,78 | -0,09 | -0,14 | 0,01 | -0,12 | 0,26 | 0,26 |
| | SAB | 0,54 | 0,41 | 0,08 | 0,07 | 0,37 | 0,48 | 0,42 | 0,11 |
| | Varianz | 0,29 | 0,17 | 0,01 | 0,00 | 0,14 | 0,23 | 0,18 | 0,01 |
| Regionstyp 5 (242) | Min. | -2,18 | -1,50 | -0,79 | -1,06 | -4,02 | -8,29 | -1,78 | 0,00 |
| | Max. | 8,10 | 10,69 | 0,54 | 0,56 | 10,17 | 14,40 | 1,12 | 0,78 |
| | MW | 0,93 | 1,49 | -0,12 | -0,18 | 2,08 | 0,38 | 0,47 | 0,23 |
| | SAB | 1,64 | 2,68 | 0,20 | 0,26 | 2,31 | 3,69 | 0,51 | 0,13 |
| | Varianz | 2,69 | 7,17 | 0,04 | 0,07 | 5,35 | 13,58 | 0,26 | 0,02 |
| Regionstyp 6 (2.295) | Min. | -1,21 | -2,16 | -0,34 | -0,27 | -1,18 | -1,02 | -1,37 | 0,00 |
| | Max. | 1,02 | 2,74 | 0,14 | 0,06 | 0,52 | 1,00 | 1,12 | 1,00 |
| | MW | -0,18 | -0,27 | -0,04 | -0,09 | -0,40 | 0,07 | 0,51 | 0,18 |
| | SAB | 0,38 | 0,72 | 0,07 | 0,05 | 0,28 | 0,31 | 0,32 | 0,13 |
| | Varianz | 0,14 | 0,51 | 0,00 | 0,00 | 0,08 | 0,10 | 0,10 | 0,02 |
| Regionstyp 7 (2.017) | Min. | -1,48 | -1,75 | -0,05 | -0,14 | -1,00 | -0,77 | -0,51 | 0,00 |
| | Max. | 0,10 | 2,74 | 0,19 | 0,09 | 0,12 | 0,61 | 1,12 | 1,00 |
| | MW | -0,71 | 0,27 | 0,08 | -0,02 | -0,48 | -0,02 | 0,62 | 0,12 |
| | SAB | 0,22 | 0,78 | 0,04 | 0,04 | 0,22 | 0,21 | 0,26 | 0,14 |
| | Varianz | 0,05 | 0,61 | 0,00 | 0,00 | 0,05 | 0,04 | 0,07 | 0,02 |
| Regionstyp 8 (2.227) | Min. | -1,43 | -2,11 | -0,17 | -0,22 | -0,90 | -1,69 | -0,91 | 0,00 |
| | Max. | 0,83 | 4,12 | 0,20 | 0,19 | 1,09 | 1,27 | 1,12 | 1,00 |
| | MW | -0,46 | 0,41 | 0,02 | -0,02 | 0,09 | -0,21 | 0,61 | 0,20 |
| | SAB | 0,31 | 1,01 | 0,06 | 0,06 | 0,34 | 0,48 | 0,30 | 0,12 |
| | Varianz | 0,09 | 1,01 | 0,00 | 0,00 | 0,12 | 0,23 | 0,09 | 0,01 |
| Regionstyp 9 (769) | Min. | -1,50 | -1,76 | -0,40 | -0,36 | -1,66 | -3,99 | -0,91 | 0,00 |
| | Max. | 1,37 | 2,72 | 0,24 | 0,25 | 3,93 | 1,12 | 1,12 | 0,67 |
| | MW | -0,12 | -0,10 | -0,04 | -0,08 | 1,01 | -0,64 | 0,54 | 0,24 |
| | SAB | 0,53 | 0,79 | 0,10 | 0,10 | 0,77 | 0,84 | 0,34 | 0,12 |
| | Varianz | 0,28 | 0,63 | 0,01 | 0,01 | 0,59 | 0,71 | 0,12 | 0,02 |

Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Küpper (2016).

Regionstypisierung

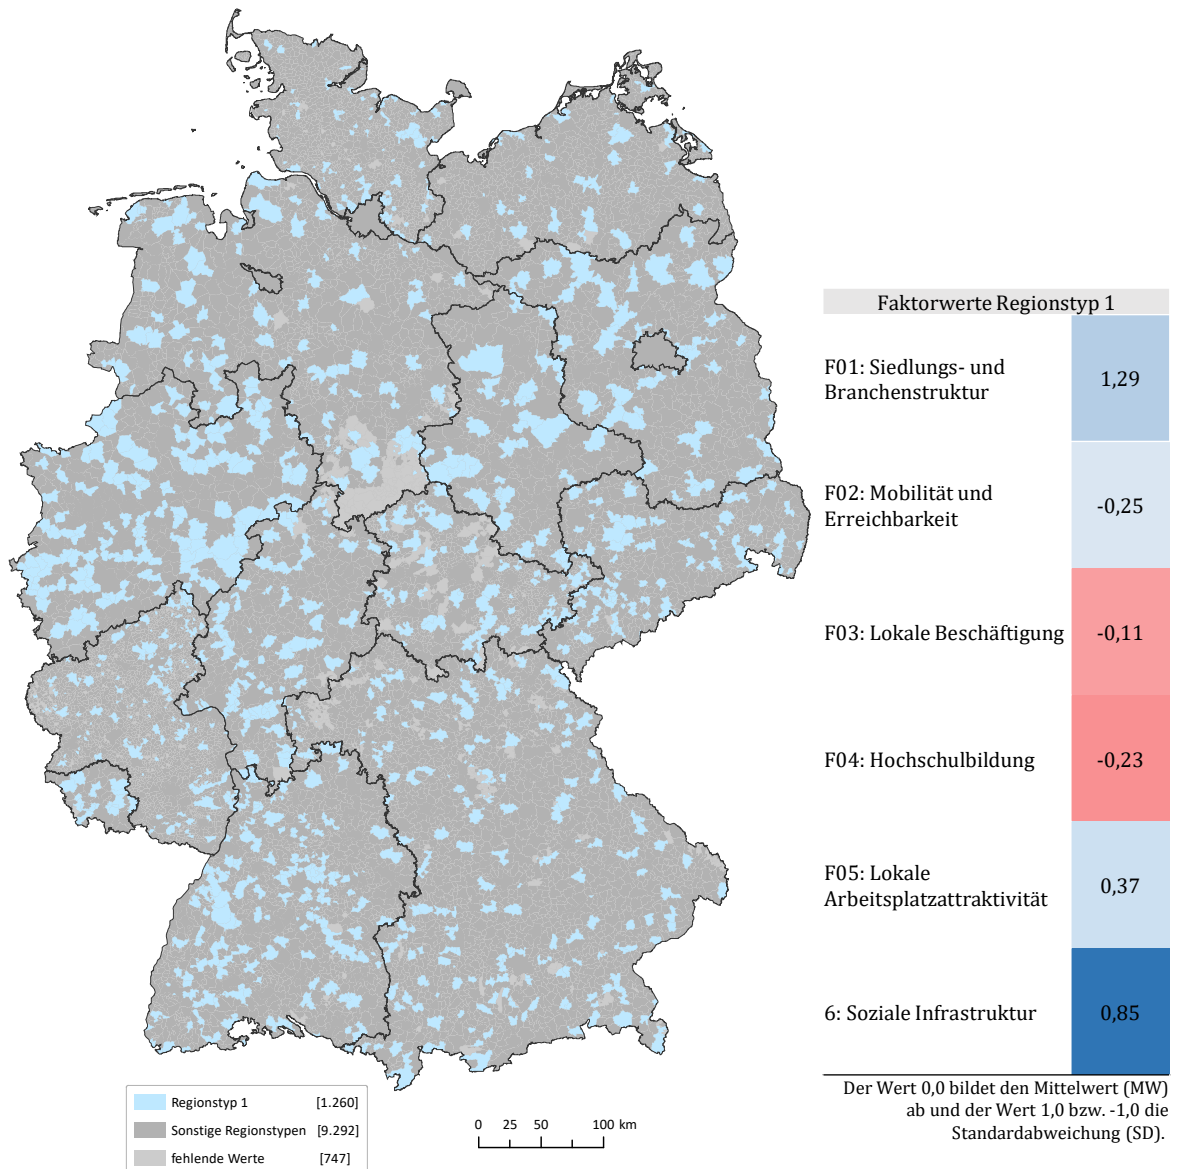
Um die räumliche Verteilung der Regionstypen zu veranschaulichen, wurde für jeden Regionstyp eine Karte erstellt. Um die sozioökonomische Struktur der Typen weiterführend zu erörtern, werden die Ausprägungen der sozioökonomischen Faktoren aus der HKA beschrieben. Ausgehend vom Mittelwert aller Gemeinden (0,0) sind die durchschnittlichen Werte der sechs Faktoren für jeden Regionstyp tabellarisch aufgeführt. Die Einfärbung der Tabellenzellen erfolgt im Verhältnis zu den jeweiligen Faktorwerten der anderen Regionstypen. Dunkelblau bedeutet, dass der Wert im Vergleich zu den anderen Regionstypen für den entsprechenden Faktor als hoch einzustufen ist. Dunkelrot bedeutet, dass der Faktor in dem betrachteten Regionstyp im Vergleich zu den anderen Typen schwächer abschneidet.

Zunächst zu Regionstyp 1 dessen räumliche Verteilung in Abbildung 17 dargestellt ist. Knapp 85 Prozent der Kreise, in welchen die Gemeinden des Typs liegen, werden durch das Thünen-Institut als ländlich oder eher ländlich kategorisiert. (Küpper 2016, S.9). Knapp 23 Prozent der deutschen Bevölkerung sind hier angesiedelt. Hier leben doppelt so viele Menschen je Gemeinde wie im Bundesdurchschnitt (ca. 7.800 Menschen je Gemeinde). Absolut gesehen hat der Regionstyp die meisten HCs vorzuweisen. In Bezug auf die HCs je 1.000 EW liegt der Wert über dem Bundesdurchschnitt (0,04) bei knapp 0,06. Der Innovationsoutput je 1.000 EW liegen mit 8,6 im Mittelfeld der Regionstypen.

Die Siedlungs- und Branchenstruktur von Regionstyp 1 liegt deutlich über einer Standardabweichung vom deutschen Durchschnitt. Auch die Mobilität und Erreichbarkeit der zugehörigen Gemeinden ist überdurchschnittlich gut, im Vergleich zu den anderen Regionstypen liegt sie im Mittelfeld. Die lokale Beschäftigung in den Gemeinden ist etwas unterdurchschnittlich ähnlich wie die Hochschulbildung. Beide Faktoren liegen wie ein der roten Einfärbung zu erkennen im Vergleich mit den anderen Regionstypen im unteren Mittelfeld. Währenddessen ist die lokale Arbeitsplatzattraktivität in den Gemeinden überdurchschnittlich hoch und die soziale Infrastruktur die Beste im Vergleich zu den anderen Regionstypen. Die räumliche Verteilung von Regionstyp 1 ist sehr flächendeckend. Der Regionstyp ist in jedem der 16 Bundesländer vertreten. Im Norden von Schleswig-Holstein und Mecklenburg-Vorpommern ist der Typ weniger häufig vorzufinden. Beispielhaft gehören die Städte Andernach, Bad Ems und Baden-Baden oder die Gemeinden Glottertal und Karlsbad zum Regionstyp 1.

Regionstypisierung

Abbildung 17: Räumliche Verteilung Regionstyp 1



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung


Abbildung 18 lokalisiert Gemeinden des Regionstyps 2. Dieser ist der ist der drittkleinste identifizierte sozioökonomische Raumtyp. Knapp 2,3 Prozent aller Gemeinden konnten ihm zugeordnet werden. Die Differenzierung der Ländlichkeit ergab, dass jeweils ca. ein Drittel der Gemeinden in ländlichen, eher ländlichen oder urbanen Kreisen liegt (Küpper 2016). Der Regionstyp ist der Bevölkerungsstärkste. Knapp 20.100 EW sind hier niedergelassen. Für die Kennziffer EW je Gemeinde des Regionstyps belegt er den zweiten Platz mit knapp 82.000 EW je Gemeinde. 23 Prozent aller HCs sind hier verortet. Je 10.000 EW liegt dieser Wert im bundesschnitt bei 0,04. Es handelt sich bei Regionstyp 2 um den Regionstyp mit den absolut gesehen, meisten Patenten (178.000). Je 1.000 EW liegt der Regionstyp mit 8,8 genau im Mittelfeld aller Typen.

Die Faktorwerte des Regionstyps sind ausschließlich überdurchschnittlich hoch. Im Typenvergleich weist er mit 2,43 die zweithöchste Siedlungs- und Branchenstruktur auf. Bezüglich der Mobilität und Erreichbarkeit liegen seine Gemeinden durchschnittlich im vorderen Mittelfeld. Die lokale Beschäftigung ist leicht über dem deutschen Durchschnitt, während die mittlere Hochschulbildung den zweit höchsten Wert aller Regionstypen aufzeigt. Neben Regionstyp 3 ist Regionstyp 2 der einzige Typ, welcher hier überdurchschnittlich abschneidet. Die lokale Arbeitsplatzattraktivität liegt nah am Bundesdurchschnitt (0,14) während die soziale Infrastruktur den zweithöchsten Wert (0,71) aller Regionstypen abbildet.

Bei Betrachtung der Karte in Abbildung 18 zeigt sich, dass der Regionstyp vor allem in der geographischen Mitte mit Tendenz gen Westen zu finden ist. Auch in Baden-Württemberg, Bayern und Sachsen-Anhalt ist er zu finden. Währenddessen lässt sich sagen, dass im Norden Deutschlands weniger häufig in diesem Regionstyp aufzufinden ist. Ein Blick in die Daten zeigt, dass überwiegend Städte in diesem Regionstyp aufzufinden sind. Dazu gehören beispielsweise Aachen, Bad Hersfeld, Fulda, Gera, Halle (Saale) oder Ingolstadt.

Regionstypisierung

Abbildung 18: Räumliche Verteilung Regionstyp 2



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

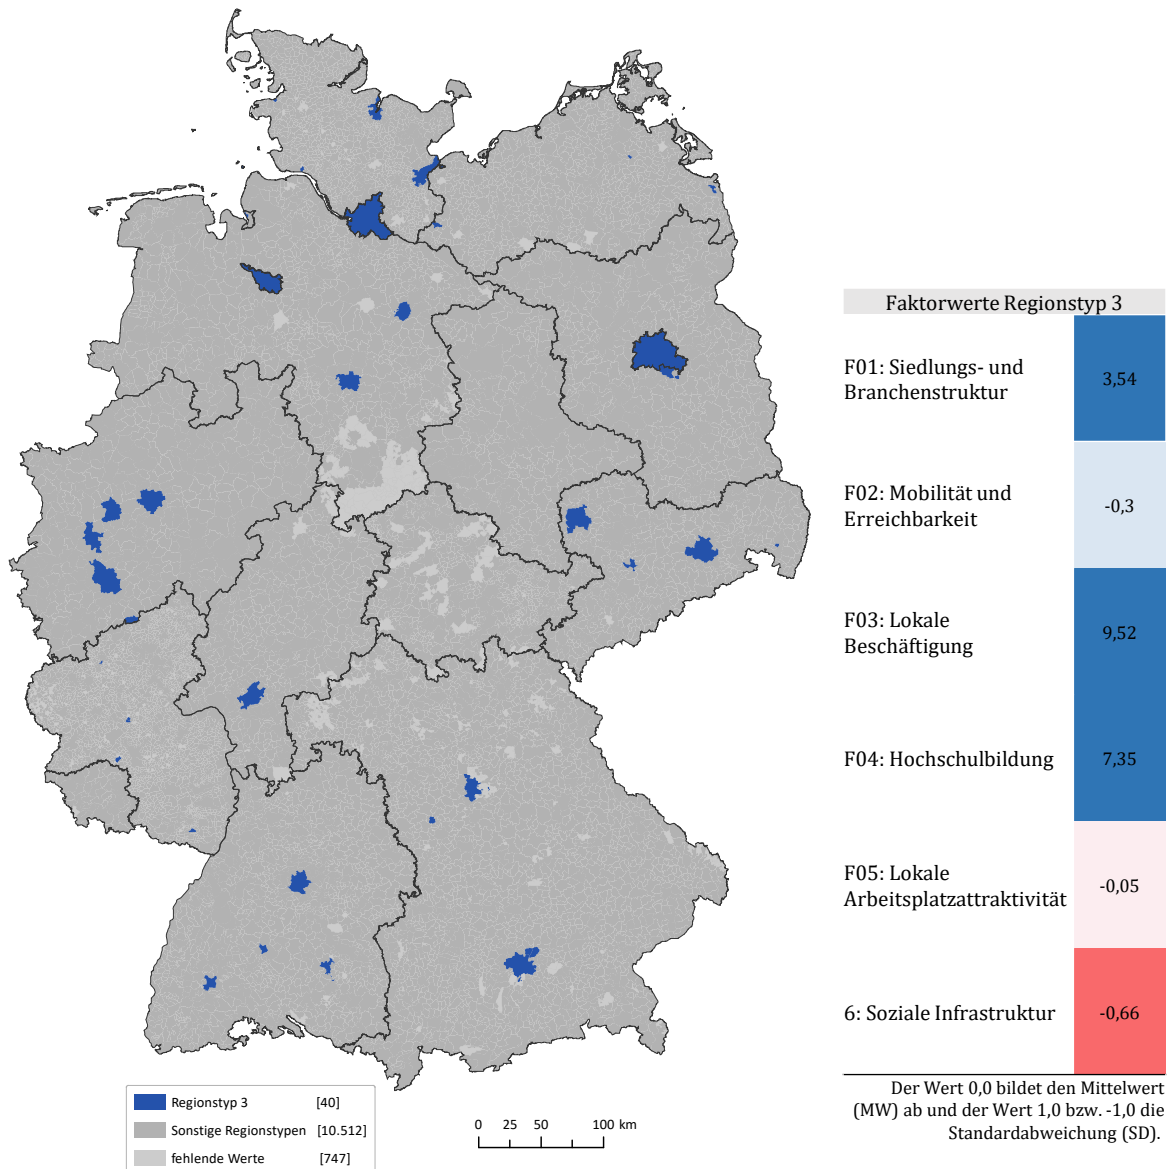
Der Regionstyp 3 ist, wie bereits beschrieben, der mit den meisten Gemeinden, welche in urbanen Kreisen liegen. Über die Hälfte der 40 Gemeinden ist dieser Kategorie zugeordnet. Es ist der Regionstyp mit den meisten Einwohnenden je Gemeinde. Mit durchschnittlich 363.000 Einwohnenden liegt der Wert weit über dem Bundesdurchschnitt (7.800). 323 der 3.654 HCs sind hier verortet. Je 1.000 EW ist die 0,02 im hinteren Mittelfeld im Regionstypenvergleich. Bezogen auf die 7,7 Patentanmeldungen je 1.000 EW liegt der Regionstyp an vorletzter Position.

Die Siedlungs- und Branchenstruktur liegt drei Standardabweichungen über dem Mittelwert aller deutschen Gemeinden (3,54). Dies ist der höchste Wert im Regionstypenvergleich. Die Mobilität und Erreichbarkeit des urbanen Regionstypen 3 ist die zweit höchste aller Regionstypen (-0,30). Ein Blick auf den Wert der lokalen Beschäftigung zeigt, dass diese ebenfalls überdurchschnittlich hoch ist. Diese ist mit Abstand der höchste Wert aller Regionstypen. 9,52 Standardabweichungen über dem Mittelwert. Ähnlich überdurchschnittlich ist der Regionstyp in Bezug auf die Hochschulbildung. Mit 7,35 gehört er zusammen mit Regionstyp 2 zu den zwei Typen, welche im Schnitt über dem Bundesmittel liegen. Bezogen auf die Lokale Arbeitsplatzattraktivität gilt dies nicht. Mit -0,05 ist Regionstyp 3 an drittletzter Position bezogen auf den Regionstypenvergleich. Der Wert liegt jedoch sehr nah am Mittelwert 0,0. Der Faktor der sozialen Infrastruktur belegt den hintersten Platz im Vergleich mit den anderen acht Typen. Die Gemeinden des Regionstyps 3 weisen mit -0,66 einen unterdurchschnittlich niedrigen Wert auf.

Bei Betrachtung der Karte in Abbildung 19 wird deutlich, dass in diesem Regionstyp vor allem Großstädte wie Berlin, Bremen, Hamburg, München, Stuttgart und Köln zu finden sind. Dies ist jedoch nicht ausschließlich der Fall. Gemeinden wie das rheinlandpfälzische Nürburg oder die Insel Helgoland sind hier ebenfalls aufgeführt.

Regionstypisierung

Abbildung 19: Räumliche Verteilung Regionstyp 3



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

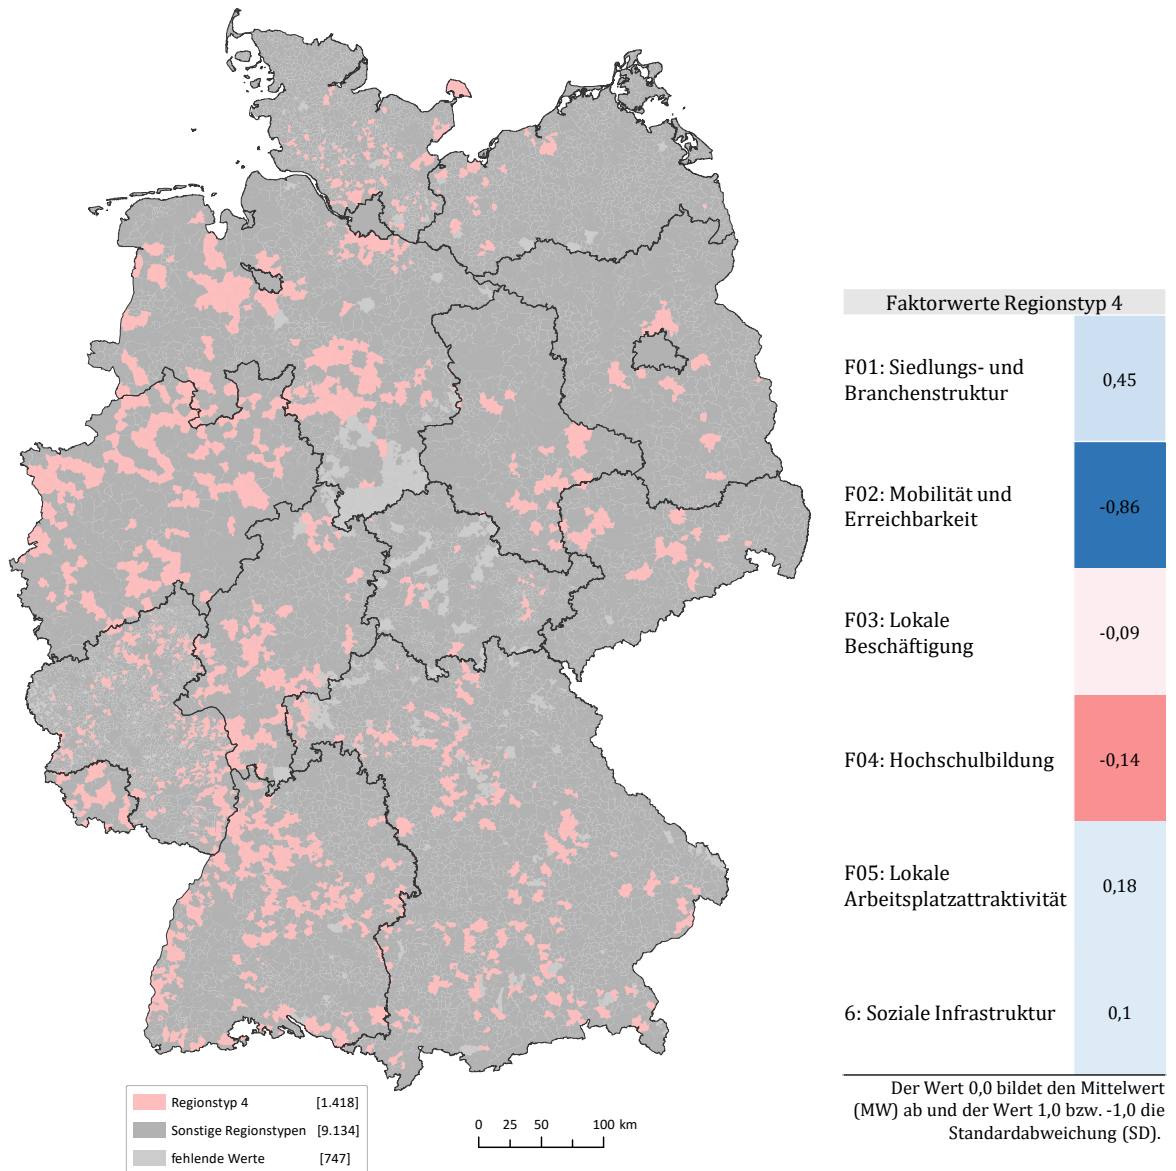
Regionstypisierung

Dem Regionstyp 4 wurden 1.418 Gemeinden zugeordnet. Die knapp 13,8 Prozent aller deutschen Gemeinden liegen überwiegend in eher ländlichen Kreisen (52 Prozent). Mit knapp 7.700 EW je Gemeinde liegt die Bevölkerungsdichte ganz im Bundesschnitt je Gemeinde. 17,4 Prozent aller HCs sind im Regionstyp angesiedelt. Mit 0,06 HCs je 1.000 EW liegt der Wert deutlich über dem Bundesdurchschnitt von 0,04. Auch die Patentanmeldungen sind überdurchschnittlich hoch. Der Regionstyp belegt im Vergleich mit den anderen acht den dritten Platz mit 11,6 Patenten je 1.000 EW.

Die Siedlungs- und Branchenstruktur ist überdurchschnittlich hoch (0,45) und die Mobilität und Erreichbarkeit die Beste im Vergleich zu den anderen Regionstypen. Die lokale Beschäftigung ist jedoch die drittniedrigste mit -0,09 und somit leicht unterdurchschnittlich. Die Hochschulbildung liegt ebenfalls unter dem Mittelwert aller Gemeinden und mit -0,14 wieder an drittletzter Position. Der Faktor lokale Arbeitsplatzattraktivität ist überdurchschnittlich hoch (0,18) und auch die soziale Infrastruktur liegt leicht über dem Mittel aller Gemeinden (0,1). Die zwei letzten Faktoren sind außerdem im Mittelfeld der Werte der anderen Regionstypen einzuordnen.

Die Verortung der Gemeinden von Regionstyp 4 sind in Abbildung 20 dargestellt. Ein leichter Überhang im Westen wird deutlich. In Thüringen, dem Norden Sachsen-Anhalts und Brandenburgs, sowie im Osten von Mecklenburg-Vorpommern sind eher weniger Gemeinden des Regionstyps 4 vorzufinden. Bei der Betrachtung der restlichen Bundesländer wird deutlich, dass diese vor allem im Umland von Ballungsräumen auftreten. Beispielsweise im Raum Stuttgart oder München, in Hessen im Rhein-Main Gebiet oder bei Hannover. Einige der Gemeinden aus Regionstyp 4 sind das hessische Linden, Lohmar im Umland von Köln, Ulmen in Rheinland-Pfalz oder Achim als Nachbargemeinde von Bremen.

Abbildung 20: Räumliche Verteilung Regionstyp 4



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d), Geodaten: BKG (2016).

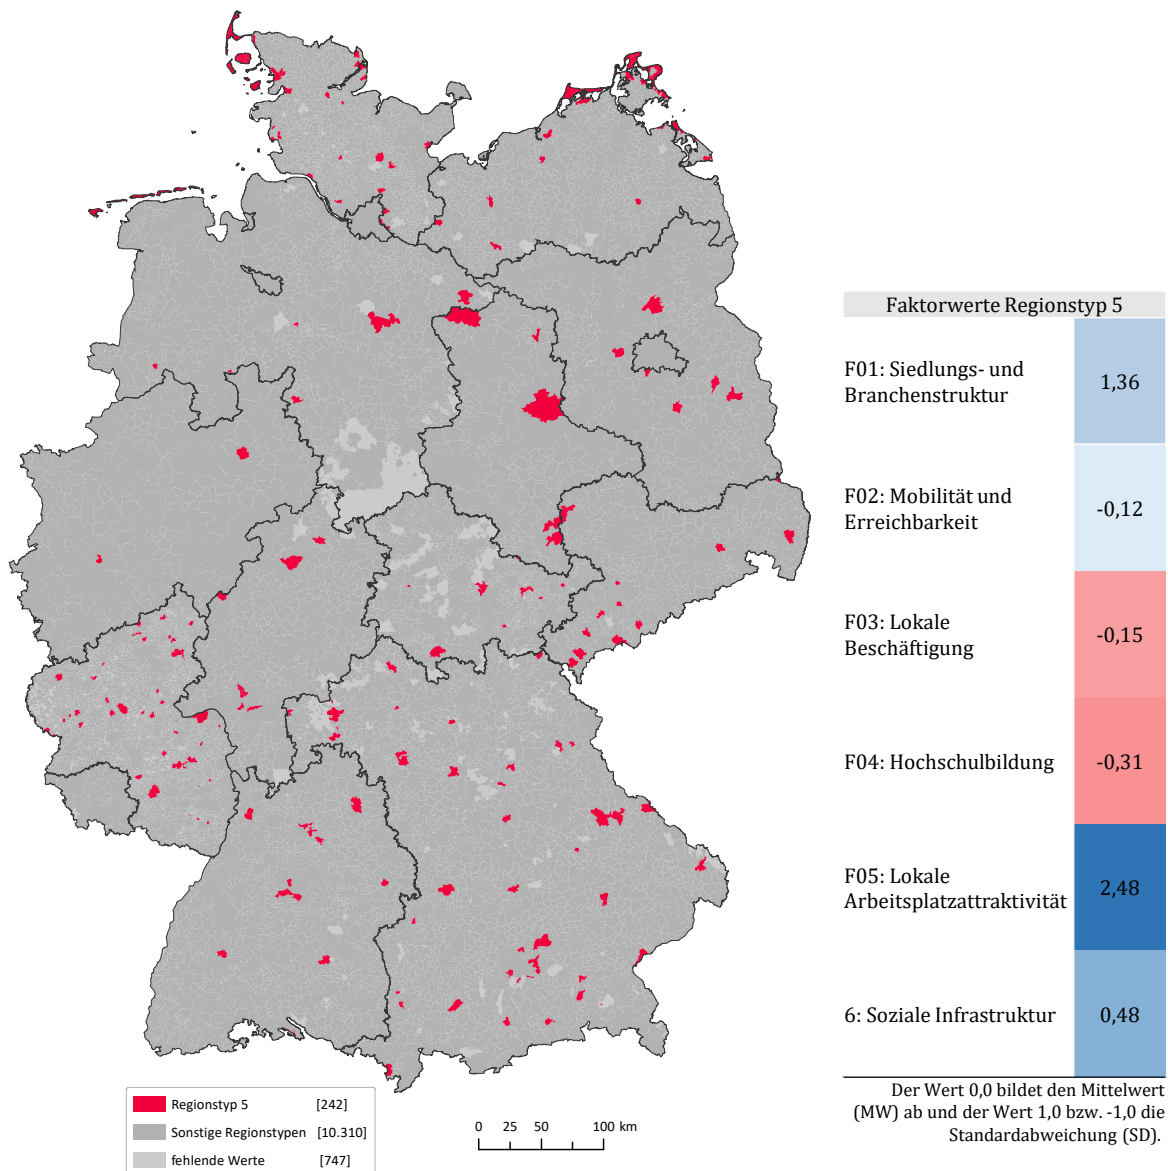
Regionstypisierung

Regionstyp 5 ist mit 242 Gemeinden ähnlich groß wie Regionstyp 2. Über 90 Prozent seiner Gemeinden liegen in Kreisen die als ländlich (62,4 Prozent) oder eher ländlich (28,5 Prozent) kategorisiert sind (Küpper 2016). Absolut gesehen leben hier die wenigsten Menschen (1,5 Millionen). Je Gemeinde ist der Wert mit 6,2 leicht unter dem deutschen Durchschnitt. 2,3 Prozent aller HCs sind hier verortet (84), was für diesen Regionstypen 0,06 HCs je 1.000 EW bedeutet. Die Digitalisierung liegt minimal unter dem Bundesdurchschnitt, der Innovationsoutput jedoch an dritt höchster Position im Vergleich zu den anderen Regionstypen.

Die Siedlungs- und Branchenstruktur innerhalb von Regionstyp 5 ist überdurchschnittlich hoch. Mit einem Wert von über einer Standardabweichung des Bundesmittels liegt sie im Typenvergleich an dritthöchster Position. Die Mobilität und Erreichbarkeit ist mit einem durchschnittlichen Faktorwert von -0,12 leicht überdurchschnittlich. Der Faktorwert der lokalen Beschäftigung ist mit -0,15 unterdurchschnittlich. Regionstyp 5 weist den niedrigsten Durchschnittswert im Vergleich zu den anderen acht auf. Ähnlich ist es bei der Hochschulbildung. Mit -0,31 hat Regionstyp 5 die niedrigste Hochschulbildung im Bundesvergleich. Die lokale Arbeitsplatzattraktivität ist jedoch die beste im Vergleich. Mit 2,48 hat Regionstyp 5 hier einen deutlich überdurchschnittlichen Faktorwert vorzuweisen. Der Wert der sozialen Infrastruktur liegt im überdurchschnittlichen Mittelfeld (0,48).

Ein Blick in die Daten zeigt, dass im Regionstyp viele Kleinstädte wie Bredstedt in Nordfriesland, Penzberg in Oberbayern, Zell (Mosel) in Rheinlandpfalz oder Stadtroda in Thüringen vertreten sind. Vereinzelt sind auch größere Kreisstädte im Regionstypen zu finden. Darunter beispielsweise Dingolfing in Niederbayern oder Teltow in Brandenburg. Gemeinden wie Heiligenroth in Rheinland-Pfalz, die Insel Norderney oder Pellworm gehören ebenfalls zum Regionstyp 5. Die Karte in Abbildung 21 zeigt, dass der Regionstyp im gesamten Bundesgebiet vertreten ist. Stärker im Süden, Osten und Nordosten des Landes. In NRW und Niedersachsen tritt der Regionstyp nur sehr vereinzelt auf.

Abbildung 21: Räumliche Verteilung Regionstyp 5



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

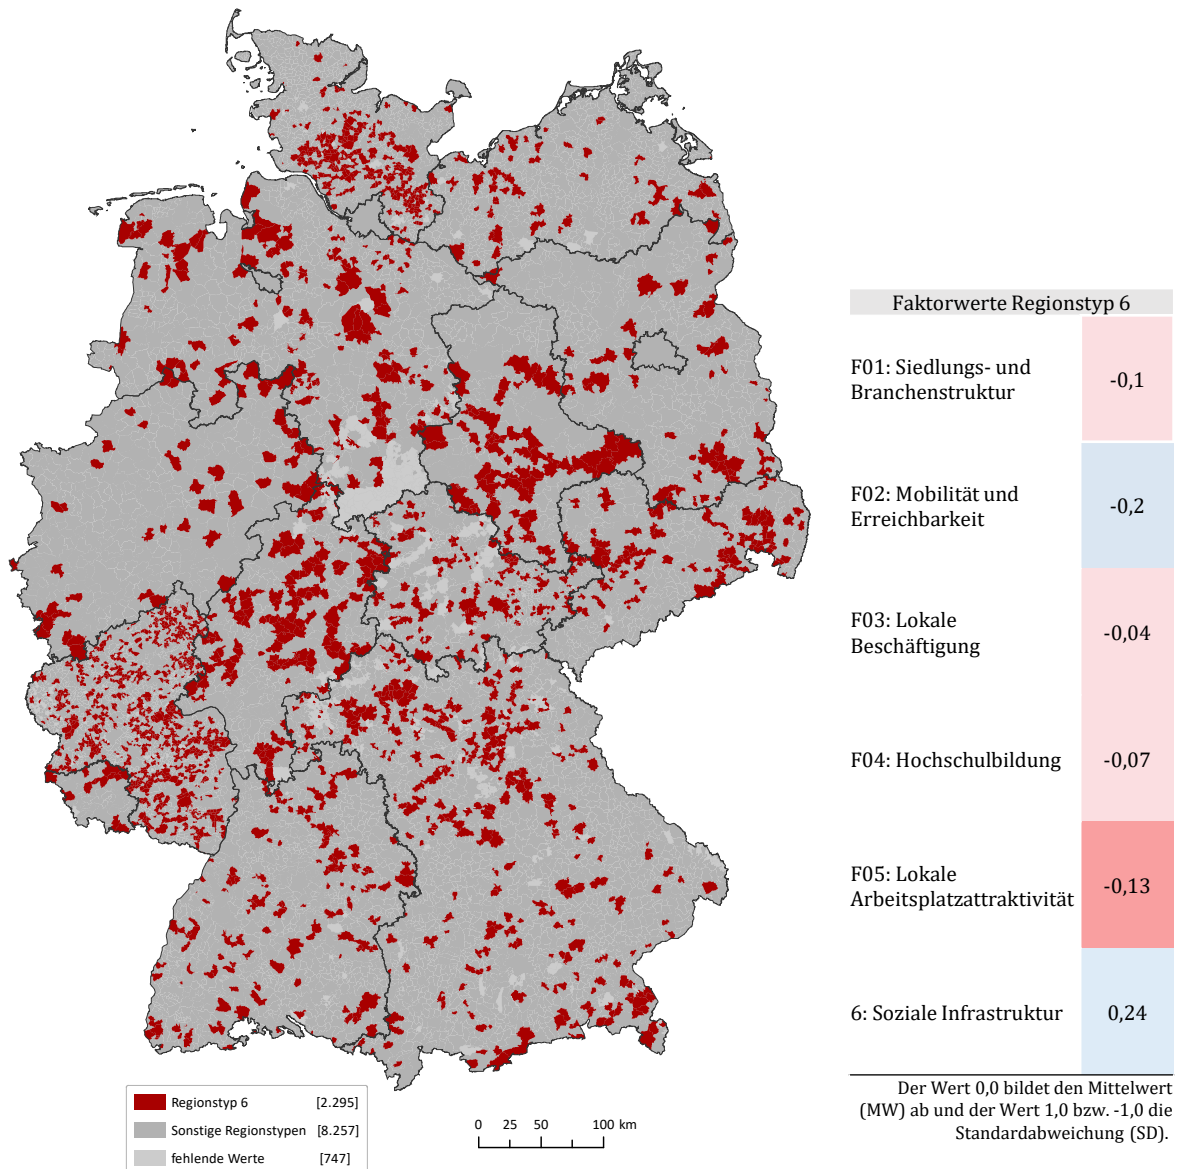
Der größte der Regionstypen ist Regionstyp 6. 2.295 Gemeinden sind hier inbegriffen. Knapp 98 Prozent dieser Gemeinden gehören zu Kreisen welche als ländlich (57,8 Prozent) oder eher ländlich (40 Prozent) eingestuft werden. Dies ist der Regionstyp mit der drittniedrigsten Bevölkerung je Gemeinde von 2.700 Menschen. 201 HCs sind im Regionstyp 6 angesiedelt, was 0,03 HCs je 1.000 EW ergibt. Der Digitalisierung ist leicht unter dem Durchschnitt mit 0,2, während der Innovationsoutput im Mittelfeld der neun Regionstypenwerte liegt.

Bezüglich der Siedlungs- und Branchenstruktur ist Regionstyp 6 leicht unterdurchschnittlich. Die Mobilität und Erreichbarkeit jedoch liegt im überdurchschnittlich guten Bereich im bundesweiten Vergleich (-0,2). Die lokale Beschäftigung in den entsprechenden Gemeinden ist nah am Bundesmittel, jedoch leicht unterdurchschnittlich mit -0,04. Ähnlich sieht es für die Hochschulbildung mit -0,07 aus. Die lokale Arbeitsplatzattraktivität ist an drittletzter Position im Vergleich zu den anderen Regionstypen (-0,13). Die soziale Infrastruktur ist mit 0,24 als überdurchschnittlich gut zu beschreiben. Im Vergleich mit den anderen Regionstypen liegt der Schnitt des Regionstyps 6 hier im Mittelfeld.

In Abbildung 22 ist der Regionstyp 6 auf einer Karte dargestellt. Der Typ ist in allen Bundesländern häufig vertreten. Hier jedoch überwiegend in weniger eng besiedelten Räumen. Bei knapp 10 Prozent der Gemeinden aus Regionstyp 6 handelt es sich um Kleinstädte wie das hessische Allendorf, Bacherach in Rheinland-Pfalz oder Hollfeld in Bayern. Weitere Beispielhafte Gemeinden sind Blumenthal in Schleswig-Holstein, Tiste in Niedersachsen oder Stetten in Baden-Württemberg.

Regionstypisierung

Abbildung 22: Räumliche Verteilung Regionstyp 6



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

Regionstypisierung

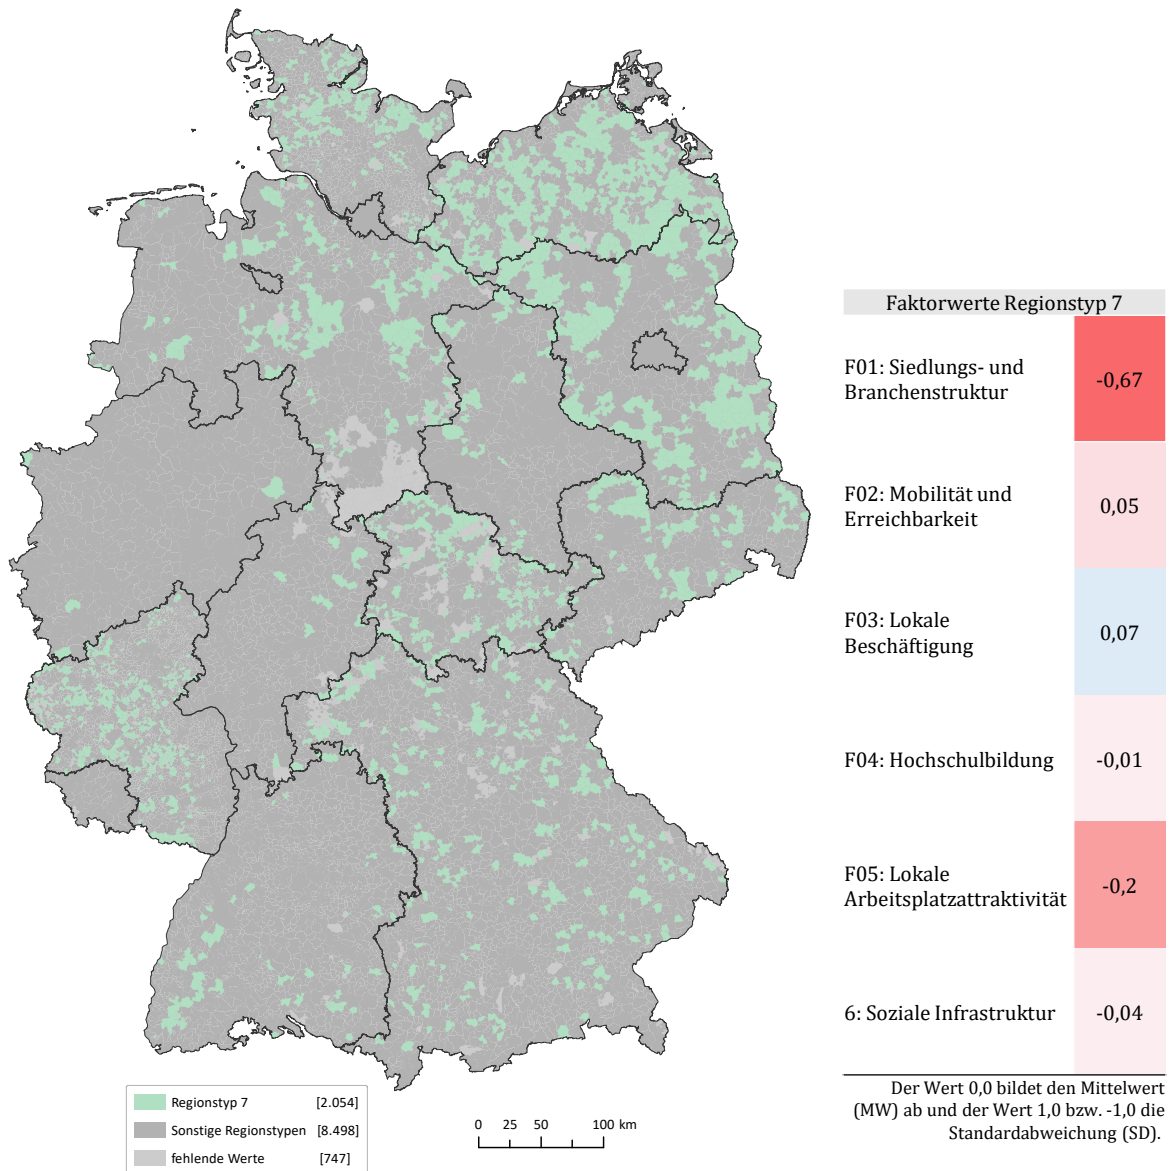
2.045 Gemeinden gehören dem Regionstyp 7 an. Diese sind in der Karte in Abbildung 24 dargestellt. 99,9 Prozent der Gemeinden liegen in Kreisen die als ländlich (74,5 Prozent) oder eher ländlich (25,4 Prozent) kategorisiert werden (Küpper 2016). Damit ist dieser Regionstyp der ländlichste aller neun. Ca. 2 Millionen Menschen leben hier, was knapp 1.000 EW je Gemeinde ausmacht. Nur 27 HCs sind in diesem Regionstyp angesiedelt. Das ergibt im Durchschnitt 0,01 HCs je 1.000 EW. Die Digitalisierung ist die niedrigste im Vergleich zu den anderen Regionstypen (0,1) und auch der Innovationsoutput ist mit 7,2 Patenten je 1.000 EW der geringste.

Regionstyp 7 weist im Vergleich zu den anderen acht die durchschnittlich niedrigsten Faktorwerte der Siedlungs- und Branchenstruktur vor (-0,67). Die Mobilität und Erreichbarkeit ist die zweitniedrigste und liegt knapp am Bundesmittel mit 0,05. Sie ist damit einer von zwei Fällen in denen die Mobilität unterdurchschnittlich ist. Die lokale Beschäftigung ist mit 0,07 leicht über dem Mittelwert ähnlich wie die Hochschulbildung in den Gemeinden welche mit -0,01 minimal unter dem Bundesmittel liegt. Die lokale Arbeitsplatzattraktivität in Regionstyp 7 ist die niedrigste im Vergleich zu allen anderen Regionstypen. Die soziale Infrastruktur liegt wiederum nur leicht unter dem Mittelwert mit -0,04.

Abbildung 23 zeigt die räumliche Verteilung der Gemeinden des Regionstyps 7. Dieser Regionstyp scheint überwiegend im Nord-Osten Deutschlands vertreten zu sein. Abgesehen von Sachsen-Anhalt sind viele Gemeinden in Thüringen, Brandenburg, Mecklenburg-Vorpommern, dem nördlichen Schleswig-Holstein sowie dem östlichen Niedersachsen einzuordnen. Auch in Bayern und Rheinland-Pfalz ist der Regionstyp häufig vorzufinden. Deutlich wird die periphere Lage der Gemeinden, wenn man die Karte wieder vor dem Hintergrund von Ballungsräumen beispielsweise den Metropolregionen betrachtet. Der Regionstyp kommt selten bis nicht im Rhein-Main Gebiet, Rhein-Ruhr oder Rhein-Neckar Gebiet vor. Auch in der Region Hannover oder um Berlin ist er nicht anzutreffen. Beispielhaft zu nennen sind die Gemeinden Bengel oder Kaschenbach in Rheinland Pfalz, Cramme im Kreis Wolfenbüttel in Niedersachsen, Jatznick in Mecklenburg-Vorpommern oder Kasseedorf in Schleswig-Holstein.

Regionstypisierung

Abbildung 23: Räumliche Verteilung Regionstyp 7



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

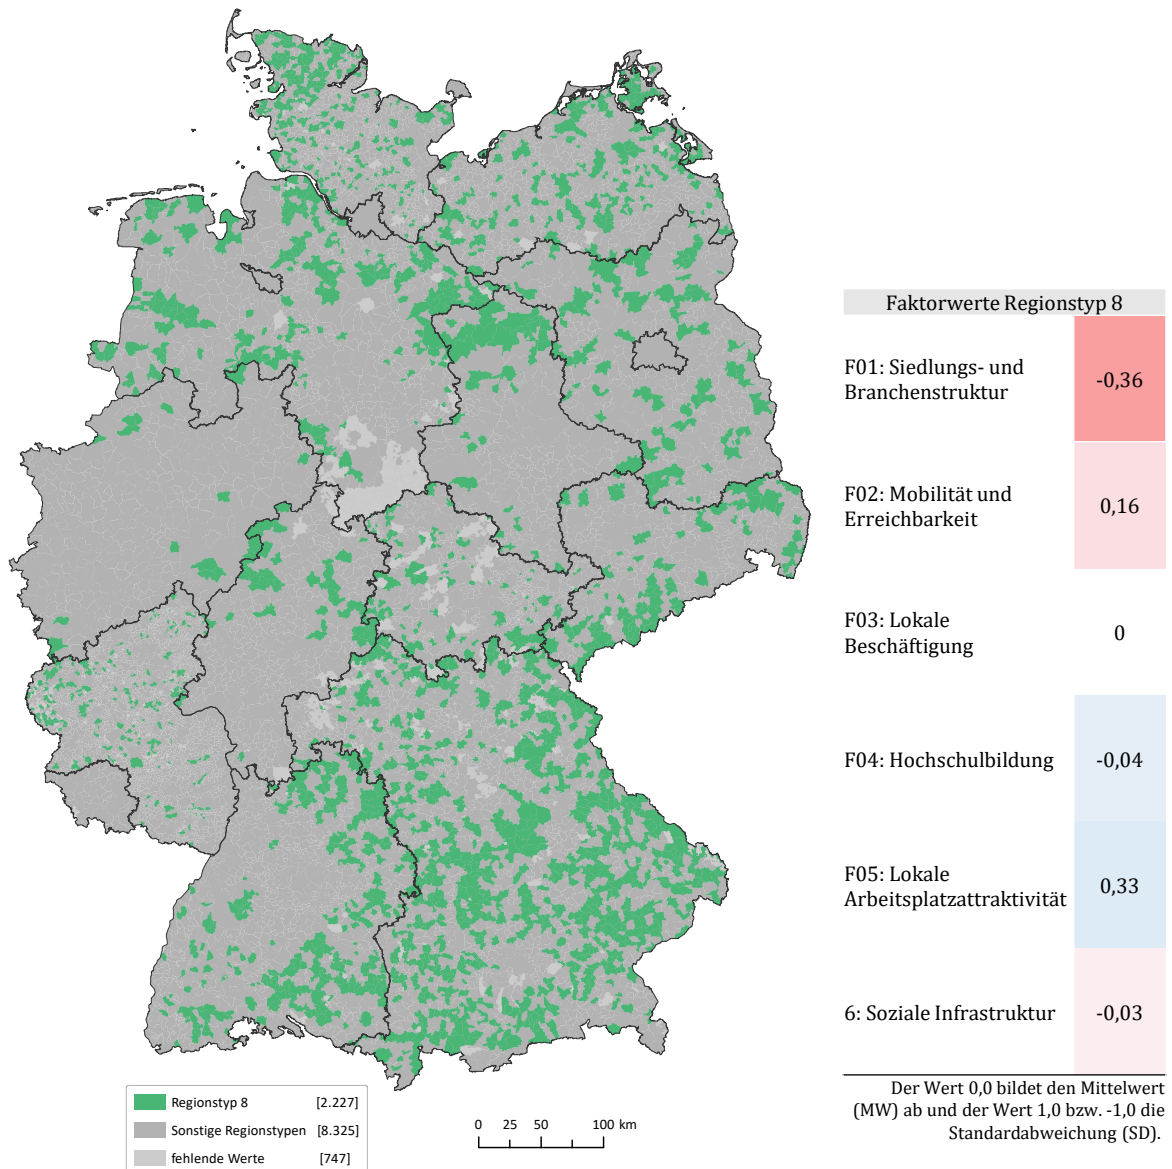
Regionstypisierung

Zu Regionstyp 8 gehören 21,1 Prozent aller deutschen Gemeinden. 98,7 Prozent der Gemeinden sind ländlichen (73,1 Prozent) oder eher ländlichen Kreisen (25,7 Prozent) zuzuordnen. Die Bevölkerung je Gemeinde liegt bei 2.400 Personen. Mit 217 HCs liegt der Wert der HCs je 1.000 EW bei 0,04 genau im Bundesmittel. Die Digitalisierung ist leicht unterdurchschnittlich mit einem Index von 0,2. Der Innovationsoutput liegt mit 8,2 Patenten je 1.000 EW im Vergleich zu den anderen Regionstypen im unteren Mittelfeld.

Die Siedlungs- und Branchenstruktur, im wie oben beschriebenen eher ländlich geprägten Regionstyp 8, ist im Vergleich mit -0,36 unter dem Bundesmittel einzuordnen. Hierbei handelt es sich um den zweitschwächsten Wert aller Typen für diesen Faktor. Die Mobilität und Erreichbarkeit ist die vergleichsweise schlechteste aller Regionstypen (0,16). Währenddessen entspricht die lokale Beschäftigung in den Gemeinden genau dem Bundesmittelwert. Die Hochschulbildung liegt mit -0,04 leicht unter dem Durchschnitt, im Vergleich zu den anderen Typen jedoch im Mittelfeld. Die lokale Arbeitsplatzattraktivität in den Gemeinden von Regionstyp 8 ist überdurchschnittlich hoch mit 0,33. Im Vergleich zu dem Faktorwert der anderen Regionstypen belegt er den vierten Platz. Die soziale Infrastruktur liegt mit -0,03 nah am Mittelwert. Im Vergleich zu den anderen Typen eher im unteren Mittelfeld.

Die räumliche Verteilung der Gemeinden des Regionstyps 8 ist in Abbildung 24 dargestellt. Die Karte zeigt deutlich, dass der Regionstyp in Norddeutschland, Bayern und im östlichen Baden-Württemberg häufig vertreten ist. Wieder wird deutlich, wie bei Regionstyp 7 abgebildet, dass die Gemeinden sich überwiegend außerhalb von Ballungsräumen befinden. Dazu zählt beispielsweise die Stadt Bad Wilsnack im Nordwesten Brandenburgs, das schwäbische Ederheim, Erzgebirge in Sachsen Geyer, Giebelstadt im bayrischen Unterfranken, Mamming in Niederbayern oder Pfatter in Oberpfalz Bayern.

Abbildung 24: Räumliche Verteilung Regionstyp 8



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

In Regionstyp 9 wurden 7,3 Prozent aller deutschen Gemeinden eingeteilt. Der Regionstyp umfasst zu 97,1 Prozent Gemeinden die in ländlichen (64,8 Prozent) oder eher ländlichen (32,4) Kreisen liegen (Küpper 2016). Je Gemeinde leben hier knapp 3.200 Menschen. Es konnten 210 HCs im Regionstyp 9 identifiziert werden. Mit 0,09 HCs je 1.000 EW ist dies der Regionstyp mit der höchsten HCs Dichte im Kontext der Bevölkerungszahl. Die durchschnittliche Digitalisierung liegt bei 0,2 und der Innovationsoutput bei 11,9 Patenten je 1.000 EW. Dieser Wert ist der zweithöchste Innovationoutput im Vergleich zu denen der anderen Regionstypen.

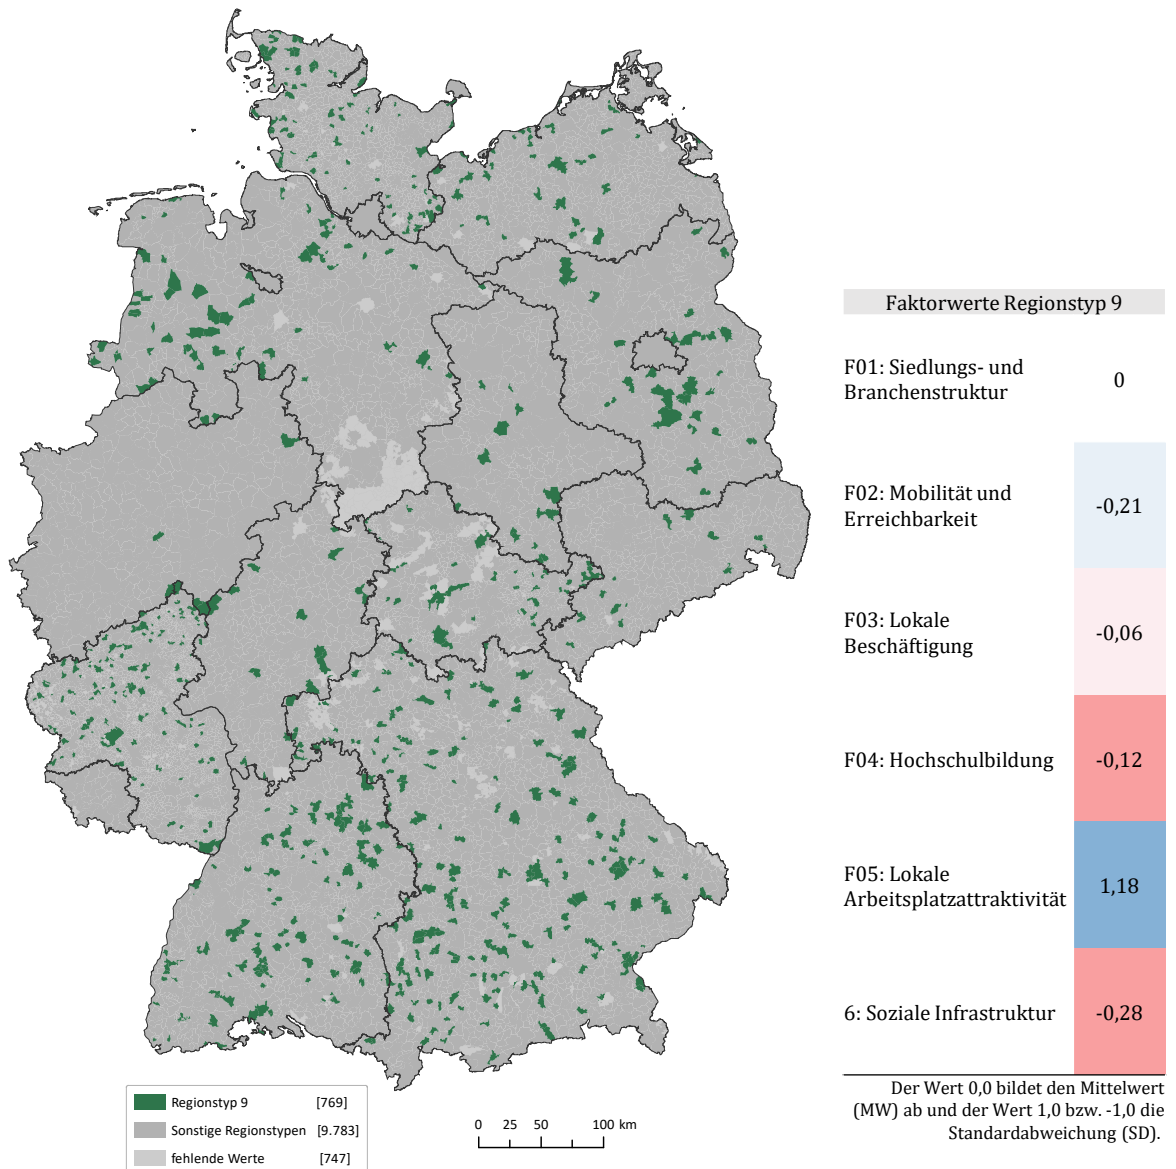
Regionstypisierung

Die Siedlungs- und Branchenstruktur in Regionstyp 9 entspricht genau dem Mittelwert aller deutschen Gemeinden. Im Vergleich der Regionstypen jedoch eher schwächer einzuordnen. Die Mobilität und Erreichbarkeit ist diesbezüglich überdurchschnittlich (-0,21), jedoch im Vergleich zu den anderen Typen im Mittelfeld einzustufen. Die lokale Beschäftigung liegt mit -0,06 leicht unter dem Durchschnitt und auch die Hochschulbildung ist an drittschwächster Position im Typenvergleich (-0,12). Anders sieht es bei der lokalen Arbeitsplatzattraktivität aus. Der Faktorwert liegt über eine Standardabweichung vom Mittelwert entfernt bei 1,18 und stellt somit den zweithöchsten Wert im Regionaltypenvergleich dar. Die soziale Infrastruktur hingegen ist die zweitschwächste und unterdurchschnittlich mit -0,28.

Der Regionstyp 9 ist im Norden, also auch im Süden und Osten häufig vertreten. Dies wird in der Karte aus Abbildung 25 deutlich. Seltener aufzufinden ist er in NRW, Hessen, dem Saarland oder dem östlichen Niedersachsen. Beispielhaft aufzuzählen ist die Stadt Schwerin oder die Gemeinde Wendorf in Mecklenburg-Vorpommern. Zossen ist eine Stadt in Brandenburg und Kelberg eine beispielhafte Gemeinde in Rheinland-Pfalz. Cleeborn liegt in der Randzone der Metropolregion Stuttgart oder Hemme nahe der Nordsee in Schleswig-Holstein.

Regionstypisierung

Abbildung 25: Räumliche Verteilung Regionstyp 9



Quelle: Eigene Darstellung und Berechnung auf Basis von Statistik der Bundesagentur für Arbeit (2017); INKAR (2020); Statistische Ämter des Bundes und der Länder (2020a-d); Geodaten: BKG (2016).

12 Darstellung der quantitativen Ergebnisse

In diesem Kapitel erfolgt zunächst die Ausführung der Ergebnisse der Regression mit Zählvariablen. Es folgt die Auswertung der der multiplen linearen Regression, bevor im nächsten Unterkapitel dann die Erkenntnisse der HLM folgen. Die Ergebnisse der räumlichen Regressionsanalyse werden das Kapitel abschließen.

12.1 Regression mit Zählvariablen

Vor der Umsetzung wurden die Voraussetzungen zur Durchführung des generalisierten linearen Modells überprüft. Dies erfolgte für die Daten aller neun Regionstypen als auch für die gesamträumliche Analyse der deutschen Gemeinden. Die ersten beiden Voraussetzungen der Daten sind erfüllt. Die abhängige Variable ist eine Zählvariable (Anzahl der HCs insgesamt) und die abhängigen Variablen sind bezüglich ihres Skalenniveaus geeignet. In Tabelle 14 sind Kennzahlen aufgeführt, die die Voraussetzungen für alle zehn Modelle überprüfen.

Tabelle 14: Voraussetzungen Regression mit Zählvariablen Hidden Champions-Anzahl

| Regionstyp | Mittelwert | Std. Abweichung | Varianz | Ratio | Gewählte Verteilung | Wert/df | Omnibus-Test | Durbin-Watson-Statistik | n |
|-------------------|------------|-----------------|---------|-------|---------------------|---------|--------------|-------------------------|--------|
| 1 | 0,87 | 1,40 | 1,96 | 2,26 | NBR | 0,73 | 0,000 | 1,90 | 1.260 |
| 2 | 3,46 | 4,01 | 16,07 | 4,65 | NBR | 0,68 | 0,000 | 1,86 | 247 |
| 3 | 6,05 | 8,46 | 71,57 | 11,83 | NBR | 0,48 | 0,000 | 2,44 | 38 |
| 4 | 0,45 | 0,83 | 0,68 | 1,52 | NBR | 0,64 | 0,000 | 1,94 | 1.378 |
| 5 | 0,37 | 0,81 | 0,65 | 1,76 | NBR | 0,65 | 0,000 | 2,02 | 242 |
| 6 | 0,09 | 0,32 | 0,10 | 1,15 | NBR | 0,29 | 0,000 | 1,95 | 2.295 |
| 7 | 0,01 | 0,11 | 0,01 | 1,12 | NBR | 0,07 | 0,000 | 2,02 | 2.017 |
| 8 | 0,10 | 0,34 | 0,12 | 1,16 | NBR | 0,33 | 0,000 | 1,96 | 2.218 |
| 9 | 0,28 | 0,64 | 0,40 | 1,46 | NBR | 0,56 | 0,000 | 2,02 | 748 |
| Deutschland insg. | 0,34 | 1,39 | 1,92 | 5,65 | NBR | 0,83 | 0,000 | 1,94 | 10.534 |

Abhängige Variable: Hidden Champions insgesamt

Quelle: Eigene Darstellung und Berechnung.

Es wurde festgestellt, dass weder in der durchgeführten Analyse des Gesamttraums noch in den einzelnen Regionstypen eine Autokorrelation vorliegt (Tabelle 14: Durbin-Watson-Statistik). Jedoch ist in allen Fällen die Voraussetzung der Gleichheit des Erwartungswerts und der Varianz verletzt. Zur Erfüllung des Kriteriums müsste der Ratio 1 ergeben. Dies ist in keinem der zehn Modelle der Fall. In den Untersuchungsregionen sind Überdispersionen zu verzeichnen. Die Dispersionsabweichungen sind zu berücksichtigen, denn durch sie können Effekte fälschlich als

Darstellung der quantitativen Ergebnisse

signifikant berechnet werden (Tutz 2010, S. 903). Auf die Überdispersion kann mit der Anwendung einer NBR reagiert werden.

Die Ergebnisse der Parameterschätzungen sind in Tabelle 15 zusammengefasst. Erfasst sind die exponentiellen Werte der Koeffizienten $Exp(B)$, da diese aussagekräftiger sind als die Koeffizientenschätzungen selbst. Unterschiede in den erklärenden Variablen wirken sich unter Konstanthaltung der anderen Prädiktoren (*ceteris paribus* (c.p.)) auf die Zahl der HCs aus, wie die geschätzten Koeffizienten zeigen. Die mit dem Koeffizienten potenzierten Werte werden erklärt. Der $Exp(B)$ gibt an, wie sich eine Erhöhung der unabhängigen Variablen um eine Einheit auf die Wahrscheinlichkeit einer Abnahme oder Zunahme der HCs-Anzahl niederschlägt. Die von der NBR abgeleiteten Beziehungen sind Korrelationen zwischen der abhängigen Variable und den Prädiktoren zu interpretieren (Kinne & Resch 2017, S. 5). Die Ergebnisse der durchgeführten NBR beantworten, inwieweit die Anzahl der HCs einer Gemeinde sich durch die sechs sozioökonomischen Faktoren, die Digitalisierung und die Ländlichkeit einer Gemeinde vorhersagen lassen.

Tabelle 15: Parameterschätzungen negativ binomiale Regressionen

| Parameter | Deutschland insg. (10.534) | | RT1 (1.260) | | RT2 (247) | | RT3 (38) | | RT4 (1.378) | |
|-----------------|-------------------------------|----------|----------------|----------|--------------|----------|-------------|---------|----------------|----------|
| | Exp(B) | p-value | Exp(B) | p-value | Exp(B) | p-value | Exp(B) | p-value | Exp(B) | p-value |
| Intercept | 0,18 | ,000 *** | 0,26 | ,000 *** | 0,42 | ,001 ** | 0,28 | ,476 | 0,24 | ,000 *** |
| F01 | 1,87 | ,000 *** | 1,94 | ,000 *** | 1,12 | ,000 *** | 1,18 | ,439 | 2,53 | ,000 *** |
| F02 | 0,71 | ,000 *** | 0,88 | ,065 | 0,93 | ,275 | 0,44 | ,072 | 1,06 | ,667 |
| F03 | 1,06 | ,000 *** | 269,93 | - | 1,59 | - | 1,02 | ,358 | - | - |
| F04 | 1,15 | ,000 *** | 1,16 | ,891 | 0,96 | ,012 * | 0,99 | ,871 | 34,67 | ,013 ** |
| F05 | 1,46 | ,000 *** | 2,12 | ,000 *** | 0,96 | ,622 | 0,56 | ,074 | 3,64 | ,000 *** |
| F06 | 1,65 | ,000 *** | 1,12 | ,058 | 1,36 | ,000 *** | 0,98 | ,955 | 2,71 | ,000 *** |
| Digitalisierung | 27,30 | ,000 ** | 17,52 | ,000 *** | 157,25 | ,000 *** | 1.636,30 | ,128 | 10,95 | ,000 *** |
| Ländlichkeit | 0,82 | ,000 *** | 0,81 | ,048 . | 0,84 | ,006 ** | 0,87 | ,674 | 0,76 | ,032 * |

| Parameter | RT5 (242) | | RT6 (2.295) | | RT7 (2.017) | | RT8 (2.218) | | RT9 (748) | |
|-----------------|--------------|----------|----------------|----------|----------------|----------|----------------|----------|--------------|----------|
| | Exp(B) | p-value | Exp(B) | p-value | Exp(B) | p-value | Exp(B) | p-value | Exp(B) | p-value |
| Intercept | 0,19 | ,000 *** | 0,22 | ,000 *** | 1,76 | ,693 | 0,11 | ,000 *** | 0,30 | ,002 ** |
| F01 | 1,54 | ,080 | 2,35 | ,001 *** | 49,51 | ,011 ** | 4,29 | ,000 *** | 10,20 | ,000 *** |
| F02 | 0,62 | ,001 ** | 1,11 | ,408 | 0,37 | ,014 ** | 0,71 | ,003 *** | 0,61 | ,000 *** |
| F03 | 6,08 | ,134 | - | - | - | - | - | - | 262,24 | ,003 *** |
| F04 | 1,08 | ,948 | - | - | - | - | 71,97 | ,051 . | 913,29 | ,000 *** |
| F05 | 1,00 | ,988 | 31,83 | ,000 *** | 932,16 | ,000 *** | 4,79 | ,000 *** | 1,56 | ,002 *** |
| F06 | 1,03 | ,528 | 2,58 | ,002 *** | 3,90 | ,229 | 2,72 | ,000 *** | 3,90 | ,000 *** |
| Digitalisierung | 7,33 | ,092 | 2,20 | ,349 | 6,08 | ,332 | 14,03 | ,000 *** | 26,80 | ,000 *** |
| Ländlichkeit | 1,15 | ,669 | 0,66 | ,064 | 0,74 | ,740 | 0,78 | ,139 | 1,60 | ,090 |

Abhängige Variable: Hidden Champions insgesamt (Gemeindeebene) Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

Zunächst zu den Ergebnissen der gesamträumlichen Analyse. Die geschätzten Effekte sind alle signifikant ($p < 0,05$). Steigt beispielhaft die Siedlungs- und Branchenstruktur (F01) um eine Einheit (c. p.), steigt die Anzahl der HCs um ca. 87 Prozent (das 1,87-fache des bestehenden Werts). Anders ist es bei der Mobilität und Erreichbarkeit (F02). Steigt der Parameter um eine Einheit (c. p.), ist zu beachten, dass damit die Entfernung länger und die Erreichbarkeit schlechter wird. Entsprechend ist der Wert wie folgt zu interpretieren: Steigt der Faktorwert um eine Einheit (c. p.), sinkt die HC-Anzahl der Gemeinde um ca. 29 Prozent. Der Effekt der lokalen Beschäftigung (F03) weist den geringsten potenzierten Koeffizienten auf. Steigt er um eine Einheit (c. p.), so wächst die Zahl der HCs um das 1,06-fache. Die Zahl der HCs steigt um das 1,16-fache, wenn die Hochschulbildung (F04) der Gemeinde um eine Einheit zunimmt (c. p.). Die lokale Arbeitsplatzattraktivität (F05) hat ebenfalls einen hohen Einfluss (c. p.) auf die HC-Anzahl (Steigerung um ca. 46 Prozent). Noch deutlicher wird es betrachtet man die soziale Infrastruktur (F06). Steigt diese um eine Einheit (c. p.), wird die HC-Anzahl 1,65-mal so groß sein. Der Digitalisierungsgrad wird an dieser Stelle der Forschungsarbeit das erste Mal quantitativ mit einbezogen. Die Steigerung der Digitalisierung um eine Einheit (c. p.) bringt die HC-Anzahl dazu um das 273-fache anzusteigen. Final zu betrachten ist der Einfluss der Ländlichkeit einer Gemeinde. Nimmt die Ländlichkeit um eine Einheit zu (c. p.), so sinkt die Anzahl der HCs um ca. 18 Prozent.

Im Anschluss wurde anhand der in den vorangehenden Kapiteln durchgeführten Regionstypisierung die NBR ebenfalls für die einzelnen Regionstypen durchgeführt. Die Betrachtung der einzelnen Charaktere der deutschen „Gemeindelandschaft“ ermöglicht eine neue Herangehensweise an die Analyse von kleinräumigen Strukturdifferenzen. In Tabelle 15 wird deutlich, dass einige der Effekte und deren Signifikanzen sich je nach Untersuchungsraum verändern. Im Folgenden werden diese Unterschiede in den neun Regionstypen beschrieben.

Für Gemeinden des Regionstyps 1 liegt der stärkste Effekt auf der Digitalisierung. Steigt die Digitalisierung um eine Einheit (c. p.), dann steigt die HC-Anzahl in den Gemeinden um ein 17,52-faches. Währenddessen hat die Ländlichkeit der Gemeinden einen negativen Effekt auf die Anzahl der HCs. Steigt die Ländlichkeit der Region um eine Einheit (c. p.), dann sinkt die Anzahl der Unternehmen um knapp 19 Prozent. Die lokale Arbeitsplatzattraktivität (F05) wirkt bei Steigerung um eine Einheit (c. p.) um das 2,12-fache auf die HC-Anzahl. Der vierte signifikante Effekt ist durch die Siedlungs- und Branchenstruktur (F01) der Gemeinden aus RT1 gegeben. Steigt diese um eine Einheit (c. p.), so steigert dies die Anzahl der HCs um das 1,94-fache. Dieser Effekt ist ähnlich ausgeprägt wie auf gesamträumlicher Ebene. Die lokale Beschäftigung, musste wegen Multikollinearität aus dem Modell entnommen werden.

Darstellung der quantitativen Ergebnisse

Für Regionstyp 2 gelten fünf signifikante Effekte. So steigert eine Zunahme der Siedlungs- und Branchenstruktur um eine Einheit (c. p.) die Anzahl der HCs um knapp 12 Prozent. Die Hochschulbildung (F04) weist hier einen negativen Zusammenhang mit der HC-Anzahl auf. Steigt sie um eine Einheit, so sinkt die HC-Zahl um ca. 4 Prozent. Steigt die soziale Infrastruktur (F06) um eine Einheit (c. p.), steigt die HC-Anzahl um das 1,36-fache. Die Digitalisierung hat einen starken Einfluss in diesem strukturräumlichen Gemeindetyp. Steigt sie um eine Einheit (c. p.), so vervielfacht sich die HC-Anzahl um ein 157,23-faches. Steigert sich die Ländlichkeit um eine Einheit (c. p.), dann sinkt die HC-Anzahl um das 0,84-fache. Die Mobilität (F02), die lokale Beschäftigung (F03) sowie die lokale Arbeitsplatzattraktivität (F05) haben keinerlei signifikanten Einfluss auf die abhängige Variable in diesem Gemeindetyp.

Der Regionstyp 3 ist der mit den wenigsten Gemeinden (N=40). Trotz Ausschluss der Ausreißer konnten keine signifikanten Effekte gemessen werden. Bei Regionstyp 4 ist dies anders. Hier steigert die Zunahme der Siedlungs- und Branchenstruktur (F01) um eine Einheit (c. p.) die HC-Anzahl um das 2,53-fache. Die lokale Beschäftigung (F03) musste wiederum aus dem Modell entnommen werden. Bei Zunahme um eine Einheit der lokalen Arbeitsplatzattraktivität erhöht sich die HC-Anzahl in Regionstyp 4 um das 3,64-fache. Bei Zunahme der sozialen Infrastruktur um eine Einheit (c. p.), steigt die HC-Anzahl um knapp 271 Prozent. Die Digitalisierung kann bei Zunahme um eine Einheit (c. p.) die HC-Anzahl knapp verzehnfachen und die Ländlichkeit senkt unter gleichen Voraussetzungen die abhängige Variable um das 0,76-fache. Die Hochschulbildung hat den stärksten Effekt, bei Steigerung (c. p.) erhöht sie die HC in dem Regionstyp um das 34,67-fache. Die die Mobilität und Erreichbarkeit (F02) hat in diesem Regionstypen keinen Einfluss auf die abhängige Variable.

Für Gemeinden des Regionstyps 5 gilt nur ein signifikanter Effekt. Dieser liegt auf der Mobilität und Erreichbarkeit (F02) der Region. Steigt diese um eine Einheit (c. p.), so sinkt die Anzahl der HCs um ca. 38 Prozent. Der Wert der Mobilität und Erreichbarkeit wird unter Zunahme schlechter. Sprich je höher der Wert, desto schlechter ist die Erreichbarkeit und Mobilität einer Region.

In Regionstyp 6 gilt, dass bei Steigerung der Siedlungs- und Branchenstruktur (c. p.) die HC-Anzahl fast um ein 2,35-faches ansteigt. Steigt die lokale Arbeitsplatzattraktivität (F05) (c. p.) um eine Einheit, vermehrt sich die Anzahl der HCs um das 31,83-fache. Nimmt die soziale Infrastruktur (F06) um eine Einheit zu (c. p.), steigt die Anzahl der HCs um das 2,58-fache. Die Mobilität und Erreichbarkeit (F02) die Digitalisierung und die Ländlichkeit weisen keinen signifikanten Effekt vor. Die lokale Beschäftigung und Hochschulbildung mussten von der Regression wegen Multikollinearität ausgeschlossen werden.

Darstellung der quantitativen Ergebnisse

Für Regionstyp 7 konnten drei signifikante Effekte identifiziert werden. Zunächst zur Siedlungs- und Branchenstruktur (F01), steigt diese um eine Einheit (c. p.), so multipliziert sich die Anzahl der HCs um das 49,51-fache. Nimmt die Mobilität und Erreichbarkeit (F02) um eine Einheit (c. p.) zu, dann sinkt die Anzahl der HCs um knapp 37 Prozent. Der dritte signifikante Exp(B) ist für die lokale Arbeitsplatzattraktivität (F05) zu verzeichnen. Steigt diese um eine Einheit (c. p.), so steigert dies die HC-Anzahl im Regionstyp um das 932,16-fache. Die lokale Beschäftigung (F03) und Hochschulbildung (F04) mussten von der Regression wegen Multikollinearität ausgeschlossen werden.

In Regionstyp 8 sind die Effekte der Hochschulbildung (F04) und Ländlichkeit nicht signifikant. Die Siedlungs- und Branchenstruktur (F01) kann durch Steigerung um eine Einheit (c. p.) die HC-Anzahl um das 4,29-fache erhöhen. Die Mobilität und Erreichbarkeit (F02) senkt sie um knapp 29 Prozent vorausgesetzt, die anderen Prädiktorvariablen sind konstant. Steigt die lokale Arbeitsplatzattraktivität um eine Einheit, so verfünffacht (4,79) sich die Zahl der HCs in der Region beinahe. Bei Steigerung der sozialen Infrastruktur (F06) wird sie (c. p.) verdreifacht (2,72). Die Digitalisierung des Regionstyps 8 kann die HC-Anzahl bei Zunahme um eine Einheit (c. p.) um das 14,03-fache steigern.

Der finale Regionstyp 9 weist nur in Bezug auf den Effekt der gesteigerten Ländlichkeit keine Signifikanz auf. Die Zunahme der Siedlungs- und Branchenstruktur (F01) um eine Einheit (c. p.), steigert die HC-Anzahl um knapp das zehnfache (10,2). Steigt die Mobilität und Erreichbarkeit (F02) um eine Einheit (c. p.), dann sinkt die Anzahl der HCs um knapp 61 Prozent. Nimmt die lokale Beschäftigung (F03) um eine Einheit zu (c. p.), verstärkt dies die Anzahl der HCs im Regionstyp 9 um das knapp 262-fache. Einen enormen Effekt ist auch in Bezug auf die Hochschulbildung festzustellen. Steigt sie um eine Einheit (c. p.), dann steigert dies die HC-Anzahl in der Region um das 913,29-fache. Die Zunahme der lokalen Arbeitsplatzattraktivität (F05) (c. p.) bringt eine 56-prozentige Zunahme der HC-Zahlen in den entsprechenden Gemeinden mit sich. Die Erhöhung der sozialen Infrastruktur (F06) um eine Einheit (c. p.), steigert die Zahl um das 3,9-fache. Die Digitalisierung hat einen starken Einfluss, steigt sie um eine Einheit, so vervielfacht sich die HC-Anzahl in Regionstyp 9 um ein 26,8-faches.

12.2 Multiple Regression

Durch die multiple lineare Regression lässt sich untersuchen, ob HCs im direkten Zusammenhang mit dem Innovationsoutput einer Gemeinde stehen. Die unabhängigen Variablen der Modellschätzung sind HCs je 1.000 EW, F01: Siedlungs- und Branchenstruktur, F02: Mobilität und Erreichbarkeit, F03: Lokale Beschäftigung, F04: Hochschulbildung, F05: Lokale Arbeitsplatzattraktivität, F06: Soziale Infrastruktur, Digitalisierung (Kriesch 2023) und die Ländlichkeit nach den Berechnungen des Thünen-Instituts (Küpper 2016).

Zunächst galt es, die Voraussetzungen der Daten für die Durchführung der Analyse zu testen. Diese sind nach logarithmischer Transformation der abhängigen Variable Innovationsoutput, sowie der unabhängigen Variablen HCs je 1.000 EW und der Digitalisierung erfüllt. Zunächst wurde die Regression auf gesamtträumlicher Ebene für alle deutschen Gemeinden berechnet. Im nächsten Schritt folgte dies dann für die einzelnen Regionstypen. In Tabelle 16 sind die Ergebnisse der Modellfunktionen dargestellt.

Tabelle 16: Ergebnisse der multiplen Regression

| | Deutschland insg | | RT1 | | RT2 | | RT3 | | RT 4 | |
|---------------------------------------|------------------|---------|----------|---------|----------|---------|----------|---------|----------|---------|
| | Estimate | p-value | Estimate | p-value | Estimate | p-value | Estimate | p-value | Estimate | p-value |
| (Intercept) | 0,87 | 0,00*** | 1,18 | 0,00*** | 0,22 | 0,58 | 0,43 | 0,52 | 1,60 | 0,00*** |
| Hidden Champions je 1.000 EW (log) | 0,44 | 0,00*** | 0,03 | 0,93 | -0,56 | 0,70 | -3,79 | 0,07. | 0,88 | 0,01** |
| F01: Siedlungs- & Branchenstruktur | 0,09 | 0,00*** | 0,22 | 0,00** | -0,07 | 0,24 | -0,11 | 0,29 | 0,80 | 0,00*** |
| F02: Mobilität & Erreichbarkeit | -0,21 | 0,00*** | -0,25 | 0,00*** | -0,06 | 0,47 | -0,08 | 0,39 | -0,34 | 0,00*** |
| F03: Lokale Beschäftigung | -0,03 | 0,00** | 0,44 | 0,26 | -0,05 | 0,66 | -0,03 | 0,10. | 2,13 | 0,00** |
| F04: Hochschulbildung | 0,01 | 0,35 | 1,28 | 0,06. | -0,01 | 0,69 | 0,03 | 0,35 | 3,74 | 0,00*** |
| F05: Lokale Arbeitsplatzattraktivität | 0,09 | 0,00*** | 0,38 | 0,00*** | 0,55 | 0,00*** | 0,00 | 0,95 | 0,29 | 0,01** |
| F06: Soziale Infrastruktur | 0,05 | 0,00*** | -0,02 | 0,58 | -0,21 | 0,03* | 0,02 | 0,32 | 0,08 | 0,29 |
| Digitalisierung (log) | 2,45 | 0,00*** | 2,18 | 0,00*** | 7,38 | 0,00*** | 3,11 | 0,09. | 1,40 | 0,00*** |
| Ländlichkeit | -0,37 | 0,00*** | -0,48 | 0,00*** | -0,26 | 0,02* | -0,62 | 0,00** | -0,51 | 0,00*** |
| Adjusted R-squared: | 0,169 | | 0,237 | | 0,268 | | 0,353 | | 0,125 | |

| | RT5 | | RT6 | | RT7 | | RT8 | | RT9 | |
|---------------------------------------|----------|---------|----------|---------|----------|---------|----------|---------|----------|---------|
| | Estimate | p-value | Estimate | p-value | Estimate | p-value | Estimate | p-value | Estimate | p-value |
| (Intercept) | 0,86 | 0,00*** | 1,57 | 0,00*** | 1,52 | 0,00*** | 1,54 | 0,00*** | 2,07 | 0,00*** |
| Hidden Champions je 1.000 EW (log) | -0,28 | 0,60 | 0,37 | 0,25 | 0,57 | 0,15 | 0,22 | 0,33 | 0,11 | 0,65 |
| F01: Siedlungs- & Branchenstruktur | 0,43 | 0,00** | 0,76 | 0,00*** | 0,50 | 0,08. | 0,87 | 0,00*** | 1,17 | 0,00*** |
| F02: Mobilität & Erreichbarkeit | -0,23 | 0,00*** | -0,35 | 0,00*** | -0,26 | 0,00*** | -0,38 | 0,00*** | -0,36 | 0,00*** |
| F03: Lokale Beschäftigung | 1,54 | 0,02* | 1,43 | 0,04* | -2,25 | 0,17 | -0,09 | 0,92 | 2,05 | 0,04* |
| F04: Hochschulbildung | 0,61 | 0,29 | 1,82 | 0,07. | 2,66 | 0,03* | 4,35 | 0,00*** | 5,35 | 0,00*** |
| F05: Lokale Arbeitsplatzattraktivität | 0,06 | 0,23 | 0,87 | 0,00*** | 0,61 | 0,00*** | 0,40 | 0,00*** | 0,16 | 0,03* |
| F06: Soziale Infrastruktur | 0,04 | 0,10. | 0,03 | 0,73 | 0,27 | 0,07. | 0,38 | 0,00*** | 0,47 | 0,00*** |
| Digitalisierung (log) | 1,04 | 0,17 | 1,48 | 0,00*** | 1,07 | 0,00*** | 1,91 | 0,00*** | 1,94 | 0,00*** |
| Ländlichkeit | -0,02 | 0,90 | -0,30 | 0,00*** | -0,07 | 0,53 | -0,22 | 0,01* | -0,65 | 0,00*** |
| Adjusted R-squared: | 0,245 | | 0,159 | | 0,064 | | 0,160 | | 0,165 | |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 Einwohner*innen) (log)
 Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

Zunächst zu den Koeffizienten aus der gesamtdeutschen Regressionsanalyse. Diese lassen sich wie folgt beschreiben. Steigt die Anzahl der HCs je 1.000 EW um ein Prozent, dann steigt sich (c. p.) der Innovationsoutput im Durchschnitt um 0,44 Prozent. Ebenfalls einen positiven Effekt wird bei der Siedlung- und Branchenstruktur (F01) festgestellt. Steigt sie um eine Einheit (c. p.), steigert sie den Innovationsoutput im Durchschnitt um ca. 9 Prozent, genau wie die lokale Arbeitsplatzattraktivität (F05). Steigt die Digitalisierung um eine Einheit (c. p.), steigert dies den Innovationsoutput im Durchschnitt um 2,45 Prozent. Negative Effekte bringen die Mobilität und Erreichbarkeit (F02) mit einer Abnahme des Innovationsoutputs um ca. 21 Prozent bei Steigerung des Wertes um eine Einheit. Außerdem birgt die Zunahme der lokalen Beschäftigung (F03) um eine Einheit (c. p.) die Abnahme des Innovationsoutputs um ca. 3 Prozent. Nimmt die Ländlichkeit der Region um eine Einheit zu, so schadet dies dem Innovationsoutput im Durchschnitt um -3,7 Prozent. Lediglich für die Hochschulbildung lässt sich auf gesamtträumlicher Ebene kein Effekt auf die Innovationsleistung einer Region messen.

Für Regionstyp 1 lässt sich ablesen, dass bei Erhöhung der Siedlungs- und Branchenstruktur um eine Einheit, der Innovationsoutput im Durchschnitt approximativ ((c. p.)) um 22 Prozent steigt. Für die Mobilität und Erreichbarkeit in Regionstyp 1 gilt, dass wenn diese sich um eine Einheit verschlechtert, der Innovationsoutput im Durchschnitt approximativ um 25 Prozent sinkt. Je schlechter die Erreichbarkeit, desto geringer ist der Innovationsoutput. Steigt die lokale Arbeitsplatzzentralität um eine Einheit, steigt der Innovationsoutput um 38 Prozent. Steigt die Digitalisierung in der Region um ein Prozent, dann nimmt der Innovationsoutput um ca. 2,18 Prozent zu. Nimmt die Ländlichkeit um eine Einheit zu, sinkt der Innovationsoutput der Region im Durchschnitt um ungefähr 48 Prozent.

Das Modell für Regionstyp 2 ergibt vier signifikante Effekte. Steigt die lokale Arbeitsplatzattraktivität um eine Einheit, dann steigt der Innovationsoutput im Durchschnitt um ca. 55 Prozent. Bei Zunahme der sozialen Infrastruktur sinkt der Innovationsoutput durchschnittlich um 21 Prozent. Und bei der Ländlichkeit um 26 Prozent. In Bezug auf die Digitalisierung in Regionstyp 2 lässt sich sagen, dass bei Zunahme dieser um ein Prozent der Innovationsoutput um 7,38 Prozent steigt.

Für Regionstyp 3 konnte ein signifikanter Effekt geschätzt werden. Dieser betrifft die Ländlichkeit der Gemeinden. Nimmt diese um eine Einheit zu, dann sinkt der Innovationsoutput der Gemeinden im Durchschnitt um ca. 62 Prozent.

Regionstyp 4 stellt den einzigen strukturräumlichen Charakter dar, in welchem die HCs je 1.000 EW einen signifikanten Einfluss auf die Innovationsleistung haben. Wird die unabhängige Variable

Darstellung der quantitativen Ergebnisse

hier um ein Prozent gesteigert, verändert sich (c. p.) der Innovationsoutput im Durchschnitt um 0,88 Prozent. Weiter hat die Siedlungs- und Branchenstruktur einen positiven Einfluss, steigt sie um eine Einheit erhöht sich die Innovationsleistung im Durchschnitt um ungefähr 80 Prozent. Die Mobilität und Erreichbarkeit hat einen negativen Effekt (-34 Prozent), genauso wie die Ländlichkeit (-51 Prozent). Die lokale Beschäftigung in der Region steigert bei Zunahme um eine Einheit die Innovationsleistung um ca. 213 Prozent. Und die Hochschulbildung überbietet dies noch um durchschnittliche 317 Prozent. Die lokale Arbeitsplatzattraktivität bringt bei Steigerung um eine Einheit einen geschätzten Effekt von 29 Prozent erhöhter Innovationsleistung mit sich. Die soziale Infrastruktur hat in Regionstyp 4 keinen signifikanten Einfluss. Jedoch kann die Digitalisierung die Innovationsleistung bei Erhöhung um ein Prozent diese um durchschnittlich 1,4 Prozent steigern.

Das Modell für Regionstyp 5 ergibt drei signifikante Parameterschätzungen. Dazu gehört zunächst die Siedlungs- und Branchenstruktur. Steigt sie um eine Einheit, dann erhöht sich der Innovationsoutput um durchschnittlich 34 Prozent. Nimmt die Mobilität und Erreichbarkeit um eine Einheit zu, so sinkt dadurch die abhängige Variable um durchschnittlich -23 Prozent. Während die lokale Beschäftigung einen sehr hohen Einfluss nehmen kann. Bei Steigerung dieser steigt die Innovationsleistung im Durchschnitt um 154 Prozent.

Für Gemeinden des Regionstyps 6 ergibt sich ein positiver signifikanter Zusammenhang zwischen der Siedlungs- und Branchenstruktur (76 Prozent), der lokalen Beschäftigung (143 Prozent), der lokalen Arbeitsplatzattraktivität (87 Prozent) und der Digitalisierung (1,48 Prozent) mit dem Innovationsoutput der Gemeinden. Negative Zusammenhänge bestehen bei Erhöhung der Mobilität und Erreichbarkeit um eine Einheit, denn dann nimmt der Innovationsoutput um durchschnittlich 35 Prozent ab, und die Ländlichkeit ebenso (-30 Prozent).

Regionstyp 7 beinhaltet vier signifikante Zusammenhänge. Nimmt die Mobilität und Erreichbarkeit um eine Einheit zu, sinkt die Innovationsleistung um durchschnittlich 26 Prozent. Die Hochschulbildung hat einen positiven Effekt, steigt sie um eine Einheit erhöht dies die Innovationsleistung um 266 Prozent. Die lokale Arbeitsplatzattraktivität führt bei Zunahme um eine Einheit zu einer, um durchschnittlich ca. 61 Prozent, erhöhten Innovationsleistung. Steigt die Digitalisierung um ein Prozent, steigert dies den Innovationsoutput um 1,07 Prozent.

Bei der Betrachtung der Ergebnisse des achten Regionstyps wird deutlich, dass hier die Hochschulbildung den stärksten Effekt mit sich bringt. Steigt sie um eine Einheit erhöht dies den Innovationsoutput im Durchschnitt um 435 Prozent. An zweiter Stelle steht die Siedlungs- und Branchenstruktur. Sie steigert bei Zunahme um eine Einheit die abhängige Variable um ca. 87

Darstellung der quantitativen Ergebnisse

Prozent. Darauf folgt die lokale Arbeitsplatzattraktivität mit 40 Prozent und dann die soziale Infrastruktur mit ca. 38 Prozent Steigerung des Innovationsoutputs. Den finalen positiven Effekt bringt die Erhöhung der Digitalisierung um ein Prozent mit sich (1,91 Prozent). Negative Zusammenhänge bestehen mit der Mobilität und Erreichbarkeit (-38 Prozent) und der Ländlichkeit (-22 Prozent).

Das Modell, welches die Gemeinden des Regionstyps 9 analysierte, kam zu den im Folgenden ausgeführten Ergebnissen. Hier gilt, dass wenn die Siedlungs- und Branchenstruktur um eine Einheit zunimmt, die Innovationsleistung im Durchschnitt um 117 Prozent steigt. Die gleiche Steigerung (c. p.) bei der Mobilität und Erreichbarkeit führt zu einer Abnahme um 36 Prozent. Die lokale Beschäftigung vervielfacht bei Erhöhung um eine Einheit den Innovationsoutput um durchschnittlich 205 Prozent. Den stärksten Effekt bringt die Hochschulbildung mit sich. Steigt diese um eine Einheit, dann erhöht sich der Innovationsoutput in Regionstyp 9 approximativ um im Durchschnitt 535 Prozent. Schwächer ist hier der Effekt der lokalen Arbeitsplatzattraktivität (ca. 16 Prozent) und der sozialen Infrastruktur (ca. 47 Prozent). Steigt die Digitalisierung um ein Prozent erhöht dies den Innovationsoutput um ca. 1,94 Prozent. Nimmt die Ländlichkeit in Regionstyp 9 zu, so sinkt der Innovationsoutput um ca. 65 Prozent.

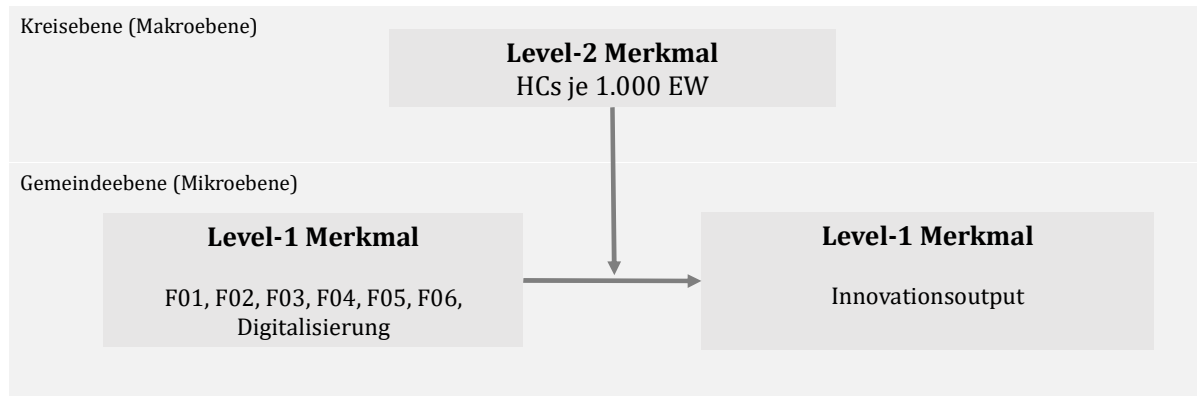
12.3 Hierarchisch Lineare Modelle

Die Innovationstätigkeit gilt als wesentlicher Faktor für den wirtschaftlichen Erfolg einer Region. Empirischen Untersuchungen zufolge wird der technische Fortschritt und die Innovationskraft einer Region durch die geographische Komponente der Wissensgenerierung beeinflusst (Audretsch & Feldmann 2004, S. 2715). Aus der in Kapitel 2 aufgeführten Literatur lässt sich ableiten, dass die Innovationsprozesse in Gemeinden, egal ob ländlich oder urban geprägt, von deren sozioökonomischen Struktur abhängen. Die Digitalisierung einer Gemeinde kann durch die Bereitstellung überregionaler Kommunikationskanäle entsprechende Wissensnetzwerke fördern (Eder & Trippel 2019, S: 1516-1517). Demnach wird in der vorliegenden Arbeit angenommen, dass mit einer hohen Digitalisierung einer Gemeinde der Innovationsoutput gesteigert wird. Weiter folgt die Annahme, dass die zusätzliche Anwesenheit von HCs als hoch innovative Unternehmen eine verstärkende Wirkung auf den Effekt der Struktur und der Digitalisierung auf den Innovationsoutput einer Gemeinde haben kann. Betrachtet man diese Wechselwirkungen auf unterschiedlichen Ebenen, nennt man sie ebenenübergreifende Moderationen. Dies bedeutet, dass die Innovationsprozesse auf Gemeindeebene nicht unabhängig voneinander, sondern eingebettet in ein größeres Umfeld stattfinden (Hundt & Holtermann 2020, S. 8). In dieser Arbeit stellen die HCs auf Kreisebene dieses Umfeld dar und variieren je nach Regionstyp. Um die

Darstellung der quantitativen Ergebnisse

beschriebenen Wirkungszusammenhänge zu messen, wurde eine HLM durchgeführt. Die verwendeten Variablen sind in Abbildung 26 zur besseren Nachvollziehbarkeit graphisch dargestellt.

Abbildung 26: Ebenenübergreifende Interaktionen in der HLM



Quelle: Eigene Darstellung.

In Vorbereitung auf diese Analyse wurden zunächst die notwendigen Voraussetzungen getestet. Da die Faktoren der sozioökonomischen Struktur bereits zentriert waren, wurde diese nur bei der Digitalisierungsrate durchgeführt. Die abhängige Variable wurde nicht zentriert (Urban 2022, S. 29). Wie in Kapitel 9.4 beschrieben erfolgte für Gesamtdeutschland, sowie für jeden der neun Regionstypen, eine Mehrebenenanalyse. Ziel war es zu untersuchen, inwieweit der Effekt der entsprechenden Kreise in den Gemeinden wirkt. Im Folgenden werden die in Kapitel 9.4 hergeleiteten Hypothesen für die Untersuchungsregion und -typen getestet und die Ergebnisse präsentiert.

12.3.1 Deutschland

Für Gesamtdeutschland wurden alle knapp 10.550 Gemeinden mit in die HLM einbezogen. Auf Kreisebene konnten 402 Kreise betrachtet werden. Begonnen wird wie in der Methodik in Kapitel 9.4 beschrieben mit einem Nullmodell (M1). Basierend auf den Ergebnissen des Nullmodells ist die erste Hypothese anzunehmen. Für die gesamte Untersuchungsregion gilt:

H1: Der Innovationsoutput unterscheidet sich signifikant zwischen den Gemeinden.

Die Daten sind zur Durchführung der HLM geeignet, denn der Adjusted ICC liegt über 0,1 bei 0,296 (Guo 2005, S. 639). Entsprechend lässt sich feststellen, dass 29,6 Prozent der Gesamtvarianz auf Unterschiede zwischen den Kreisen zurückzuführen ist. Die Modellgüte (Deviance) liegt bei 31.891,2 und ist durch Hinzunahme weiterer Variablen in den kommenden Modellen zu unterschreiten. Im zweiten Schritt erfolgte die Kalkulation des (M2) *Random-Intercept-Modells*. Hier wurden mehrere unabhängige Variablen auf beiden räumlichen Leveln hinzugenommen. Zunächst zur Modellgüte. Diese hat sich von M1 auf 31.504,7 verringert. Die Modellgüte hat sich also durch die Hinzunahme der sechs sozioökonomischen Faktoren aus der HKA: F01 – F06 und der Digitalisierung als Effekte auf der Gemeindeebene sowie der Ländlichkeit als Effekt auf der Kreisebene verbessert. Der Adjusted ICC von M2 liegt bei 0,236. Der Erklärungsanteil der Prädiktoren aus Modell 2 liegt somit bei 6 Prozent. Anhand der Ergebnisse von M2 lassen sich die aufgestellten Hypothesen bestätigen:

H2.1: Je stärker die sozioökonomische Struktur und die Digitalisierung der Gemeinde, desto höher ist der Innovationsoutput.

Außerdem ergeben die Resultate des Modells, das H2.2 ebenfalls anzunehmen ist:

H2.2: Unter Kontrolle der Gemeindeebenenvariablen gilt, dass je höher die Ländlichkeit eines Kreises ist, desto niedriger ist der Innovationsoutput der dazugehörigen Gemeinden.

In Tabelle 17 werden die Fixen Effekte des M2 aufgeführt. Für die Zeilen des jeweiligen Prädiktors gilt, dass der jeweilige Effekt über alle Kreise hinweg gilt. Die Siedlungs- und Branchenstruktur, die lokale Arbeitsplatzattraktivität, die soziale Infrastruktur und die Digitalisierung haben einen signifikanten positiven Effekt auf den Innovationsoutput. Signifikant negative Effekte bestehen im Zusammenhang mit der Mobilität und Erreichbarkeit. Für die Kreisebenenvariable der Ländlichkeit ist ebenfalls ein negativer signifikanter Effekt abzulesen.

Darstellung der quantitativen Ergebnisse

Tabelle 17: Modell 2 Fixe Effekte (Deutschland insgesamt)

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-----------|---------|----------|
| (Intercept) | 1,39 | 0,04 | 574,80 | 34,21 | 0,00 *** |
| F01: Siedlungs- und Branchenstruktur | 0,10 | 0,01 | 10.470,00 | 7,98 | 0,00 *** |
| F02: Mobilität und Erreichbarkeit | - 0,19 | 0,01 | 9.947,00 | - 12,85 | 0,00 *** |
| F03: Lokale Beschäftigung | - 0,02 | 0,01 | 2.823,00 | - 1,19 | 0,23 |
| F04: Hochschulbildung | 0,01 | 0,01 | 10.540,00 | 0,89 | 0,38 |
| F05: Lokale Arbeitsplatzattraktivität | 0,06 | 0,01 | 10.420,00 | 5,39 | 0,00 *** |
| F06: Soziale Infrastruktur | 0,04 | 0,01 | 10.430,00 | 3,47 | 0,00 *** |
| Digitalisierung | 0,66 | 0,10 | 10.260,00 | 6,69 | 0,00 *** |
| Ländlichkeit | - 0,22 | 0,06 | 1.067,00 | - 3,62 | 0,00 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Im Anschluss an M2 prüft M3, wie oben ausführlich beschrieben, ob sich der Einfluss der unabhängigen Variablen auf die abhängige Variable auf Gemeindeebene zwischen den Kreisen unterscheidet. Dies führte in der Ausführung in R zu einem Warnhinweis, denn das Modell konvergiert nicht. Dies ist auf eine zu geringe Varianz der Random Effekte zurückzuführen. In den nächsten Schritten wurden die einzelnen Variablen testweise aus den Random Effekten herausgenommen. Das Modell schloss nach Abschluss dieser Selektion folgende Effekte mit ein: die Siedlungs- und Branchenstruktur, die lokale Beschäftigung, Hochschulausbildung und die lokale Arbeitsplatzattraktivität. Die Ergebnisse der Random Effekte sind in Tabelle 18 festgehalten.

Tabelle 18: Modell 3 Random Effekte und Modellgüte (Deutschland insgesamt)

| | Deviance | Variance Random Slope | Std. Dev. | sig. |
|---------------------------------------|----------|-----------------------|-----------|------|
| (Intercept) | | 0,346485 | 0,589 | *** |
| F01: Siedlungs- und Branchenstruktur | | 0,004638 | 0,068 | *** |
| F03: Lokale Beschäftigung | 31.487,3 | 0,000211 | 0,015 | *** |
| F04: Hochschulbildung | | 0,000191 | 0,014 | *** |
| F05: Lokale Arbeitsplatzattraktivität | | 0,005576 | 0,075 | *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

Die Deviance ist im Vergleich zu M2 weiter gesunken (31.487,3). Die Hinzunahme der Random Slopes verbessert demnach weiter die Modellgüte. Im nächsten Schritt wird die Varianz der Random Slopes betrachtet. Diese hat sich im Vergleich zu den hier nicht abgebildeten Fixen Effekten in jedem Fall deutlich verringert. Die Varianz des F01 in der Random Slope liegt bei 0,005 mit einer Standardabweichung von 0,068. Die Fixen Effekte lagen bei 0,116. Die Effekte der Siedlungs- und Branchenstruktur schwanken also deutlich zwischen den Klassen. Diese Schwankungen sind hoch signifikant. Gleiches gilt für die lokale Beschäftigung (Fixe Effekte: 0,004), die Hochschulbildung (0,017) als auch die lokale Arbeitsplatzattraktivität (0,101) im gesamten Bundesgebiet. Die beschriebenen Schwankungen sind signifikant. Die Varianz der Slope für FAC1; 3, 4 und 5 sind hoch signifikante (0,000015). Die Kovarianz der Random Effekte (Zufallsparameter) sind ebenfalls signifikant (0,00458). Die eingangs aufgestellte Hypothese (H3), dass sich *die Effekte der sozioökonomischen Struktur und die Digitalisierung der Gemeinden zwischen den Kreisen unterscheiden* kann entsprechend für F01, F03, F04 und F05 angenommen werden. Für die anderen Prädiktoren ist sie jedoch abzulehnen.

Der finale Schritt der HLM erfolgte durch die Aufstellung von M4. Die Ergebnisse des Modells geben Auskunft darüber, inwieweit die Effekte der Prädiktoren auf Gemeindeebenen F01, F03, F04 und F05 auf den Innovationsoutput von der Anwesenheit der HCs im Kreis abhängen. Dazu wurde ein Modell aufgestellt, welches diese vier unabhängigen Variablen sowie ebenenübergreifende Interaktionen beinhaltet.

Die Modellgüte ist auch in M4 liegt nun bei 31.479,4 und es lässt sich schlussfolgern, dass die ergänzten Effekte zur besseren Modellgüte beitragen. Die Varianzen der Random Effekte sind jedoch im Vergleich zu denen in M3 nicht alle zurückgegangen. Sie sind in Tabelle 19 abgebildet.

Tabelle 19: Random Effekte M4 (Deutschland insgesamt)

| | Deviance | Variance Random Slope | Std. Dev. |
|---------------------------------------|----------|-----------------------|-----------|
| (Intercept) | | 0,345400 | 0,588 |
| F01: Siedlungs- und Branchenstruktur | | 0,004194 | 0,065 |
| F03: Lokale Beschäftigung | 31.479,4 | 0,000227 | 0,015 |
| F04: Hochschulbildung | | 0,000006 | 0,003 |
| F05: Lokale Arbeitsplatzattraktivität | | 0,006472 | 0,080 |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Quelle: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

Die Varianz des Effekts von F01 ist zurückgegangen, von 0,004638 im vorherigen M3 auf 0,004194 in diesem Modell. Ein Teil der Schwankung zwischen den Kreisen in der Siedlungs- und Branchenstruktur konnte also durch die Anwesenheit der HCs erklärt werden. Die Varianz des Effekts von F03 ist nicht zurückgegangen, von 0,000211 im vorherigen Modell auf 0,000227 in diesem Modell. Die Varianz des Effekts von F04 ist zurückgegangen, von 0,000191 vorherigen Modell auf 0,000006 in diesem Modell. Ein großer Teil der Schwankung zwischen den Kreisen in der Hochschulbildung konnte also durch die HCs je 1.000 EW erklärt werden. Die Varianz des Effekts von F05 ist wiederum nicht zurückgegangen, sondern von 0,005576 auf 0,006472 gestiegen. In Tabelle 19 sind die Random Effekte des M4 abgebildet. Keine der Interaktionen zwischen den Variablen auf Gemeinde- und Kreisebene sind signifikant. Es lässt sich keine Aussage darüber treffen, inwieweit die Kreise mit mehr HCs je 1.000 EW den Effekt der sozioökonomischen Faktoren auf die Innovationsleistung höher ausfällt als in solchen in denen mit wenig HCs.

In Tabelle 20 ist zu erkennen, dass sich ein Teil der Effektschwankungen für die Siedlungs- und Branchenstruktur (F01) sowie die Hochschulbildung (F04) zwischen den Kreisen durch die Anzahl der HCs je 1.000 EW erklären lässt. Innerhalb der Kreise gibt es darauf keinen Hinweis. Es kann also kein Großteil der Schwankungen zwischen den Klassen in der Siedlungs- und Branchenstruktur (F01) oder der Hochschulbildung (F04) durch die Anzahl der HCs erklärt werden. H4 ist somit abzulehnen.

Tabelle 20: Fixe Effekte M4 (Deutschland insgesamt)

| | Estimate | Std. Error | t-value | p-value | sig. |
|---------------------------------------|----------|------------|---------|---------|------|
| (Intercept) | 1,13 | 0,04 | 27,77 | 0,00 | *** |
| F01: Siedlungs- und Branchenstruktur | 0,12 | 0,01 | 8,38 | 0,00 | *** |
| F02: Mobilität und Erreichbarkeit | -0,20 | 0,01 | -13,44 | 0,00 | *** |
| F03: Lokale Beschäftigung | 0,00 | 0,01 | 0,09 | 0,93 | |
| F04: Hochschulbildung | 0,02 | 0,01 | 1,87 | 0,06 | . |
| F05: Lokale Arbeitsplatzattraktivität | 0,05 | 0,01 | 4,84 | 0,00 | *** |
| F06: Soziale Infrastruktur | 0,04 | 0,01 | 3,46 | 0,00 | *** |
| Digitalisierung | 0,91 | 0,11 | 7,98 | 0,00 | *** |
| HCs je 1000 EW | 0,26 | 0,11 | 2,45 | 0,01 | * |
| F01 : HCs je 1000 EW (log) | -0,21 | 0,14 | -1,46 | 0,14 | |
| F04: HCs je 1000 EW (log) | -0,08 | 0,04 | -1,92 | 0,07 | . |

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

H4: Die Anzahl der Hidden Champions hat eine verstärkend positive Wirkung auf den Effekt der sozioökonomischen Struktur und der Digitalisierung auf die Ausprägung des Innovationsoutputs der Gemeinden.

Über alle deutschen Gemeinden und Kreise hinweg sind keine signifikanten ebenenübergreifenden Mehrebeneneffekte zu messen. Ein Blick auf die Ergebnisse der NBR gibt einen Hinweis darauf, dass sowohl unterschiedliche Regionstypen als auch unterschiedliche Raumstrukturen einen Einfluss auf deren HC-Anzahl haben. Im nächsten Schritt gilt es also die oben durchgeführte Analyse im nächsten Schritt für alle neun Regionstypen durchzuführen. Wie aus der Literatur schon zu vermuten und nun in der Analyse bestätigt, müssen um wissenschaftliche, regionalpolitische und strukturraumspezifische Handlungsempfehlungen auf kleinster Raumebene zu formulieren, die Gemeinden in homogene Klassen zusammengefasst werden (Schätzl 2000, S. 94), um unterschiedliche sozioökonomischer Strukturlevel auf Gemeindeebene zu berücksichtigen (Wieland & Fuchs 2018, S. 152).

12.3.2 Regionstypen

Im Folgenden werden die Ergebnisse für die HLM der neun Regionstypen präsentiert. Ziel war es zu untersuchen, inwieweit der Effekt sich in den entsprechenden Kreisen und Gemeinden unterscheidet. Durch die Untersuchung der einzelnen Regionstypen wird die Heterogenität der deutschen Gemeinden berücksichtigt. Im Folgenden werden die in Kapitel 9.4 aufgestellten Hypothesen für die Regionstypen getestet und die Ergebnisse präsentiert.

Begonnen wird mit *H1: Der Innovationsoutput unterscheidet sich signifikant zwischen den Gemeinden*. M1, das Nullmodell, welches zur Testung der Hypothese verwendet wird, gibt außerdem Aussage darüber, inwieweit die dritte Voraussetzung der Daten zur Durchführung der HLM erfüllt ist. Dadurch lassen sich gemeinsame Auswirkungen auf die abhängige Variable (auf Gemeindeebene, der Innovationsoutput) testen. Die Ergebnisse des M1 für alle neun Regionstypen sind in Tabelle 21 notiert.

Darstellung der quantitativen Ergebnisse

Tabelle 21: Interklassenkoeffizient (ICC) Modell 1 und Modell 2

| | | Modell 1: Adjustet ICC | sig. Nullmodell | Modell 2: Adjusted ICC | Erklärungsanteil Prädiktoren Modell 2 | |
|------------|---|------------------------|-----------------|------------------------|--|--------|
| REGIONSTYP | 1 | 1.260 | 0,368 | <,0001 *** | 0,232 | 13,60% |
| | 2 | 247 | 0,518 | <,0001 *** | 0,317 | 20,10% |
| | 3 | 38 | 0,212 | 0,4036 | - | - |
| | 4 | 1.378 | 0,259 | <,0001 *** | 0,195 | 6,40% |
| | 5 | 242 | 0,621 | <,0000 *** | 0,529 | 9,20% |
| | 6 | 2.295 | 0,292 | <,0000 *** | 0,199 | 9,30% |
| | 7 | 2.017 | 0,245 | <,0000 *** | 0,198 | 4,70% |
| | 8 | 2.218 | 0,324 | <,0001 *** | 0,248 | 7,60% |
| | 9 | 748 | 0,313 | <,0001 *** | 0,219 | 9,40% |
| | D | 10.534 | 0,296 | <,0001 *** | 0,236 | 6,00% |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)
Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Für alle neun Regionstypen liegt der ICC über den benötigten 0,10 (Guo 2005, S. 639). Dies gibt einen Hinweis darauf, dass die Anwendung der HLM zu empfehlen ist. Nach der Schätzung des Modells erfolgt ein Signifikanztest für den zufälligen Effekt. Die Ergebnisse des angewandten Likelihood-Ratio-Test sagen aus, dass für acht der neun Regionstypen der p-Wert des Tests signifikant ist. Entsprechend ist ein *Random-Effekt-Modell* zu verwenden, da es eine signifikant bessere Anpassung an die Daten bietet. Dies gilt jedoch nicht für RT3. Hier liegt keine signifikante Varianz auf Kreisebene vor. Es liegen keine nennenswerten Abweichungen der Gemeindemittelwerte von den Kreismittelwerten vor (Urban 2022, S. 50). Die HLM wird für RT3 nicht weiter fortgeführt. Wenn im Folgenden von allen Regionstypen gesprochen wird, ist RT3 damit nicht gemeint. Der Adjusted ICC gibt an, dass 36,8 Prozent der Gesamtvarianz in RT1 auf Unterschiede zwischen den Kreisen zurückzuführen sind. Bei RT2 sind es ganze 52,8 Prozent. RT7 hat mit einem ICC von 0,313 den niedrigsten Wert, während in RT5 62,1 Prozent der Gesamtvarianz erklärt werden können.

Die Between Varianz von M1 in Tabelle 22 gibt an, wie stark die Mittelwerte des Innovationsoutputs der Kreise um das Gesamtmittel schwanken. Auch die dazugehörige Standardabweichung ist abgebildet und bei der Interpretation mit einzubeziehen. Die Within Varianz in Tabelle 22 ist die Gemeindeebenen Varianz. Sie sagt aus, wie stark im Durchschnitt der Innovationsoutput innerhalb eines Kreises um den mittleren Innovationsoutput im Kreis schwankt. Der Fixed Intercept in der letzten Spalte der Tabelle gibt den erwartete

Darstellung der quantitativen Ergebnisse

durchschnittlichen Innovationsoutput einer zufällig ausgewählten Gemeinde aus einem zufällig ausgewählten Kreis an.

Tabelle 22: M1 Random Effekte

| | | Deviance | Between Varianz | Std. Abw. | Within Varianz | Std. Abw. | Fixed Intercept | |
|------------|---|----------|-----------------|-----------|----------------|-----------|-----------------|-------|
| REGIONSTYP | 1 | 1.260 | 3.665,7 | 0,477 | 0,691 | 0,825 | 0,908 | 1,510 |
| | 2 | 247 | 713,5 | 0,570 | 0,755 | 0,534 | 0,731 | 1,737 |
| | 3 | 38 | - | - | - | - | - | - |
| | 4 | 1.378 | 4.578,7 | 0,436 | 0,660 | 1,256 | 1,121 | 1,628 |
| | 5 | 242 | 725,5 | 1,059 | 1,029 | 0,646 | 0,804 | 1,282 |
| | 6 | 2.295 | 7.213,1 | 0,486 | 0,697 | 1,181 | 1,087 | 1,284 |
| | 7 | 2.017 | 6.248,7 | 0,355 | 0,596 | 1,096 | 1,047 | 0,903 |
| | 8 | 2.218 | 6.671,7 | 0,481 | 0,693 | 1,002 | 1,001 | 1,198 |
| | 9 | 748 | 2.536,5 | 0,569 | 0,754 | 1,247 | 1,117 | 1,475 |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Quellen: Eigene Darstellung und Berechnung.

Anhand der Between und der Within Varianzen lässt sich der Adjusted ICC des Modells berechnen. Dieser ist in Tabelle 21 abgebildet. Folgende Aussagen lassen sich anhand der M1 Adjusted ICCs der Regionstypen treffen. In RT1 sind 36,8 Prozent der Gesamtvarianz auf Unterschiede zwischen den Kreisen zurückzuführen. In RT5 ist der höchste Erklärungsgehalt zwischen den Kreisunterschieden bei 62,4 Prozent. Bei RT7 liegt der niedrigste Wert mit 24,5 Prozent vor.

Es folgt Modell 2, das *Random-Intercept-Modell*. Es schätzt mehreren unabhängigen Variablen auf beiden Ebenen. Anhand dieses Modells lässt sich H2 überprüfen: *Auf der Gemeindeebene gibt es einen positiven Effekt der sozioökonomischen Struktur und der Digitalisierung der Gemeinden auf den Innovationsoutput einer Gemeinde*. Es wird festgestellt, wie viel der Gemeindeebenen-Varianz sich durch die einzelnen Variablen erklären lässt. Weiter führt es zu der Aussage, welcher Anteil der Gesamtvarianz (beider Ebenen) durch die Kreisebenen Variablen erklärt werden kann. Außerdem ist festzustellen, inwieweit sich das Modell insgesamt durch die Hinzunahme der unabhängigen Variablen verbessert. Dies wird für die acht Regionstypen untersucht.

In der vierten Spalte von Tabelle 21 ist der Modell 2: Adjusted ICC aufgeführt. Er gibt Aussage darüber aus wieviel Gemeindeebenenvarianz durch die unabhängigen Variablen erklärt wird. Dieser lässt sich wie folgt interpretieren. Nach der Aufnahme der unabhängigen Gemeinde- und Kreisebenenvariablen in M2 für RT1, verkleinert sich der unerklärte Anteil auf 23,5 Prozent. In

Darstellung der quantitativen Ergebnisse

der nächsten Spalte lässt sich herausfinden welchen Anteil der Gesamtvarianz durch die Prädiktoren erklärt wird. Dazu wird die Differenz des M1 Adjusted ICCs und des M2 Adjusted ICCs berechnet. Das Ergebnis ist der Erklärungsanteil der abhängigen Variablen. Die aufgenommenen Variablen tragen in RT1 anteilig mit 13,6 Prozent zur Varianzerklärung bei. Aus der Tabelle 21 lassen sich anhand des Modell 2 Adjusted ICCs für RT1, RT2 und RT4 bis RT9 ablesen, dass die Hinzunahme der Kontrollvariablen zur Verbesserung der Modelle beiträgt. Am deutlichsten ist dies in RT2 zu vermerken (20,1 Prozent) und die geringste Verbesserung findet in RT7 statt (4,7 Prozent).

Tabelle 23 zeigt die Random Effekte des M2. Die Werte aus den Tabellen werden miteinander verglichen. Zunächst zur Deviance. Diese ist für die M2 der Regionstypen in jedem Fall niedriger als M1. Entsprechend verbessert sich die Modellgüte. Im nächsten Schritt lässt durch Zunahme der Tabelle 23 ableiten, ob die die Within und Between Varianzen in M2 zurückgehen oder zunehmen. Die Between Varianzen, also zwischen den Kreisen, haben sich im Vergleich zu den M1 Varianzen aller Regionstypen verkleinert. Bezugnehmend auf die Within Varianzen, also innerhalb der Kreise, lässt sich ablesen, dass diese nur in RT4 und RT7 nicht kleiner wurden. Da die Deviance des M2 jedoch geringer ist als die von M1 kann die HLM weitergeführt werden.

Tabelle 23: M2 Random Effekte

| | | Deviance | Between Varianz | Std. Abw. | Within Varianz | Std. Abw. |
|------------|---|----------|-----------------|-----------|----------------|-----------|
| | 1 | 1.260 | 3.529,3 | 0,244 | 0,494 | 0,899 |
| | 2 | 247 | 656,1 | 0,269 | 0,159 | 0,761 |
| | 3 | 38 | - | - | - | - |
| REGIONSTYP | 4 | 1.378 | 4.499,6 | 0,297 | 0,545 | 1,108 |
| | 5 | 242 | 702,3 | 0,739 | 0,860 | 0,812 |
| | 6 | 2.295 | 7.043,5 | 0,281 | 0,530 | 1,065 |
| | 7 | 2.017 | 6.180,1 | 0,266 | 0,515 | 1,077 |
| | 8 | 2.218 | 6.564,1 | 0,320 | 0,566 | 0,986 |
| | 9 | 748 | 2.458,0 | 0,330 | 0,575 | 1,206 |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Quellen: Eigene Darstellung und Berechnung.

Weiter sind die Fixen Effekte von M2 zu betrachten. Diese sind in den kommenden Tabellen aufgeführt. Es lassen sich für die acht betrachteten Regionstypen unterschiedliche Effekte auf Gemeindeebene erkennen. Diese werden für die einzelnen Regionstypendatensätze interpretiert. Hier wird dann darauf eingegangen, ob die Prädiktoren einen signifikanten Effekt auf die

Darstellung der quantitativen Ergebnisse

abhängige Variable haben. Die Effekte werden immer unter Kontrolle der anderen unabhängigen Variablen interpretiert. Tabelle 24 zeigt die Fixen Effekte des M2 von Regionstyps 1.

Tabelle 24: Regionstyp 1 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-------|---------|-----------|
| (Intercept) | 1,57 | 0,098 | 993 | 16,118 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 0,18 | 0,08 | 1.237 | 2,290 | 0,022 * |
| F02: Mobilität und Erreichbarkeit | -0,22 | 0,04 | 1.095 | -4,971 | 0,000 *** |
| F03: Lokale Beschäftigung | 0,28 | 0,38 | 1.246 | 0,728 | 0,467 |
| F04: Hochschulbildung | 0,76 | 0,69 | 1.242 | 1,097 | 0,273 |
| F05: Lokale Arbeitsplatzattraktivität | 0,37 | 0,06 | 1.250 | 5,959 | 0,000 *** |
| F06: Soziale Infrastruktur | 0,01 | 0,03 | 1.227 | 0,283 | 0,777 |
| Digitalisierung | -0,15 | 0,40 | 1.214 | -0,376 | 0,707 |
| Ländlichkeit | -0,51 | 0,10 | 332 | -5,193 | 0,000 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

Zunächst zum ersten Regionstyp. Die aufgeführten Effekte lassen sich wie folgt interpretieren. Es sind die Effekte in RT1 über alle Kreise hinweg. Die Siedlungs- und Branchenstruktur in RT1 hat einen signifikanten positiven Effekt auf die Innovationsleistung in der Region. Zunehmend schlechte Mobilität und Erreichbarkeit bringt einen signifikant negativen Effekt mit sich. Die lokale Arbeitsplatzattraktivität im Regionstyp hat einen signifikant positiven Effekt auf den Innovationsoutput über alle Kreise hinweg. Die Ländlichkeit ist eine Variable auf Kreisebene. Sie hat einen negativ signifikanten Effekt auf die Innovationsleistung. Dies bedeutet, dass in Kreisen mit hoher Ländlichkeit die Gemeinden (c. p.) weniger innovativ sind.

In RT2 sind andere Effekte signifikant als in RT1. Die Fixen Effekte sind in Tabelle 25 abgebildet. Während der Effekt der lokalen Arbeitsplatzattraktivität positiv signifikant ist. Ist das Regressionsgewicht der sozialen Infrastruktur negativ. Steigt die soziale Infrastruktur sinkt der Innovationsoutput der Region. Die Ländlichkeit hat wieder die gleiche Wirkrichtung wie in RT1. Nimmt die Ländlichkeit zu, nimmt der Innovationsoutput signifikant ab.

Darstellung der quantitativen Ergebnisse

Tabelle 25: Regionstyp 2 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-----|---------|-----------|
| (Intercept) | 1,68 | 0,19 | 235 | 8,624 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 0,01 | 0,06 | 220 | 0,185 | 0,853 |
| F02: Mobilität und Erreichbarkeit | -0,17 | 0,09 | 221 | -1,882 | 0,061 . |
| F03: Lokale Beschäftigung | 0,02 | 0,13 | 219 | 0,185 | 0,854 |
| F04: Hochschulbildung | 0,01 | 0,02 | 226 | 0,404 | 0,687 |
| F05: Lokale Arbeitsplatzattraktivität | 0,72 | 0,12 | 237 | 6,185 | 0,000 *** |
| F06: Soziale Infrastruktur | -0,27 | 0,10 | 234 | -2,843 | 0,005 ** |
| Digitalisierung | -0,91 | 1,85 | 233 | -0,490 | 0,624 |
| Ländlichkeit | -0,30 | 0,12 | 238 | -2,556 | 0,011 * |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

In Tabelle 26 unten sind die Fixen Effekte von RT4 dargestellt. Bei der Spalte Estimate handelt es sich über die Effekte der jeweiligen Variablen über alle Kreise hinweg. Die Siedlungs- und Branchenstruktur hat einen hoch signifikanten positiven Effekt während mit zunehmend schlechter Mobilität und Erreichbarkeit der Region der Innovationsoutput sinkt. Die lokale Beschäftigung, die Hochschulbildung und die lokale Arbeitsplatzattraktivität sind ebenfalls positiv signifikant. Mit zunehmender Ländlichkeit sinkt der Innovationsoutput signifikant.

Tabelle 26: Regionstyp 4 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-------|---------|-----------|
| (Intercept) | 1,78 | 0,12 | 1.016 | 14,528 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 0,63 | 0,14 | 1.401 | 4,457 | 0,000 *** |
| F02: Mobilität und Erreichbarkeit | -0,41 | 0,10 | 1.360 | -4,091 | 0,000 *** |
| F03: Lokale Beschäftigung | 1,89 | 0,78 | 1.398 | 2,440 | 0,015 * |
| F04: Hochschulbildung | 2,63 | 0,86 | 1.408 | 3,045 | 0,002 ** |
| F05: Lokale Arbeitsplatzattraktivität | 0,23 | 0,10 | 1.409 | 2,261 | 0,024 * |
| F06: Soziale Infrastruktur | 0,13 | 0,08 | 1.407 | 1,630 | 0,103 |
| Digitalisierung | 0,29 | 0,34 | 1.310 | 0,839 | 0,402 |
| Ländlichkeit | -0,50 | 0,13 | 273 | -3,906 | 0,000 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

Für Regionstyp 5 sind nur zwei signifikante Effekte zu verzeichnen (Tabelle 27). Zunächst ein positiver Effekt der Siedlungs- und Branchenstruktur über alle Kreise hinweg. Und ein negativ signifikanter Zusammenhang der Mobilität und Erreichbarkeit mit der Innovationstätigkeit. Je schlechter eine Gemeinde zu erreichen ist, desto niedriger wird deren Innovationsoutput über alle Kreise hinweg.

Tabelle 27: Regionstyp 5 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-------|---------|-----------|
| (Intercept) | 1,37 | 0,19 | 2.055 | 7,080 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 0,31 | 0,12 | 1.900 | 2,639 | 0,009 ** |
| F02: Mobilität und Erreichbarkeit | -0,15 | 0,05 | 2.323 | -3,389 | 0,001 *** |
| F03: Lokale Beschäftigung | 0,71 | 0,61 | 2.206 | 1,154 | 0,250 |
| F04: Hochschulbildung | 0,82 | 0,50 | 1.656 | 1,656 | 0,100 . |
| F05: Lokale Arbeitsplatzattraktivität | 0,04 | 0,04 | 1.813 | 0,915 | 0,361 |
| F06: Soziale Infrastruktur | 0,04 | 0,02 | 2.023 | 1,649 | 0,101 |
| Digitalisierung | -0,38 | 0,62 | 1.822 | -0,615 | 0,539 |
| Ländlichkeit | -0,29 | 0,24 | 1.176 | -1,237 | 0,218 |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

In Tabelle 28 sind die Fixen Effekte von RT6 abgebildet. Über alle Kreise hinweg ist der Effekt der Siedlungs- und Branchenstruktur wieder positiv signifikant und die Mobilität und Erreichbarkeit negativ signifikant. Die lokale Beschäftigung und lokale Arbeitsplatzattraktivität haben weiter einen positiv signifikanten Effekt auf den Innovationsoutput in den Kreisen dieses Regionstyps. Neben der Fixen Effekte aus der HLM von Deutschland insgesamt ist in RT6 das einzige Mal der Digitalisierungseffekt positiv signifikant. Je höher die Ländlichkeit der Gemeinden, desto niedriger ist der Innovationsoutput über alle Kreise hinweg (-0,46).

Darstellung der quantitativen Ergebnisse

Tabelle 28: Regionstyp 6 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-------|---------|-----------|
| (Intercept) | 1,89 | 0,11 | 688 | 17,476 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 0,66 | 0,16 | 2.122 | 4,199 | 0,000 *** |
| F02: Mobilität und Erreichbarkeit | -0,36 | 0,05 | 2.072 | -6,581 | 0,000 *** |
| F03: Lokale Beschäftigung | 1,99 | 0,74 | 2.275 | 2,675 | 0,008 ** |
| F04: Hochschulbildung | 0,76 | 1,06 | 2.255 | 0,721 | 0,471 |
| F05: Lokale Arbeitsplatzattraktivität | 0,89 | 0,13 | 2.273 | 6,695 | 0,000 *** |
| F06: Soziale Infrastruktur | 0,09 | 0,10 | 2.280 | 0,874 | 0,382 |
| Digitalisierung | 0,41 | 0,20 | 2.148 | 2,001 | 0,046 * |
| Ländlichkeit | -0,46 | 0,14 | 268 | -3,372 | 0,001 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

Für RT7 sind über alle Kreise hinweg fünf der acht Effekte signifikant (Tabelle 29). Negativ ist wie in den anderen Regionstypen auch der Effekt der Mobilität und Erreichbarkeit. Positiv signifikant ist die Siedlungs- und Branchenstruktur des Regionstyps, sowie die Hochschulbildung. Auch die lokale Arbeitsplatzattraktivität und die soziale Infrastruktur haben bei Steigerung um eine Einheit einen positiv signifikanten Effekt auf den Innovationsoutput.

Tabelle 29: Regionstyp 7 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|------|---------|-----------|
| (Intercept) | 1,85 | 0,20 | 847 | 9,469 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 0,83 | 0,31 | 1978 | 2,710 | 0,007 ** |
| F02: Mobilität und Erreichbarkeit | -0,31 | 0,06 | 1893 | -5,102 | 0,000 *** |
| F03: Lokale Beschäftigung | 1,24 | 1,72 | 2007 | 0,719 | 0,472 |
| F04: Hochschulbildung | 3,63 | 1,27 | 2021 | 2,868 | 0,004 ** |
| F05: Lokale Arbeitsplatzattraktivität | 0,55 | 0,15 | 1994 | 3,679 | 0,000 *** |
| F06: Soziale Infrastruktur | 0,32 | 0,15 | 2027 | 2,177 | 0,030 * |
| Digitalisierung | 0,33 | 0,21 | 1933 | 1,575 | 0,115 |
| Ländlichkeit | -0,14 | 0,18 | 1603 | -0,770 | 0,443 |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

In der HLM für RT8 wurden in M2 sechs signifikante Effekte geschätzt (siehe Tabelle 30). Zunächst wie in den meisten Regionstypen ein positiver Effekt der Siedlungs- und Branchenstruktur auf den Innovationsoutput, sowie ein negativ signifikanter der Mobilität und Erreichbarkeit. Weiter ist in RT8 auch die Hochschulbildung hoch signifikant, sodass bei Steigerung dieser der Innovationsoutput ebenfalls steigt. Die lokale Arbeitsplatzbeschäftigung sowie die soziale Infrastruktur in den Gemeinden haben einen signifikant positiven Effekt auf den Innovationsoutput. Je ländlicher eine Gemeinde ist, desto weniger Innovationsoutput produziert sie.

Tabelle 30: Regionstyp 8 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value | |
|---------------------------------------|----------|------------|------|---------|---------|-----|
| (Intercept) | 2,04 | 0,13 | 833 | 15,741 | 0,000 | *** |
| F01: Siedlungs- und Branchenstruktur | 1,04 | 0,20 | 2186 | 5,155 | 0,000 | *** |
| F02: Mobilität und Erreichbarkeit | -0,38 | 0,05 | 2076 | -7,852 | 0,000 | *** |
| F03: Lokale Beschäftigung | 1,88 | 0,96 | 2188 | 1,957 | 0,050 | . |
| F04: Hochschulbildung | 2,86 | 0,75 | 2164 | 3,816 | 0,000 | *** |
| F05: Lokale Arbeitsplatzattraktivität | 0,25 | 0,08 | 2215 | 3,264 | 0,001 | ** |
| F06: Soziale Infrastruktur | 0,24 | 0,08 | 2215 | 3,087 | 0,002 | ** |
| Digitalisierung | 0,15 | 0,22 | 2121 | 0,695 | 0,487 | |
| Ländlichkeit | -0,41 | 0,15 | 263 | -2,806 | 0,005 | ** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

Die Tabelle 31 zu den Fixen Effekten des M2 listet die Regressionsgewichte des RT9 auf. Bis auf die Digitalisierung haben sieben der acht unabhängigen Variablen einen signifikanten Effekt auf den Innovationsoutput über alle Klassen hinweg. Den stärksten positiven Effekt auf die abhängige Variable hat die Hochschulbildung der Gemeinden. Danach folgt die lokale Beschäftigung, dann die Siedlungs- und Branchenstruktur, die soziale Infrastruktur und abschließend die lokale Arbeitsplatzattraktivität. Steigt die Mobilität und Erreichbarkeit um eine Einheit, dann sinkt der Innovationsoutput der Gemeinden da ein negativ signifikanter Zusammenhang besteht. Die Ländlichkeit hat ebenfalls einen negativen Effekt auf den Innovationsoutput. Steigt die Ländlichkeit der Gemeinden des RT9, dann sinkt dieser. Alle Regressionsgewichte sind immer unter Kontrolle der jeweils anderen Prädiktoren zu interpretieren.

Darstellung der quantitativen Ergebnisse

Tabelle 31: Regionstyp 9 M2 Fixe Effekte

| | Estimate | Std. Error | df | t-value | p-value |
|---------------------------------------|----------|------------|-----|---------|-----------|
| (Intercept) | 2,54 | 0,19 | 612 | 13,603 | 0,000 *** |
| F01: Siedlungs- und Branchenstruktur | 1,29 | 0,24 | 736 | 5,484 | 0,000 *** |
| F02: Mobilität und Erreichbarkeit | -0,41 | 0,08 | 707 | -5,067 | 0,000 *** |
| F03: Lokale Beschäftigung | 2,81 | 1,04 | 749 | 2,700 | 0,007 ** |
| F04: Hochschulbildung | 5,05 | 1,05 | 749 | 4,801 | 0,000 *** |
| F05: Lokale Arbeitsplatzattraktivität | 0,15 | 0,07 | 758 | 2,120 | 0,034 * |
| F06: Soziale Infrastruktur | 0,45 | 0,10 | 760 | 4,584 | 0,000 *** |
| Digitalisierung | -0,03 | 0,42 | 697 | -0,074 | 0,941 |
| Ländlichkeit | -0,65 | 0,19 | 228 | -3,467 | 0,001 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quellen: Eigene Darstellung und Berechnung.

Um zu prüfen, ob sich der Einfluss der unabhängigen Variablen auf Gemeindeebenen zwischen den Kreisen unterscheidet, wird für die Regionstypen jeweils ein *Random-Slope-Modell* (M3) berechnet. Es gilt H3 zu überprüfen:

H3: *Die Effekte der sozioökonomischen Struktur und der Digitalisierung der Gemeinden unterscheiden sich zwischen den Kreisen.*

Bei der Berechnung in R wurden die Prädiktoren (Gemeindeebene) zunächst alle in die Modellgleichung eingefügt. Die Ländlichkeit konnte hier nicht mit einbezogen werden, da hier keine Random Effekte auf der obersten Modellebene möglich sind. Dies führte bei allen acht Regionstypen zu einem Warnhinweis, denn die Modelle konvergierten nicht. Dies ist auf eine zu geringe Varianz der Random Effekte zurückzuführen. In den nächsten Schritten wurden die einzelnen Variablen testweise aus den Random Effekten herausgenommen. Die einbezogenen Random Effekte unterscheiden sich je nach Datensatz der Regionstypen. Die in Tabelle 33 mit Varianzwerten aufgeführten Faktoren konnten in das jeweilige Modell mit aufgenommen werden.

Es werden die Varianz der Random Slope und der Fixed Slopes von M3 verglichen. Fixe Effekte sind im Rahmen der HLM-Effekte, die über alle Kreise hinweg geschätzt werden. Random Effekte hingegen sind solche, die sich zwischen den Kreisen unterscheiden. Sie zeigen das Ausmaß der Schwankungen in den Effekten zwischen den verschiedenen Kreisen an. In Tabelle 32 (S. 146) werden die Varianzen der Random Slopes der Regionstyp aus M3 zusammengefasst dargestellt.

Darstellung der quantitativen Ergebnisse

Tabelle 32: M3 Random Slope Varianzen

| Regionstypen | 1 (n = 1.260) | | 4 (n=1.378) | | 5 (n=242) | | 6 (n=2.295) | | 7 (n=2.017) | | 8 (n=2.218) | | 9 (n=748) | |
|-----------------|------------------|-----------|----------------|-----------|--------------|-----------|----------------|-----------|----------------|-----------|----------------|-----------|--------------|-----------|
| | Variance | Std. Dev. | Variance | Std. Dev. | Variance | Std. Dev. | Variance | Std. Dev. | Variance | Std. Dev. | Variance | Std. Dev. | Variance | Std. Dev. |
| Intercept | 0,277 | 0,527 | 0,541 | 0,735 | 0,312 | 0,559 | 0,326 | 0,571 | 0,788 | 0,888 | 0,240 | 0,489 | 0,387 | 0,622 |
| F01 | 0,035 | 0,187 | | | | | 0,253 | 0,503 | | | 0,192 | 0,438 | 0,183 | 0,428 |
| F02 | | | 0,133 | 0,365 | | | | | 0,008 | 0,089 | | | | |
| F03 | 0,493 | 0,702 | | | | | 18,705 | 4,325 | 14,120 | 3,758 | 2,868 | 1,693 | | |
| F04 | | | 0,426 | 0,653 | | | 7,491 | 2,737 | 52,148 | 7,221 | 5,564 | 2,359 | | |
| F05 | | | | | 0,024 | 0,155 | 0,541 | 0,736 | | | | | | |
| F06 | | | | | | | 0,067 | 0,259 | | | | | 0,152 | 0,390 |
| Digitalisierung | 1,227 | 1,108 | 1,618 | 1,272 | | | 0,055 | 0,235 | | | | | | |
| Residual | 0,773 | 0,879 | 1,190 | 1,091 | 8,466 | 2,910 | 1,091 | 1,045 | 1,060 | 1,029 | 0,960 | 0,980 | 1,081 | 1,040 |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 Einwohner*innen)

Quelle: Eigene Darstellung und Berechnung.

In der Tabelle sind die Varianzen der Random Slopes aufgeführt, welche mit in die jeweilige Modellgleichung aufgenommen wurden. Für RT1 ist dies F01, F03 und die Digitalisierung. Bei den anderen Effekten lag eine zu geringe Schätzung vor, sodass dies zu Schätzproblemen bzw. nicht konvergierten Modellen führte. Die Varianz der Fixen Slope für F01 beträgt 0,216, während die der Random Slope bei 0,035 (Standardabweichung 0,187) liegt. Für F03 wird eine Varianz der Fixen Slope von 0,613 geschätzt, die Random Slope Varianz liegt bei 0,493 (Standardabweichung 0,702). Für beide Faktoren gilt, dass eine deutliche Schwankung zwischen den Kreisen vorliegt. Die Varianz der Random Slope der Digitalisierung zwischen den Kreisen in RT1 ist mit 1,227 deutlich größer als die Varianz der Fixen Slope (-0,339). Die Varianzen wurden auf Signifikanz geprüft.

RT2 ist in der obenstehenden Tabelle nicht aufgeführt. Für den Datensatz konnte keine gültige Parameterschätzung vorgenommen werden. Das Modell hat nicht konvergiert. Für Regionstyp 4 gilt, dass die Random Slope Varianzen von F02, F04 sowie der Digitalisierung niedriger sind als die der Fixen Slopes. Es liegt eine Schwankung der Gemeindegewerte zwischen den Kreisen vor.

Für Regionstyp 5 gilt, dass die Schwankungen zwischen den Kreisen für Faktor 05 nachgewiesen werden konnte. In den Gemeinden von Regionstyp 6 gilt dies für F01, F05 und die Digitalisierung. In Regionstyp 7 konnte durch den Vergleich der Fixen und Random Slope Varianzen der F02

Darstellung der quantitativen Ergebnisse

Schwankungen diesbezüglich zwischen den Kreisen festgestellt werden. Bei Regionstyp 8 gilt dies für F01 und bei Regionstyp 9 für F01 und F06.

In Tabelle 32 (S. 148) konnten für die aufgeführten Regionstypen unterschiedliche Varianzen der Random Slopes verschiedener Faktoren identifiziert werden. Genauer bedeutet dies, dass eine Schwankung des Effekts der Faktoren auf den Innovationsoutput zwischen den Kreisen stattfindet. Für jeden Regionstypen betrifft dies, wie beschrieben, unterschiedliche Faktoren. In Modell 4 wurde überprüft, inwieweit diese Effekte zum Teil durch die Anwesenheit der HCs in den Kreisen abhängt. Diese Abhängigkeiten sind in Abbildung 26 beschrieben. Es gilt H4 zu überprüfen.

H4: Die HCs je 1.000 EW haben eine verstärkend positive Wirkung auf den Effekt der sozioökonomischen Struktur, der Digitalisierung und der Ländlichkeit auf die Ausprägung des Innovationsoutputs der Gemeinden.

Für die Regionstypen 1, 4, 5, 7 und 8 sind die Cross-Level-Interaktionen zwischen den Variablen nicht signifikant. Das bedeutet, dass für diese Regionstypen in Kreisen mit mehr HCs kein Effekt der sozioökonomischen Faktoren auf den Innovationsoutput der jeweiligen Gemeinden stattfindet.

Die Modelle 4 mit der Cross Level Interaktionen der Regionstypen 6 und 9 sind konvergiert und zeigen einen signifikanten Mehrebeneneffekt. Die Deviance von M4 des RT6 ist auf 6.985,5 und die Deviance von RT9 auf 2.449,2 gesunken. Die Hinzunahme der Cross-Level-Interaktionen trägt zur Modellgüte bei.

Um mit RT6 zu beginnen ist ein Blick auf die Varianzen des Random Effekts der jeweiligen Faktoren zu werfen. Diese sind in Tabelle 33 (S. 150) aufgeführt. Wenn dieser in M4 niedriger ist als in M3, bedeutet dies, dass ein Teil der Schwankungen zwischen den Kreisen im durch die Anwesenheit von HCs erklärt werden kann. Die Varianzen aus M3 sind in Tabelle 32 (S. 148) dargestellt. Die Varianz des Effekts der Siedlungs- und Branchenstruktur (F01) ist in M4 auf 0,239 gesunken und die lokale Beschäftigung (F03) sank auf 16,324. Die Varianz der lokalen Arbeitsplatzattraktivität sank von 0,541 auf 0,46. Teile der Schwankungen des jeweiligen Prädiktors zwischen den Kreisen von Regionstyp 6 können demnach durch die HC-Anzahl beeinflusst werden. Währenddessen sind die Schwankungen des Effekts der Hochschulbildung (F04) sowie der Digitalisierung in M4 gestiegen. Anhand der Fixen Effekte aus der Tabelle lässt sich ablesen, dass nur die Interaktion zwischen der Digitalisierung und der HCs je 1.000 EW

Darstellung der quantitativen Ergebnisse

signifikant ist. Daraus lässt sich ableiten, dass in Kreisen in welchen viele HCs angesiedelt sind der Effekt der Digitalisierung stärker ist als in Kreisen mit wenigen HCs je 1.000 EW.

Tabelle 33: Random und Fixe Effekte M4 Regionstyp 6

| | Varianz | Std. Dev |
|---------------------------------------|---------|----------|
| (Intercept) | 0,276 | 0,526 |
| F01: Siedlungs- und Branchenstruktur | 0,239 | 0,489 |
| F03: Lokale Beschäftigung | 16,324 | 4,040 |
| F04: Hochschulbildung | 7,891 | 2,809 |
| F05: Lokale Arbeitsplatzattraktivität | 0,460 | 0,678 |
| F06: Soziale Infrastruktur | 0,068 | 0,261 |
| Digitalisierung | 0,446 | 0,668 |
| Residual | 1,084 | 1,041 |

| | Estimate | Std. Error | t-value | p-value | sig. |
|---------------------------------------|----------|------------|---------|---------|------|
| (Intercept) | 1,44 | 0,11 | 12,88 | 0,00 | *** |
| F01: Siedlungs- und Branchenstruktur | 0,49 | 0,16 | 3,05 | 0,00 | ** |
| F02: Mobilität und Erreichbarkeit | -0,38 | 0,05 | -7,76 | 0,00 | *** |
| F03: Lokale Beschäftigung | 0,93 | 0,83 | 1,13 | 0,26 | |
| F04: Hochschulbildung | 0,76 | 1,08 | 0,71 | 0,48 | |
| F05: Lokale Arbeitsplatzattraktivität | 0,99 | 0,14 | 7,11 | 0,00 | *** |
| F06: Soziale Infrastruktur | 0,05 | 0,10 | 0,45 | 0,66 | |
| Digitalisierung | 1,07 | 0,25 | 4,34 | 0,00 | *** |
| HC je 1000 EW (log) | -2,48 | 1,37 | -1,81 | 0,07 | . |
| F01:HC je 1000 EW (log) | -1,50 | 1,58 | -0,95 | 0,34 | |
| F03:HC je 1000 EW (log) | 5,51 | 10,33 | 0,53 | 0,59 | |
| F04:HC je 1000 EW (log) | -6,53 | 14,27 | -0,46 | 0,65 | |
| F05:HC je 1000 EW (log) | -2,17 | 1,55 | -1,40 | 0,16 | |
| F06:HC je 1000 EW (log) | 0,52 | 1,19 | 0,44 | 0,66 | |
| Digitalisierung:HC je 1000 EW (log) | 7,85 | 3,31 | 2,37 | 0,02 | * |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Darstellung der quantitativen Ergebnisse

In Tabelle 34 sind die Random und Fixen Effekte des Regionstyps 9 aufgeführt. Diese sind ebenfalls mit den Varianzen der Effekte der Faktoren aus Tabelle 32 (S. 148) zu vergleichen. Die Varianz der Siedlungs- und Branchenstruktur ist an dieser Stelle von 0,183 auf 0,176 gesunken. Die Varianz der sozialen Infrastruktur ist jedoch von 0,152 auf 0,174 gestiegen. Für Regionstyp 9 lässt sich feststellen, dass die Schwankungen der sozialen Infrastruktur zwischen den Kreisen nicht durch die HC-Anzahl beeinflusst wird. In den Fixen Effekten aus M4 des Regionstypen zeigt sich ein statistisch signifikanter positiver Zusammenhang des Interaktionseffekts der Siedlungs- und Branchenstruktur mit den HCs je 1.000 EW. Für Kreise mit einer hohen Anzahl von HCs je 1.000 EW gilt, dass dort der Effekt der Siedlungs- und Branchenstruktur auf den Innovationsoutput gesteigert wird.

Tabelle 34: Random Effekte M4 Regionstyp 9

| | Varianz | Std. Dev |
|--------------------------------------|---------|----------|
| (Intercept) | 0,385 | 0,620 |
| F01: Siedlungs- und Branchenstruktur | 0,176 | 0,419 |
| F06: Soziale Infrastruktur | 0,174 | 0,417 |
| Residual | 1,067 | 1,033 |

| | Estimate | Std. Error | t-value | p-value | sig. |
|---------------------------------------|----------|------------|---------|---------|------|
| (Intercept) | 2,02 | 0,21 | 9,69 | 0,00 | *** |
| F01: Siedlungs- und Branchenstruktur | 1,39 | 0,23 | 5,91 | 0,00 | *** |
| F02: Mobilität und Erreichbarkeit | -0,46 | 0,08 | -6,05 | 0,00 | *** |
| F03: Lokale Beschäftigung | 3,15 | 1,00 | 3,15 | 0,00 | ** |
| F04: Hochschulbildung | 5,01 | 1,04 | 4,83 | 0,00 | *** |
| F05: Lokale Arbeitsplatzattraktivität | 0,13 | 0,07 | 1,80 | 0,07 | . |
| F06: Soziale Infrastruktur | 0,45 | 0,11 | 4,18 | 0,00 | *** |
| Digitalisierung | 1,16 | 0,48 | 2,41 | 0,02 | * |
| HC je 1000 EW (log) | -0,52 | 0,30 | -1,73 | 0,08 | . |
| F01:HC je 1000 EW (log) | -1,04 | 0,46 | -2,27 | 0,02 | * |
| F06:HC je 1000 EW (log) | -0,84 | 0,45 | -1,85 | 0,07 | . |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

12.4 Räumliche Regressionsanalyse

Im finalen methodischen Schritt wurde eine räumliche Regressionsanalyse durchgeführt. Das Vorgehen wurde bereits in Kapitel 9.5 vorgestellt. Durchgeführt wurde die Analyse für den Gesamttraum Deutschland auf Gemeindeebene. Einbezogen wurden 10.552 Gemeinden (Gebietsstand 2016). Die abhängige Variable war, wie bei der Regressionsanalyse zuvor, der Innovationsoutput. Die unabhängigen Variablen sind die HCs je 1.000 EW, die sechs sozioökonomischen Faktoren (F01 bis F06), sowie die Digitalisierung der Gemeinden. Zunächst wurde eine OLS-Regressionsmodell geschätzt. Dessen Ergebnisse sind in Tabelle 36 dargestellt.

Hier gilt, dass wenn die Anzahl der HCs je 1.000 EW um ein Prozent ansteigt, dann steigert sich (c. p.) der Innovationsoutput im Durchschnitt um 0,44 Prozent. Ebenfalls ein positiver signifikanter Effekt ist bei der Siedlung- und Branchenstruktur (F01) abzulesen. Steigt sie um eine Einheit (c. p.), steigert sie den Innovationsoutput im Durchschnitt um (ca. 16 Prozent). Verbessert sich die Mobilität und Erreichbarkeit um eine Einheit (c. p.), dann steigert dies den Innovationsoutput um 26,4 Prozent. Die lokale Beschäftigung sowie die Hochschulbildung auf Gemeindeebene haben keinen signifikanten Effekt auf den Innovationsoutput. Steigert sich jedoch die lokale Arbeitsplatzattraktivität um eine Einheit, dann steigt der Innovationsoutput um 10,2 Prozent. Bezogen auf die soziale Infrastruktur ist dieser Effekt mit 5,7 Prozent zu beschreiben. Für die Digitalisierung gilt, dass wenn diese um ein Prozent steigt, dies den Innovationsoutput um 2,03 Prozent steigert.

Darstellung der quantitativen Ergebnisse

Tabelle 35: Ergebnisse der multiplen Regression

| | Estimate | Std. Error | t-value | p-value | |
|---------------------------------------|----------|------------|---------|---------|-----|
| (Intercept) | 0,721 | 0,022 | 32,507 | 0,000 | *** |
| Hidden Champions je 1.000 EW (log) | 0,438 | 0,116 | 3,789 | 0,000 | *** |
| F01: Siedlungs- & Branchenstruktur | 0,160 | 0,012 | 13,513 | 0,000 | *** |
| F02: Mobilität & Erreichbarkeit | -0,264 | 0,012 | -22,681 | 0,000 | *** |
| F03: Lokale Beschäftigung | -0,005 | 0,011 | -0,464 | 0,643 | |
| F04: Hochschulbildung | 0,020 | 0,011 | 1,732 | 0,083 | . |
| F05: Lokale Arbeitsplatzattraktivität | 0,102 | 0,012 | 8,624 | 0,000 | *** |
| F06: Soziale Infrastruktur | 0,057 | 0,011 | 5,002 | 0,000 | *** |
| Digitalisierung (log) | 2,026 | 0,096 | 21,196 | 0,000 | *** |

p-value: ,000 ***

Adjusted R-squared: 0,1548

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 EW) (log)

Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Im nächsten Schritt erfolgt der Test auf räumliche Autokorrelation. Zunächst musste dazu eine räumliche Gewichtungsmatrix berechnet werden. Die Tabelle 36 gibt einen Einblick auf die Nachbarschaftsverteilungen auf Gemeindeebene des analysierten Datensatzes. Insgesamt wurden 10.534 Gemeinden mit in die Berechnung der Global Moran's I Teststatistik der Residuen aufgenommen. 60.586 Nachbarschaften (Links) konnten identifiziert werden. Im Durchschnitt hat eine Gemeinde in Deutschland 5,75 Nachbarn. 18 Gemeinden mussten aus der Kalkulation entnommen werden. Hierbei handelt es sich um die deutschen Inseln, welche aufgrund ihrer Lage keine Nachbarn haben.

Darstellung der quantitativen Ergebnisse

Tabelle 36: Nachbarschaftsverteilung nach der Queens-Kontiguität

| Nachbarschaftsverteilung | | | | | |
|--------------------------|------------------|--------------|------------------|--------------|------------------|
| Anzahl Links | Anzahl Gemeinden | Anzahl Links | Anzahl Gemeinden | Anzahl Links | Anzahl Gemeinden |
| 1 | 51 | 9 | 383 | 17 | 3 |
| 2 | 215 | 10 | 184 | 18 | 5 |
| 3 | 750 | 11 | 115 | 19 | 2 |
| 4 | 1.786 | 12 | 61 | 20 | 1 |
| 5 | 2.431 | 13 | 37 | 21 | 5 |
| 6 | 2.226 | 14 | 20 | 22 | 2 |
| 7 | 1.435 | 15 | 11 | 27 | 1 |
| 8 | 802 | 16 | 6 | 29 | 2 |

Quelle: Eigene Darstellung und Berechnung.

Die globale Moran's I Teststatistik liegt bei 0,208 und ist statistisch hoch signifikant (p-value: 0,000). Diese Werte geben einen Hinweis auf eine positive räumliche Autokorrelation des Innovationsoutputs auf Gemeindeebene. Die Residuen hängen systematisch miteinander zusammen. Es gilt das oben beschriebene Regressionsmodell als räumliches Regressionsmodell umzuformen, um die räumliche Autokorrelation zu berücksichtigen. Die durchgeführte Interpretation ist zu vernachlässigen.

Die Durchführung des Lagrange Multiplier Tests zu Entscheidung über ein Spatial Error oder Spatial Lag Modell ergab folgende Schätzungen: Spatial Error Model: LMerr = 1227,7, df = 1, p-value: 0,000*** und das Spatial Lag Modell: LMLag = 1659,7, df = 1, p-value: 0,000***. Wenn beide p-values unter 0,05 liegen, muss die robuste Teststatistik betrachtet werden. Wenn beide robusten Teststatistiken signifikant sind, dann wird die "größte" robuste Teststatistik einbezogen. Da dies der Fall war wurden die robusten Statistiken RLMerr (211,45, df = 1, p-value: 0,000***) und RLMlag (643,52, df = 1, p-value: 0,000***) berechnet. In dieser Arbeit wird sich anhand der RMLlag Statistik für ein SLM entschieden. Zusätzlich zur Statistik wurde in die Modellentscheidung die Zielsetzung der Fragestellung miteinbezogen.

In Tabelle 37 sind die Ergebnisse des Spatial Lag (räumliche Verzögerung) Modells aufgeführt. Der räumlich autoregressive Parameter Rho und dessen Likelihood Ratio Test (LR) sind statistisch signifikant (p-value: 0,000). Rho (0,427) gibt die räumliche Verzögerung (Spatial Lag) im Modell an. Es ist eine zusätzliche erklärende Variable des Modells. Die Variable misst den Innovationsoutput in den Nachbargemeinden. Dadurch wird die durch den Moran's I festgestellte räumliche Clusterung der Daten berücksichtigt. Rho lässt sich wie folgt interpretieren: Wenn der

Darstellung der quantitativen Ergebnisse

Innovationsoutput in der Nachbarschaft ansteigt, steigt dieser auch in der betrachteten Gemeinde, selbst unter Berücksichtigung der erklärenden Variablen.

Tabelle 37: Spatial Lag Modell

| | Estimate | Std. Error | z-value | p-value |
|---------------------------------------|----------|------------|---------|-----------|
| (Intercept) | 0,377 | 0,024 | 15,813 | 0,000 *** |
| Hidden Champions je 1.000 EW (log) | 0,358 | 0,107 | 3,343 | 0,001 *** |
| F01: Siedlungs- & Branchenstruktur | 0,101 | 0,011 | 9,069 | 0,000 *** |
| F02: Mobilität & Erreichbarkeit | -0,158 | 0,012 | -13,498 | 0,000 *** |
| F03: Lokale Beschäftigung | -0,002 | 0,011 | -0,210 | 0,833 |
| F04: Hochschulbildung | 0,015 | 0,011 | 1,406 | 0,160 |
| F05: Lokale Arbeitsplatzattraktivität | 0,077 | 0,011 | 6,881 | 0,000 *** |
| F06: Soziale Infrastruktur | 0,050 | 0,011 | 4,679 | 0,000 *** |
| Digitalisierung (log) | 1,231 | 0,089 | 13,812 | 0,000 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1.000 EW)
 Anzahl der Beobachtungen: 10.534
 AIC: 32.015, AIC lm: 33.241; Rho: 0,427, LR test value: 1.228,6, p-value: 0,000
 Asymptotic standard error: 0,012
 z-value: 34,93, p-value: 0,000
 Wald statistic: 1220,4, p-value: 0,000
 Log likelihood for lag model: -15.996,34
 ML residual variance (sigma squared): 1,18, sigma: 1,085
 LM test for residual autocorrelation: 635,47, p-value: 0,000

Quelle: Eigene Darstellung und Berechnung.

Da der LR-Test statistisch signifikant ist, ist dies ein erste Hinweis auf eine bessere Modellgüte als bei der multiplen Regression. Weiter wird das Akaike Information Cirterion (AIC) mit einbezogen. Der AIC des Spatial Lag Modells liegt bei 32.015, während der des multiplen Modells höher ist und bei 33.241 liegt. Das Spatial Lag Modell ermöglicht eine bessere Modellgüte.

Durch die Einbeziehung der räumlichen Verzögerung (Rho) (Maß für Innovationsoutput in den Nachbargemeinden) wird indirekt auch die Wirkung der unabhängigen Variablen auf den Innovationsoutput in den benachbarten Gemeinden berücksichtigt. Die Effekte der jeweiligen unabhängigen Variablen sind also die Summe von zwei bestimmten Wirkungen: eine direkte, lokale Wirkung der Kovariate in dieser Gemeinde A und eine indirekte, durch die räumliche Verzögerung (spatial lag) bedingte Spilloverwirkung aus den Nachbargemeinden. Die direkte Auswirkung des Prädiktors einer Gemeinde auf ihr eigenes Ergebnis (Innovationsoutput) sowie die indirekte Auswirkung (Spillover) des Prädiktors aus den Nachbargemeinden auf das Ergebnis in der eigenen Gemeinde. Diese drei unterschiedlichen Größen sind in Tabelle 38 aufgeführt.

Darstellung der quantitativen Ergebnisse

Tabelle 38: Direkte und indirekte Effekte Spatial Lag Modell

| | Direkter Einfluss | p-value | Indirekter Einfluss | p-value | Summe Einflüsse | p-value |
|---------------------------------------|-------------------|-----------|---------------------|-----------|-----------------|-----------|
| Hidden Champions je 1.000 EW (log) | 0,372 | 0,001 *** | 0,253 | 0,001 *** | 0,625 | 0,001 *** |
| F01: Siedlungs- & Branchenstruktur | 0,105 | 0,000 *** | 0,071 | 0,000 *** | 0,176 | 0,000 *** |
| F02: Mobilität & Erreichbarkeit | -0,165 | 0,000 *** | -0,112 | 0,000 *** | -0,276 | 0,000 *** |
| F03: Lokale Beschäftigung | -0,002 | 0,878 | -0,002 | 0,878 | -0,004 | 0,878 |
| F04: Hochschulbildung | 0,015 | 0,176 | 0,011 | 0,177 | 0,026 | 0,176 |
| F05: Lokale Arbeitsplatzattraktivität | 0,081 | 0,000 *** | 0,055 | 0,000 *** | 0,135 | 0,000 *** |
| F06: Soziale Infrastruktur | 0,052 | 0,000 *** | 0,035 | 0,000 *** | 0,086 | 0,000 *** |
| Digitalisierung (log) | 1,279 | 0,000 *** | 0,869 | 0,000 *** | 2,148 | 0,000 *** |

Abhängige Variable: Innovationsoutput (Patentanmeldungen je 1000 Einwohner*innen) (log)
 Signif. codes: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1

Quelle: Eigene Darstellung und Berechnung.

Außer der lokalen Beschäftigung (F03) und der Hochschulbildung (F04) sind alle anderen unabhängigen Variablen aus dem Modell statistisch hoch signifikant. Die Werte lassen sich wie folgt interpretieren. Steigt die Anzahl der HCs in der eigenen Gemeinde um ein Prozent, so verändert sich (c. p.) der Innovationsoutput der Gemeinde im Durchschnitt um 0,372 Prozent. Steigt die Anzahl der HCs in den Nachbargemeinden um ein Prozent, dann steigert dies den Innovationsoutput um 0,253 Prozent.

Bei Steigerung der Siedlungs- und Branchenstruktur (F01) in der eigenen Gemeinde um eine Einheit, steigt der Innovationsoutput im Durchschnitt um 10,5 Prozent. Steigt F01 um eine Einheit in den Nachbargemeinden, steigert dies den Innovationsoutput in der eigenen Gemeinde um durchschnittlich 7,1 Prozent.

Weiter zur Mobilität und Erreichbarkeit (F02). Steigt die Mobilität und Erreichbarkeit in der eigenen Gemeinde um eine Einheit, dann sinkt der Innovationsoutput um 16,5 Prozent. Die Effekte des Prädiktors aus den Nachbargemeinden liegen bei -11,2 Prozent. Zur Erinnerung, wenn die Mobilität und Erreichbarkeit steigen, bedeutet dies eine höhere Distanz also eine schlechtere Erreichbarkeit und Mobilität.

Die lokale Arbeitsplatzattraktivität hat einen etwas geringeren Effekt als die vorangehenden sozioökonomischen Faktoren. Steigt F05 um eine Einheit in der eigenen Gemeinde, dann steigt der Innovationsoutput um durchschnittlich 8,1 Prozent. Durch Steigerung von F05 in den Nachbargemeinden steigt der Innovationsoutput im Mittel um 5,5 Prozent.

Darstellung der quantitativen Ergebnisse

Die soziale Infrastruktur (F06) verändert bei Steigerung um eine Einheit den Innovationsoutput um durchschnittlich 5,2 Prozent. Der indirekte Effekt aus den Nachbargemeinden beinhaltet durchschnittlich eine Steigerung um 3,5 Prozent.

Abschließend wird der Digitalisierungsprädiktor betrachtet. Auch dieser ist hoch signifikant. Steigt die Digitalisierung in der eigenen Gemeinde um ein Prozent, dann steigert dies den Innovationsoutput durchschnittlich um 1,279 Prozent. Die indirekten Effekte steigern den Innovationsoutput um 0,869 Prozent.

13 Ergebnisdiskussion

In diesem Kapitel werden die Ergebnisse zur Beantwortung der Forschungsfragen zusammengefasst und unter Berücksichtigung der betrachteten Literatur und theoretischen Grundlagen diskutiert. Das Kapitel ist in drei Unterkapitel eingeteilt. Im ersten Unterkapitel werden die Ergebnisse zur *Identifizierung des Untersuchungsgegenstandes* aufgezeigt. Im zweiten Unterkapitel erfolgt die Ergebnisdiskussion der *regionalen Typisierung*. Die Diskussion und Zusammenfassung zur Beantwortung der Forschungsfragen zu regionalen *Wirkungszusammenhängen* erfolgt dann abschließend im dritten Unterkapitel.

13.1 Identifizierung des Untersuchungsgegenstands

1. *Wie werden HCs in der Literatur definiert und mit welchen Inhalten beschäftigt sich die HCs-Forschung?*

Die in Kapitel 4 vorgenommene detaillierte Analyse der HC-Literatur zeigt, dass die allgemein verwendete HC-Definition diejenige von Simon (2012) ist. Zu diesem Ergebnis kommt auch Schenkenhofer (2022, S. 445). Die drei von Simon (2012, S. 83) festgelegten Identifizierungskriterien dienen vielen Studien als definitorische Basis. Die Umformulierung zu abweichenden Arbeitsdefinitionen beschränkt sich jedoch nicht nur auf länderspezifische Definitionen, wie Schenkenhofer (2022, S. 445) schlussfolgert. In der Empirie wird entweder auf die durch Simons Veröffentlichungen bekannten Unternehmen zurückgegriffen oder es wird eine abweichende Arbeitsdefinition abgeleitet. Je nach Datenverfügbarkeit und Umfang der Studie werden die Kriterien angepasst. Dazu kommt, dass der Untersuchungsraum einen Einfluss auf die HC-Definition haben kann. So passen Autor:innen, die beispielsweise österreichische oder asiatische HCs identifizieren möchten, die Definition noch einmal länderspezifisch an (u.a. Jungwirth & König 2019; Yu & Chen 2009). Es lässt sich schlussfolgern, dass die Definition der HCs nach Simon (2012) als richtungsweisend und Basis für die Identifizierung der HCs dienen kann. Da jedoch die Defizite in der Anwendung der Definition auf empirische Arbeiten bisher nur durch abweichende Arbeitsdefinitionen behoben werden konnten, wurde die Notwendigkeit einer Operationalisierung der Kriterien bestätigt.

Die Erfolgsstrategien der HCs werden ausführlich beforscht. So fokussiert sich ein Großteil der Forschung entweder auf die *Innovationsaktivitäten* der Unternehmensstrategie oder auf die *Internationalisierung* der HCs. Thematisch beinhaltet die wissenschaftliche Diskussion außerdem Analysen zu Marketingstrategien oder auch finanzpolitischen Fragestellungen (u.a. Jungwirth

Ergebnisdiskussion

2010; Johann et al. 2021). Andere Arbeiten untersuchen die Unternehmenskultur von HCs beispielsweise durch die Analyse der CSR (Jungwirth & König 2019). Seit einigen Jahren werden die Erfolgsstrategien der HCs häufig im Kontext der Digitalisierung analysiert (u.a. Rietmann 2021b, Rietmann 2022b; Simon 2020; Wittenstein 2022). Viele Arbeiten vergleichen die Strategien von HCs mit Nicht-HCs, Familienunternehmen oder HCs aus anderen Ländern (u.a. Purg et al. 2016; Block 2021). Ziel ist in der Regel die Identifizierung von neuen ggf. unüblichen Strategien, welche sich für andere Unternehmen - häufig KMU - übernehmen lassen.

2. Wie werden HCs in wissenschaftlichen Arbeiten untersucht? Welche Methoden und Daten werden verwendet?

Die Analysemethoden in der HC-Forschung sind sehr breit gefächert. Einige wenige Arbeiten sind rein literaturbasiert und besprechen beispielsweise internationalen Handel und Strategien, monopolistische Wettbewerbe (Lahti 2014) oder die kritischen Punkte in den identifizierten Strategien anderer Arbeiten (Witt & Carr 2013). Überwiegend handelt es sich bei der HC-Forschung um empirische Arbeiten. In der Regel werden kleinere Untersuchungsregionen ausgewählt oder Fallbeispiele von HCs analysiert (beispielsweise Rietmann 2022a oder Blackburn et al. 2001). Häufig sind hier Expert:inneninterviews das gewählte Methodeninstrumentarium. Diese werden in der Regel qualitativ inhaltsanalytisch ausgewertet. Fallbeispiele werden für qualitative als auch quantitative Untersuchungen häufig aus den Veröffentlichungen Simons (2012) entnommen. Alternativ stehen Forschenden vor der Herausforderung, die HCs einzeln zu identifizieren. Hier orientiert man sich beispielsweise an öffentlich zugänglichen Listen, kombiniert diese miteinander und selektiert die zu untersuchenden Unternehmen händisch (siehe Kapitel 4). Simons (2012) Liste ist in den vergangenen Jahrzehnten kontinuierlich erweitert worden. Der Autor identifiziert die HCs seit 30 Jahren fortlaufend „händisch“.

Die quantitativen Arbeiten, welche größere Anzahlen von HCs und deren Verhalten untersuchen, haben ihre Untersuchungsgegenstände beispielsweise durch umfassende Befragungen identifiziert. Größere Befragungen zu Internationalisierungsstrategien oder Innovationsverhalten werden ausgewertet und HCs anhand differenzierter Kriterien identifiziert (z.B. Frietschs 2015; Rammer & Spielkamp 2015; 2019a; 2019b). Häufig nutzen die Autor:innen zunächst deskriptive Statistik zur Beschreibung der Daten. Faktoranalysen kommen zum Einsatz, um Einflussgrößen wie Internationalisierung oder Innovationstätigkeiten zusammenzufassen. Zusammenhangsmaße werden verwendet, um beispielsweise den Vergleich von HCs und Nicht-

Ergebnisdiskussion

HCs durchzuführen. Weiter dienen sie dem Zweck, Wechselwirkungen mit den Erfolgskennziffern der HCs zu analysieren.

Einige wenige Arbeiten sind rein literaturbasiert. Dies sind u.a. Literaturanalysen, um anhand zusammenfassender Analysen Erfolgsfaktoren oder Risiken zu identifizieren (Schenkenhofer 2022). Darüber hinaus dienen sie der Synthese des Forschungsstandes bzw. der Einordnung des Konzepts in verschiedene managementbezogene Theorien und Frameworks.

3. Inwieweit besteht die Möglichkeit die Unternehmenskategorie HC zu operationalisieren?

Im Anschluss an die Literaturanalyse wurde ein Ansatz entwickelt die Identifizierung von HCs zu operationalisieren. Vorgegangen wurde dabei wie folgt. Zunächst wurden die drei Kriterien nach Simon als Ausgangsdefinition verwendet (2012, S. 83). Das erste Identifizierungskriterium zur Umsatzgrenze von fünf Mrd. Euro ist bereits eine messbare Größe. Das zweite Kriterium der europäischen oder weltweiten Marktführerschaft (*Champions-Kriterium*) ist ebenfalls operationalisierbar, jedoch müssen die Inputwerte zur Berechnung der Marktanteile bekannt oder die relative Marktführerschaft kalkulierbar sein. Dazu müssen Informationen darüber bekannt sein, wie der Nischenmarkt, in dem das Unternehmen sich bewegt, zu definieren ist. Weiter muss bekannt sein, wie groß der Marktanteil des Unternehmens selbst, sowie der stärksten Konkurrenz ist. Da HCs in der Regel in Nischenmärkten tätig sind, erschwert eine subjektive Marktabgrenzung dieses Prozedere. In den bestehenden Untersuchungen hat dies zur subjektiven Einschätzung der Marktführerschaft durch die Forschenden geführt. Alternativ wurde sich auf die Aussage des Unternehmens bezogen. Diese Aussagen wurden beispielsweise durch Interviews mit den Geschäftsführenden erhoben.

Die Operationalisierung des *Champions-Kriteriums* erfolgte anhand öffentlich zugänglicher Webdaten. Zur Generierung des HC-Datensatzes wurden die Webseiten aller Unternehmen aus dem produzierenden und verarbeitenden Gewerbe identifiziert und im Anschluss gescraped (Kapitel 7.2). Durch den Web Mining Ansatz der angewandte Kombination einer automatisierten Keywordsuche und des Klassifikationsalgorithmus konnten die Webseitentexte analysiert werden. Im Ergebnis konnten ca. 8.000 marktführende Unternehmen standardisiert erfasst werden.

Durch Gök et al. (2015) wurden Unternehmenswebseiten als verlässliche Datenquellen für Unternehmensinformationen identifiziert. In dieser Arbeit wird davon ausgegangen, dass wenn ein Unternehmen in bestimmten Unternehmensfeldern oder Produkten als Weltmarkt- oder Kontinentalmarktführer gilt, dies dem Unternehmen bekannt ist und dies der Kundschaft

Ergebnisdiskussion

gegenüber kommuniziert wird. Es wird angenommen, dass die Webseite als Kommunikationsinstrument diese Information enthält. Nichtsdestotrotz ist zu vermerken, dass eine Überprüfung der Richtigkeit dieser Aussagen im Rahmen dieser Arbeit nicht durchgeführt werden konnte. Unternehmenswebseiten wurden von den Unternehmen als Repräsentation ihrer selbst erstellt. Bestünde die Möglichkeit, Nischenmärkte verlässlich zu identifizieren, wäre eine Überprüfung der Marktführerschaft durchaus sinnvoll, um potenzielle Fehler in der Datenerhebung bereits zu identifizieren und den Bias diesbezüglich zu minimieren.

Das dritte Kriterium zur Identifizierung der HCs ist das sie der breiten Öffentlichkeit unbekannt sind. Das *Hiddenness*-Kriterium wurde in vielen vorangegangenen quantitativen Arbeiten zu HCs vernachlässigt. In den qualitativen Studien wird es in der Regel durch Expert:innen eingeordnet. Jedoch erfolgt diese Einordnung anhand subjektiver Einschätzungen. In der vorliegenden Dissertation basiert die Operationalisierung der *Hiddenness* auf Google-Suche Treffern.

Das Scraping von Google-Suche-Treffern diente in dieser Arbeit als ein Ansatz zur Messung von der Bekanntheit der als Champions identifizierten Unternehmen (Kapitel 7.4). Der Schwellenwert der Unbekanntheit wird zwei Standardabweichungen unter den mittleren Suchtreffern der MDAX Unternehmen gewählt (Dr. Doeblin Gesellschaft für Wirtschaftsforschung mbH 2019). Nach dieser Abgrenzung konnten 3.654 HCs identifiziert werden. Die HC-Datenbank umfasst die Namen und Rechtsform der Unternehmen sowie die Koordinaten, Adressen und Telefonnummern.

4. Wie lässt sich die Summe der identifizierten HCs beschreiben?

Insgesamt wurden auf Basis des mehrstufigen methodischen Ansatzes 3.654 HCs in Deutschland identifiziert. Das sind über 2.000 HCs mehr als bisher in der Literatur bekannt (Simon 2021, S. 5). Damit erhöht sich der bisher angenommene Dichte-Wert von 16 HCs auf 44 HCs je eine Million EW. Die HCs sind in der Regel nicht börsennotiert und liegen zu 70 Prozent in ländlichen Kreisen. Dieser Wert bestätigt die Angaben von (Simon 2012, S. 382). Denn auch bei den bisher bekannten ca. 1.600 HCs sind zwei Drittel in ländlichen Räumen angesiedelt. Den höchsten Wert an HCs hält die Gemeinde Unterwachingen in Baden-Württemberg im Regierungsbezirk Tübingen mit 4,9 je 1.000 EW. Absolut gesehen hat Berlin mit 51 HCs die höchste Anzahl der Unternehmen. Räumlich betrachtet wird ein Überhang an HCs im Westen und Süd-Westen Deutschlands deutlich. Es lässt sich schlussfolgern, dass trotz der deutlich höheren Zahl an betrachteten HCs die räumliche Konzentration auf ländliche Räume, die von Simon (2022, S. 51) beschrieben wird, bestätigt werden kann. Dies gibt einen Hinweis darauf, dass die verwendete Definition, sowie die Operationalisierung der Identifizierungskriterien diesbezüglich zielführend ist.

Ergebnisdiskussion

Im Mittel sind die in dieser Arbeit identifizierten HCs 36 Jahre alt (Stand 2020). Zum Vergleich: Die von Simon (2021, S. 50) identifizierten ca. 1.600 HCs sind im Mittel über 70 Jahre alt. Gründe für die abweichenden Werte könnten sein, dass Simons Liste seit 2012 nicht erweitert wurde, sodass insbesondere jüngere HCs nicht berücksichtigt werden können. Bezugnehmend auf die Untereinteilungen nach WZ Code C, in welchem die HCs identifiziert wurden, ist der Maschinenbausektor mit ca. 24 Prozent der am stärksten vertreten. Weiter zählen knapp 27 Prozent der HCs als kleine oder mittlere Unternehmen, während 72 Prozent große Unternehmen mit über 249 Beschäftigten und über 50 Millionen Euro Umsatz sind. Informationen zu den konkreten Umsätzen der Unternehmen liegen nicht vor.

Nach Simon (2012, S. 86) sind zwei Drittel der HCs im verarbeitenden Gewerbe angesiedelt. Nicht berücksichtigt wurden in dieser Arbeit Unternehmen, welche in anderen tätig sind. Entsprechend kann davon ausgegangen werden, dass bezugnehmend zu den Werten Simons noch weitere HCs in Deutschland zu verorten sind. Beispielsweise in der Informationstechnologie, in Beratungs- oder in Nischendienstleistungsbranchen.

13.2 Regionale Typisierung

5. Wie sind die Regionen strukturiert, in denen viele bzw. wenige HCs angesiedelt sind?

Um zu beschreiben in welchen Regionen HCs anzutreffen sind und wie diese Regionen strukturiert sind, wurde eine *regionale Typisierung* durchgeführt. Wie durch Eder und Trippel (2019, S. 1517) beschrieben, war das übergeordnete Ziel der regionalen Typisierung, die Charaktereigenschaften der Gemeinden zu identifizieren und zu vergleichen. Dazu wurden zunächst literaturbasiert sozioökonomische Indikatoren zusammengetragen. Diese wurden im Anschluss durch eine HKA zu sechs Faktoren zusammengefasst. Durch eine anschließende Clusteranalyse auf Gemeindeebene, konnten neun Regionstypen identifiziert werden. Die Anzahl der HCs variiert hier zwischen 27 (Regionstyp 7) und 1.091 (Regionstyp 1).

Der Regionstyp 9 weist mit 0,09 im Mittel den höchsten HCs-Wert je 1.000 EW auf. Generell ist er jedoch im Vergleich zu den anderen als ein eher schwächer entwickelter Regionstyp zu zählen. Bei 97,1 Prozent der dünn besiedelten Gemeinden handelt es sich um ländliche Räume (Küpper 2016) und in jeder dritten Gemeinde ist im Schnitt ein HC angesiedelt. Bezugnehmend auf die Diskussion im Kapitel 2.1 zur Innovation in ländlichen Räumen, hat dieser den zweithöchsten Innovationsoutput (11,9 je 1.000 EW) vergleichend zu den anderen Regionstypen, vorzuweisen. Obwohl es sich um überwiegend ländliche Gemeinden handelt, ist die Siedlungs- und

Ergebnisdiskussion

Branchenstruktur in Regionstyp 9 durchschnittlich. Die gute Erreichbarkeit der Gemeinden sticht ebenfalls hervor. Während die lokale Beschäftigung und Hochschulbildung dieses Regionstyps leicht unter dem Durchschnitt liegen und die soziale Infrastruktur ebenfalls als eher schlecht entwickelt einzuordnen ist, ist die lokale Arbeitsplatzattraktivität herausragend. Als Regionstyp 9 identifiziert sind unter anderem die Stadt Schwerin oder die (Land-)Gemeinde Wendorf in Mecklenburg-Vorpommern. Zossen ist eine Stadt in Brandenburg und Kelberg eine beispielhafte (Land-)Gemeinde in Rheinland-Pfalz. Cleebronn liegt in der Randzone der Metropolregion Stuttgart oder Hemme nahe der Nordsee in Schleswig-Holstein.

Regionstyp 7 lässt sich als den im Bundesvergleich sozioökonomisch schwächsten entwickelten Typen beschreiben. Hier sind außerdem die wenigsten HCs je 1.000 EW agglomeriert und 99,9 Prozent der Gemeinden liegen in ländlichen oder eher ländlichen Kreisen (Küpper 2016). Die Digitalisierung und der Innovationsoutput sind im Bundesvergleich die niedrigsten. Weiter ist der Faktor der Siedlungs- und Branchenstruktur am wenigsten ausgeprägt und die Mobilität und Erreichbarkeit überdurchschnittlich schlecht. Auch die lokale Arbeitsplatzattraktivität in Regionstyp 7 ist die niedrigste aller Regionstypen. Dennoch ist die lokale Beschäftigung und die Hochschulbildung durchschnittlich. Die soziale Infrastruktur liegt wiederum etwas niedriger im unteren Mittelfeld. Gemeinden des Regionstyps 7 mit der geringsten HC-Anzahl sind überwiegend im Nord-Osten Deutschlands vertreten. Außerdem sind viele Gemeinden in Bayern und Rheinland-Pfalz diesem Regionstyp zuzuordnen. Beispielhaft zu nennen sind die Gemeinden Bengel oder Kaschenbach in Rheinland-Pfalz, Cramme im Kreis Wolfenbüttel in Niedersachsen, Jatznick in Mecklenburg-Vorpommern oder Kasseedorf in Schleswig-Holstein.

6. Lassen sich räumliche, sozioökonomische Muster erkennen?

In der räumlichen Verteilung der HCs konnten Muster nachgewiesen werden. Bezugnehmend auf die Forderung in der wissenschaftlichen Diskussion, war ein Ziel dieser Arbeit, die identifizierten HCs unter Bezugnahme unterschiedlicher räumlicher Gegebenheiten zu analysieren. Weiter wurden außerdem unterschiedliche Regionstypen identifiziert, in welchen unterschiedliche Effekte signifikant im Zusammenhang mit der HC-Anzahl in der Region stehen. Um weiterführend Innovationsprozesse zu analysieren, wurde die räumliche Variation der sozioökonomischen Struktur mit einbezogen und identifiziert (Glückler & Bathelt 2017, S. 130).

Rein deskriptiv sind die meisten HCs in ländlichen Räumen angesiedelt (ca. 70 Prozent). Auf Basis der Auswertung der Statistik zur räumlichen Autokorrelation wurden signifikante räumliche Gruppierungen identifiziert. Die Verteilung der HCs ist somit als nicht zufällig zu betrachten. Insgesamt wurden 141 HC-Hotspots identifiziert. Diese liegen im Mittel eher in ländlichen

Räumen (Küpper 2016). Diese Erkenntnis gibt einen Hinweis auf das Verhältnis der Verteilung der Unternehmen in ländlichen und urbanen Räumen Deutschlands. Jedoch hat die Ländlichkeit in der generalisierten Analyse deutscher Gemeinden einen negativen Effekt auf die Anwesenheit von HCs (s. Kapitel 12.1). Daher wurde die räumliche Variation der sozioökonomischen Struktur mit einbezogen (Glückler & Bathelt 2017, S. 130) und weiterführende Untersuchungen für die jeweiligen Regionstypen durchgeführt.

Die Frage nach sozioökonomischen Mustern wurde bereits teilweise in Forschungsfrage 5 beantwortet. Die räumliche Typisierung auf Gemeindeebene ist hier die Grundlage der Analyse (Wieland & Fuchs 2018). Die Zusammenfassung der Gemeinden zu homogenen Gruppen führte zu neun heterogenen Regionstypen. Diese unterscheiden sich in der Ausprägung der einzelnen Faktorwerte voneinander und wurden im Anschluss basierend auf der HC-Anzahl, dem Innovationsoutput, der Ländlichkeit sowie der Digitalisierung verglichen. Die in Kapitel 11.4 beschriebenen Typen unterscheiden sich deutlich in ihren Charaktereigenschaften. Die Regionstypen 2, 3 und 4 lassen sich als überwiegend gut entwickelte Regionen beschreiben. Sie liegen in fast allen Faktormittelwerten über dem deutschen Durchschnitt. Die Regionstypen 1 und 5 sind dem deutschen Mittelmaß sehr nah, während die Regionstypen 6, 7, 8 und 9 unterdurchschnittlich entwickelt sind. Diese stark vereinfachten Aussagen lassen sich nicht für gesamt Deutschland generalisieren. Beispielsweise haben die Regionstypen mit hohem Innovationsoutput ebenfalls einen großen Anteil an Gemeinden aus ländlichen oder eher ländlichen Kreisen (Küpper 2016). Entsprechend gilt es die sozioökonomischen Charaktereigenschaften der Gemeinden in jegliche Analyse mit einzubeziehen, möchte man durch seine Analysen zielführende Entwicklungspotenziale der Gemeinden identifizieren.

13.3 Regionale Wirkungszusammenhänge

7. Inwiefern stehen regionale Strukturmerkmale mit der Anwesenheit von HCs in Verbindung?

Um Aussagen über Einflussgrößen zur Steigerung der HC-Anzahl zu formulieren und die räumlichen Muster in der Verteilung in Deutschland zu verstehen, galt es festzustellen, ob und wenn ja, welche regionalen Strukturmerkmale die Anzahl von HCs in einer Region überhaupt fördern. Um diese Effekte zu untersuchen, wurden mehrere NBR durchgeführt. Zunächst fand diese Analyse auf gesamt-räumlicher Ebene für alle deutschen Gemeinden statt.

Für Deutschland insgesamt weist jeder der sozioökonomischen Faktoren einen signifikanten Effekt auf die HC-Anzahl auf. Unter Konstanthaltung der anderen Prädiktoren hat die Siedlungs-

Ergebnisdiskussion

und Branchenstruktur den stärksten Effekt auf die HC-Anzahl in der betrachteten Gemeinde. Danach folgt die soziale Infrastruktur und es konnte festgestellt werden, dass die zunehmende Ländlichkeit einen starken negativen Effekt auf die Anzahl der HCs hat. Nimmt sie zu, nimmt die Anzahl der HCs ab. Um diese Zusammenhänge wie durch die aktuelle Literatur empfohlen vor dem Hintergrund der differenzierten räumlichen Strukturen der Gemeinden zu analysieren, erfolgt die Analyse im Anschluss erneut für die einzelnen Regionstypen (Glückler 2022, S. 235). Bezüglich der Effektstärke steht die lokale Arbeitsplatzattraktivität an vierter Stelle. Steigt diese, hat dies (c. p.) einen positiven Effekt auf die HCs-Anzahl in der Gemeinde. Eine schlechtere Mobilität und Erreichbarkeit bringt wiederum weniger HCs in der Region mit sich. Sortiert nach der Effektstärke folgt die Hochschulbildung vor der Digitalisierung. Den schwächsten, aber ebenfalls positiven, Effekt auf die Anzahl der HCs unter Konstanthaltung der anderen Einflussgrößen hat die lokale Beschäftigung.

Die oben beschriebenen Effekte können als erster Überblick über Wirkungszusammenhänge und zur Formulierung allgemeiner Aussagen dienen. Um individuelle Aussagen über die Zusammenhänge zwischen den sozioökonomischen Faktoren, der Digitalisierung und Ländlichkeit mit der Anwesenheit von HCs in einer Gemeinde zu treffen, ist es unabdingbar die regionale Charakteristik dieser einzubeziehen (BBSR, S. 58). Dazu wurde eine Regression mit Zählvariablen (NBR) für jeden einzelnen Regionstypen durchgeführt. Im Ergebnis kann abgeleitet werden, wie in welchem Regionstyp welche sozioökonomischen Strukturen gefördert werden müssen, um mehr HCs in den Gemeinden anzusiedeln. Ist dies das Ziel, sollten die entsprechend stärksten Effekte verfolgt werden.

Deutlich wird die Relevanz der regionalen „Einzelbetrachtung“ beispielsweise bei der Ländlichkeit. Diese weist im Modell für Gesamtdeutschland einen signifikanten positiven Effekt auf die HC-Anzahl vor. In der Betrachtung der Regionstypen wird jedoch deutlich, dass die Ländlichkeit in Regionstyp 2 und 4 einen signifikanten Effekt mit sich bringt. Steigt die Ländlichkeit, sinkt dies die Anzahl der HCs in den jeweiligen betrachteten Gemeinden. Beide Regionstypen gelten im Vergleich zu den anderen Typen bezogen auf seine sozioökonomische Struktur als überdurchschnittlich. In Regionstyp 2 sind überwiegend Städte inbegriffen, was einen Hinweis auf die Erklärung des signifikanten Effekts der Ländlichkeit auf die Anwesenheit von HCs in hier gibt. Die Steigerung der Ländlichkeit fördert in der Regel nicht die Ansiedlung von HCs, was einen Hinweis auf die Zufälligkeit ihrer Standortwahl geben kann.

Es stellt sich heraus, dass die differenzierte Berücksichtigung der Regionstypen nachweislich deutliche Differenzen der Effekte und deren statistischer Signifikanz mit sich bringt. Während für

Ergebnisdiskussion

Deutschland insgesamt für jede unabhängige Variable signifikante Effekte auf die HC-Anzahl einer Gemeinde festgestellt wurden, gilt dies für die Regionstypen nicht. Inwieweit dies für die Steigerung der Innovationsleistung einer Region sinnvoll ist, wird im nachstehenden Kapitel diskutiert.

8. In welchem Zusammenhang steht die Anwesenheit von HCs mit dem Innovationsoutput einer Gemeinde?

HCs gelten als Triebkräfte der deutschen Wirtschaft, indem sie durch Innovation und Internationalisierung zu Spitzenreitern werden (Bundesministerium für Wirtschaft und Energie 2019, S. 7-10; Simon 2022, S. 5). Den Beitrag der HCs zum allgemeinen Innovationsoutput einer Region konnte in der vorliegenden Arbeit nachgewiesen werden. Dies wurde zunächst mittels einer multiplen linearen Regression durchgeführt. Es wurde festgestellt, dass unter Einbezug der gesamtäumlichen Daten der Effekt von HCs auf den Innovationsoutput einer Gemeinde in Deutschland statistisch signifikant ist. Steigt die Anzahl von HCs in einer Region, bringt dies einen erhöhten positiven Effekt auf die Innovationsleistung einer Region mit sich. Der Effekt ist jedoch schwach, verglichen zu den anderen signifikanten Werten der sozioökonomischen Faktoren im Modell. Glückler (2022, S. 235) schildert, dass die Unternehmen gerade durch ihre periphere Lage innovativ sein können. Aus der vorliegenden Analyse konnte dies nicht bestätigt werden. Denn bei zunehmender Ländlichkeit, sinkt der Innovationsoutput in dem hier geschätzten Modell für Deutschland insgesamt (Siehe Kapitel 12.2). In den Modellen der einzelnen Regionstypen sind die Ergebnisse differenzierter. So weist der überwiegend urbane Regionstyp 3 beispielsweise den stärksten negativen Effekt der zunehmenden Ländlichkeit auf den Innovationsoutput nach. In dem „ländlichsten“ Regionstyp 7 ist der Effekt der Ländlichkeit wiederum nicht signifikant. Diese Ergebnisse bestätigen, dass eine differenzierte Raumbetrachtung nachweisliche unterschiedliche Schlussfolgerungen mit sich bringt. Wenn diese oder ähnliche Analysen zur Formulierung von Handlungsempfehlungen genutzt werden, sollten die Ergebnisse der regionalen Typisierung mit einbezogen werden.

Der Beitrag von HCs als Treiber für eine regionale Entwicklung im Innovationskontext konnte zwar schwach, jedoch positiv signifikant nachgewiesen werden (Sotarauta et al. 2012, S. 359). Glückler und Bathelt (2017, S. 130) stellen in ihrer Arbeit fest, dass die räumliche Variation der Wirtschaftsstruktur ausschlaggebend für erfolgreiche Innovationsprozesse ist. Entsprechend wurde das Modell auch auf die neun Regionstypen angewandt. Auf Gemeindeebene ist der Effekt der HCs-Anwesenheit auf den Innovationsoutput nur in Regionstyp 4 signifikant. Ein möglicher Ansatz, um die Effekte besser zu verstehen und zu beschreiben, wäre hier der räumliche Fokus

Ergebnisdiskussion

auf beispielsweise funktionale, statt administrative Regionen. Alternativ muss der durch Glückler und Bathelt (2017, S. 130) beschriebene geographische Blickwinkel durch eine andere Methodenwahl eingenommen werden. Dazu wurde in Kapitel 12.4 eine räumliche Regressionsanalyse durchgeführt. Die Erkenntnisse werden in Forschungsfrage 10 adressiert.

9. Inwieweit sind regionale, ebenenübergreifende Effekte zwischen der Anwesenheit von HCs mit den regionalen Strukturmerkmalen und dem Innovationsoutput einer Region festzustellen?

Um innovationsfördernde Handlungsempfehlungen formulieren zu können, gilt es ebenenübergreifende Interaktionen und ihre Wirkungen zu verstehen (Bathelt et al. 2017, S. 3). Zur Beantwortung der Forschungsfrage wurde zunächst der gesamte Untersuchungsraum, sprich alle deutschen Gemeinden und Kreise, in einer HLM analysiert. Die erste Erkenntnis ist, dass ein Teil der Effektschwankungen der Siedlungs- und Branchenstruktur, sowie der Hochschulbildung zwischen den Kreisen sich durch die Anzahl der HCs je 1.000 EW erklären lässt. Innerhalb der Kreise gibt es darauf jedoch keinen signifikanten Einfluss. In der Theorie lassen sich stärkere und ggf. signifikante Effekte zwischen beispielsweise Kreisen und Arbeitsmarktregionen oder Gemeinden und Arbeitsmarktregionen vermuten. Als Funktionalregionen könnten diese endogene ökonomischen Aktivitäten von Regionen ggf. besser abbilden, als es Verwaltungsregionen tun (Eckey et al. 2007B, S. 6). Im Rahmen dieser Arbeit wurde wegen des Umfangs einer solchen vergleichenden und fortführenden Analyse abgesehen.

Um die Heterogenität der Gemeinden mit einzubeziehen, wurde die Analyse ebenfalls für die einzelnen Regionstypen durchgeführt. Ziel war es, von generischen Handlungsempfehlungen abzusehen (Tödling & Tripl 2005, S. 1204) und die Disparitäten zwischen den Regionen zu berücksichtigen. Es konnten ebenenübergreifende Effekte in den Regionstypen 6 und 9 identifiziert werden.

Für Gemeinden des Regionstyps 6 konnte festgestellt werden, dass in Kreisen, in welchen viele HCs angesiedelt sind, der Effekt der Digitalisierung stärker auf den Innovationsoutput wirkt als in Kreisen mit weniger HCs je 1.000 EW. Glückler (2013, S. 13) beschreibt in seiner Arbeit, dass das reine Vor-Ort-Sein von Unternehmen nicht dafür ausreicht, um von lokalem Wissen zu profitieren und Spillover-Effekte abzugreifen. Jedoch scheint das Vor-Ort-Sein der hoch innovativen und vernetzten HCs einen Effekt auf die Wirkkraft der regionalen Digitalisierung im Zusammenhang zur Innovation zu haben. Eder und Tripl (2019, S: 1516-1517) beschreiben, dass Wissensspillover und damit verbundene Innovation durch Digitalisierung auch über große Distanzen möglich sind. Für den eher durchschnittlichen Regionstyp 6 konnte dies entsprechend nachgewiesen werden.

Ergebnisdiskussion

In Regionstyp 9 wirkt die gesteigerte Anwesenheit der HCs auf den Effekt der Siedlungs- und Branchenstruktur auf den Innovationsoutput. Regionstyp 9 liegt mit seinen Werten der Siedlungs- und Branchenstruktur komplett im deutschen Durchschnitt. Der Effekt des Faktors auf Gemeindeebene wird in Gemeinden noch verstärkt, in welchen mehr HCs angesiedelt sind.

Es konnte festgestellt werden, dass in zwei Regionstypen die Anwesenheit von HCs im zugehörigen Kreis die Effekte von einzelnen sozioökonomischen Faktoren auf den Innovationsoutput der Gemeinden stärken. HCs wurden in diesen Gemeinden also nicht nur als direkte, sondern ebenfalls als indirekte Triebkraft von Innovation über räumliche Ebenen hinweg identifiziert. Basierend auf diesen Erkenntnissen, können für die Regionstypen 6 und 9 Handlungsempfehlungen nicht nur auf Gemeinde, sondern auch auf Kreisebene formuliert werden. Die regionale Wirtschaftsförderung kann durch Maßnahmen in den Kreisen zur Agglomeration von HCs ebenfalls den Innovationsoutput in den Gemeinden des Regionstyps stärken. Investitionen in eine gesteigerte Digitalisierung (Regionstyp 6) oder einer höheren Siedlungs- und Branchenstruktur (Regionstyp 9) bringen hier einen gestärkten Effekt auf das endogene Wachstum mit sich (Sotarauta et al. 2012, S. 359ff).

10. Inwieweit lassen sich durch die Anwesenheit von HCs in einer Region Spillover-Effekte auf ihre Nachbarregionen feststellen?

Im Rahmen der durchgeführten Analyse in Kapitel 12.4 konnte festgestellt werden, dass durch HCs innovationssteigernde Effekte über die amtlichen Grenzen der Gemeinden hinausgehen. Um diese Spillover-Effekte zwischen den lokalen HCs und sozioökonomischen Strukturen mit regionalen Innovationsoutputs zu erfassen, wurde eine räumliche Regressionsanalyse durchgeführt. Zur Identifizierung von Unternehmens- und Wirtschaftsstrukturen (BBSR 2018, S. 58), wurde auf Basis aller deutschen Gemeinden eine Analyse von potenziellen Spillover-Effekten der HCs durchgeführt. In der vorliegenden Dissertation wurde anhand der einbezogenen Inhalte der Literaturanalyse in Kapitel 3 und 4 angenommen, dass HCs durch ihre Unternehmensstrategien die Mechanismen, welche für die Entstehung von Wissensspillover notwendig sind, verwenden. Der positive Zusammenhang zwischen der Anwesenheit von HCs in einer Gemeinde und dem jeweiligen Innovationsoutput konnte, wie in Kapitel 12.2 beschrieben, bestätigt werden. Inwieweit dies im räumlichen Kontext über die Grenzen einer Gemeinde hinausgeht, wurde durch die räumliche Regressionsanalyse in Kapitel 12.4 untersucht.

Im Rahmen der Analysen wurden direkte und indirekte räumliche Effekte untersucht. Die direkten Effekte, sprich innerhalb einer Gemeinde, konnten für den positiven Effekt der HCs auf den Innovationsoutput der eigenen Gemeinde statistisch signifikant nachgewiesen werden. Nur

Ergebnisdiskussion

der direkte positive Effekt der Digitalisierung auf den Innovationsoutput ist höher. Bezugnehmend auf Bathelt et al. (2004, S. 12) könnte dies durch den Effekt der durch Digitalisierung gestärkten Global Pipelines erklärt werden. Digital vernetzte Unternehmen haben somit einen anderen Wissenszufluss als solche, die es nicht sind. Entsprechend kann der Effekt auf Innovation anders und, im Fall der zugrundeliegenden Daten, stärker sein.

Etwas schwächer als der direkte, jedoch genauso hoch statistisch signifikant ist der indirekte Effekt der HCs auf den Innovationsoutput. Steigt die Anzahl der HCs einer Gemeinde, so steigert dies auch den Innovationsoutput der Nachbargemeinden. Die räumliche Anwesenheit der HCs hat also einen deutlichen Erklärungsgehalt zur Innovationsleistung der eigenen und umliegenden Regionen.

Die signifikanten Spillover-Effekte lassen, wie bereits bei der Diskussion anderer Forschungsfragen, darauf schließen, dass die Berücksichtigung von funktionalen statt amtlichen Grenzen für fortführende Analysen sinnvoll wäre. Weiter lässt sich schlussfolgern, dass die Förderung von Maßnahmen, welche die Anwesenheit von HCs beeinflussen, nicht nur auf der kommunalen, sondern auch der überregionalen Ebene gewinnbringende Effekte mit sich bringt.

14 Zusammenfassendes Fazit

Die übergeordneten Ziele der vorliegenden Dissertation lassen sich in drei wesentlichen, inhaltlichen Teilen erfassen. Zunächst die *Identifizierung des Untersuchungsgegenstandes*, dann die *regionale Typisierung* und abschließend die Untersuchung von *Wirkungszusammenhängen* zwischen HCs und der regionalen Struktur im Innovationskontext. In diesem abschließenden Kapitel werden die Kernerkenntnisse bezüglich zunächst zusammengefasst. Anschließend erfolgen einige Limitationen des Vorgehens und ein Forschungsausblick.

Zunächst konnte die Arbeit einen transparenten und operationalisierten methodischen Ansatz schaffen um HCs zu identifizieren. Die webdatenbasierte Methodik war insoweit erfolgreich, dass 3.654 HCs adressscharf lokalisiert und identifiziert werden konnten. Im Ergebnis sind das ca. 2.000 Unternehmen mehr als bisher in der Literatur bekannt (Simon 2021, S. 42). Ca. 70 Prozent dieser Unternehmen sind in ländlichen Räumen angesiedelt, was mit den Ergebnissen Simons (2012) übereinstimmt. Durch die Analyse der räumlichen Autokorrelation konnten darüber hinaus einige HC-Hot-Spots empirisch nachgewiesen werden. Beispielsweise im süd-östlichen NRW sowie im Süden von Baden-Württemberg und Bayern.

Unter Berücksichtigung der kleinräumig verfügbaren Datenlage wurde in dieser Arbeit die Analyse auf Gemeindeebene durchgeführt. Um strukturelle Unterschiede zu berücksichtigen, wurde durch die Kombination einer HKA und einer Clusteranalyse neun heterogene Regionstypen identifiziert. Diese unterscheiden sich nach Siedlungs- und Branchenstruktur, Mobilität und Erreichbarkeit, Hochschulbildung, lokaler Beschäftigung, sozialer Infrastruktur und lokaler Arbeitsplatzattraktivität. Auch die Verteilung der HCs ist heterogen. Regionstyp 9 weist beispielsweise im Vergleich mit den anderen Typen überdurchschnittlich hohen HC je 1.000 EW Werte vor.

Nach der Deskription der *regionalen Typisierung* folgte die Untersuchung der *Wirkungszusammenhänge* mit den HCs im Innovationskontext. Es wurde festgestellt, dass unter Berücksichtigung der heterogenen regionalen Strukturen, die sich nachgewiesenen Zusammenhänge zwischen den Regionstypen und der Gesamtbetrachtung Deutschlands unterscheiden. Je nach Regionstyp, stehen die betrachteten Strukturmerkmale mit der Anwesenheit von HCs in Verbindung. Hervorzuheben ist der Regionstyp 9, welcher zum einen mit der höchsten HCs-Dichte ausgestattet ist und zum anderen konnten die meisten betrachteten Merkmale einen signifikanten Einfluss auf diesen Wert nehmen. Andersherum betrachtet, bringt auch die Anwesenheit von HCs bestimmte Effekte mit sich. Die Analysen zum Zusammenhang von

HCs mit dem Innovationsoutput einer Gemeinde wurden ebenfalls regional je nach Gemeindetyp differenziert durchgeführt. Im Ergebnis tragen die HCs je 1.000 EW bei gesamtäumlicher Betrachtung aller Gemeinden signifikant zum gesteigerten Innovationsoutput bei. Dies bestätigt die Aussagen der Industriestrategie 2030 (Bundes XXX). Betrachtet man die strukturellen Unterschiede der Regionen, gilt dieser signifikante Effekt nur für Gemeinden des eher strukturstarken Regionstyps 4. Zur Einnahme einer weiteren räumlichen Perspektive wurden die ebenenübergreifenden Effekte der HCs von Kreis- auf Gemeindeebene geschätzt. Aus den Ergebnissen ließ sich schlussfolgern, dass die HCs-Dichte eines Kreises einen positiven signifikanten Effekt auf den Zusammenhang einzelner sozioökonomischer Faktoren mit dem Innovationsoutput auf Gemeindeebene hat. Auch auf Bundesebene haben die Modellergebnisse einen Hinweis auf indirekte Effekte von höheren auf kleinräumigere regionale Ebenen.

Weiter beschränkt sich der Effekt der HC-Dichte nicht nur auf die Region selbst, sondern ebenfalls auf die Nachbargemeinden. Direkte und indirekte Spillover-Effekte zeigen, dass die hoch innovativen Unternehmen einen nachweislichen Einfluss auf den Innovationsoutput der Nachbarschaft haben können. Die Ergebnisse bestätigen die Ausführungen Eders (2019, S. 42), die Charaktereigenschaften einer Region trage maßgeblich zur Innovationskraft dieser bei. Dies geht nachweislich über die Einteilung in ländliche und urbane Regionen hinaus und ist in jedem Regionsfall einzeln zu betrachten.

Die Ergebnisse sind eine vielversprechende Datengrundlage für weiterführende Analysen zu HCs. Dennoch weisen das Vorgehen und die daraus resultierenden Ergebnisse Grenzen auf, die im folgenden Kapitel dargelegt werden, um auf dieser Basis darzustellen, welche zentralen weiteren Forschungsbedarfe in methodischer, inhaltlicher und theoretischer Hinsicht bestehen.

14.1 Limitationen

Zum Ende dieser Dissertation gilt es einige methodische Einschränkungen zu adressieren. Zunächst werden Limitationen bezüglich der *Identifizierung* der HCs diskutiert. Die HCs wurden im Rahmen dieser Arbeit nur im für das verarbeitende und produzierende Gewerbe identifiziert. Dies fußt auf der anfänglichen Annahme, dass eine Ausweitung auf alle WZ - die Grundgesamtheit der Unternehmen - die Konzipierung des Algorithmus deutlich erschwert und die Rechendauer der verfügbaren Computer deutlich verlängert hätte. Außerdem wurde durch Simon ein Großteil der HCs in dem entsprechenden WZ beschrieben (Simon 2012, S. 86). Eine Anwendung eines Webscrapings zur Zusammenstellung aller Webseiten dieser nicht berücksichtigten Unternehmen, sowie eines Klassifikationsalgorithmus zur Identifizierung der *Championship*, wäre im Nachgang an diese Arbeit möglich.

Zusammenfassendes Fazit

Weiter hat das Verfahren zur Feststellung der *Championship* eine Genauigkeit von knapp 82 Prozent erreicht. Es wird vorausgesetzt, dass die Webseite als Kommunikationsinstrument die notwendigen Informationen enthält, um Unternehmen auf Basis dieses Kriteriums zu identifizieren. Die durch die Methodik identifizierten Aussagen zur *Championship* der ca. 8.000 Unternehmen wurden nicht noch einmal händisch überprüft. Lediglich die Validierung des Testdatensatzes gibt Aussage über die Validität der Ergebnisse. So kann zwar identifiziert werden, wenn ein Unternehmen von der Weltmarktführerschaft spricht, inwieweit es dann tatsächlich zu den Top-3 Unternehmen in seinem Segment gehört, bleibt im Rahmen dieser Arbeit ungelöst. Eine gewisse Unschärfe birgt ebenfalls die Definition der europäischen Marktführerschaft. Simon (2012, S. 83) spricht davon, dass HCs auf dem eigenen Kontinent marktführend sein müssen. Hier gelten dieselben Unsicherheiten wie im Zuge der Weltmarktführerschaft. Dennoch bietet die Methodik durch die Kombination der Keyword-Suche und des Klassifikationsalgorithmus eine neue Chance auf differenziertere Ergebnisse. Eine Unterscheidung der Art der *Championship* war im Rahmen dieser Arbeit nicht geplant. Durch Weiterentwicklung durch Neutraining und Auslegung des Klassifikationsalgorithmus wäre dies nach aktuellen Einschätzungen jedoch möglich.

Eine oben angesprochene Überprüfung der Ergebnisse ist sinnvoll, um potenzielle Fehler in der Datenerhebung zu identifizieren und den Bias diesbezüglich zu minimieren. Im Rahmen dieser Arbeit wurde dies aus Gründen des zeitlichen Aufwands nicht durchgeführt. Eine finale händische Überprüfung der Champions (ohne Anwendung *Hiddenness-Kriteriums*) sowie HCs könnte zusätzlich zur Prüfung des Testdatensatzes Erkenntnisse bringen. Die Differenzierung aus der Definition nach Simon (2012, S. 84) zwischen Weltmarktführerschaft und der europäischen Marktführerschaft wurde in der vorliegenden Dissertation aus Komplexitätsgründen vernachlässigt. Zum Abschluss der Arbeit und mit dem daraus resultierenden methodischen Verständnis, wäre eine solche Differenzierung für fortführende Forschungsarbeiten sicherlich machbar. Hier stellt sich jedoch die Frage der Relevanz dieser Unterscheidung für die Ergebnisse. Denn ein HC ist also solcher im Falle einer europäischen als auch weltweiten Marktführerschaft zu identifizieren.

Bei der Operationalisierung des *Hiddenness-Kriteriums* fällt auf, dass die Bekanntheit der HCs außerhalb des Internets nicht mit einbezogen werden konnte. Die breite Öffentlichkeit lässt sich hier zwar in gewisser Weise abbilden, jedoch nur im Rahmen von Online-Nennungen, beispielsweise von kooperierenden Unternehmenswebseiten, der eigenen Webseite oder Bekanntmachungen aus der (Online-)Presse. Inwieweit dies die subjektive Wahrnehmung der Unternehmen in der Bevölkerung spiegelt, wurde bis dato noch nicht untersucht. Auch der

Zusammenfassendes Fazit

Schwellenwert der Hiddenness könnte auf seine Belastbarkeit geprüft werden. Eine alternative Kennzahl wäre der sog. Niche Brand Awareness Index (Schenkenhofer 2022, S. 472). Hier werden fünf Kennzahlen zu einem Composite Index zusammengefasst. Einbezogen wird die Anzahl an LinkedIn Follower:innen, der Facebook Likes, die Anzahl der Besuche der Wikipedia-Seite sowie Kununu Webseite und Reviews. Die Datenbasis zur Berechnung des Niche Brand Awareness Index lässt sich jedoch nicht automatisiert erheben. Das Scrapen von Facebook Likes wurde durch die Nutzungsbedingungen untersagt (Meta Platform, Inc. 2023). Entsprechend kann die Erstellung des Index für große Datenmengen eine Herausforderung darstellen. Nichtsdestotrotz wäre ein Ergebnisabgleich des Index mit der hier angewandten Methodik sicherlich der Verifizierung beider Vorgehen dienlich. Alternativ wäre es allgemein zielführend, die bestehende Liste von Simon (2012) mit der hier identifizierten Anzahl von HCs zu vergleichen und Unterschiede zu analysieren.

Auch bei der rückkoppelnden Betrachtung des Vorgehens der *regionalen Typisierung* sind einige Anwendungen der Methodik im Nachhinein zu diskutieren. Orientiert am Vorgehen von Wieland und Fuchs (2018) sowie Küpper (2016) ist zunächst zur Variablenauswahl zu sagen, dass eine ergänzende Digitalisierungsvariable, wie beispielsweise die Breitbandverfügbarkeit, zusätzliche Informationen und Effekte hätte aufdecken können. Die Verfügbarkeit von öffentlich zugänglichen, sozioökonomischen Daten auf Gemeindeebene ist jedoch sehr begrenzt. Auch eine neue Berechnung der Variable Ländlichkeit hätte die Ergebnisse schärfen können, wäre jedoch aufgrund der Datenverfügbarkeit nur sehr eingeschränkt möglich gewesen, sodass sich dagegen entschieden wurde (Küpper 2016).

Dapena et al. 2016 (S. 186) empfehlen, die kleinräumig verfügbaren Daten zu verwenden. Hierdurch lässt sich eine Beeinflussung der Ergebnisse durch das Zusammenfassen in größere Regionen jedoch nur teilweise umgehen. Die Problematik der Auswertung von Verwaltungsregionen anstelle von funktionalen Regionen besteht nach wie vor (Eckey et al. 2007b, S. 6). Durch die Identifizierung der HC-Adressen können diese auf jegliche Regionsebenen und -formen aggregiert werden. Eine Analyse beispielsweise auf kleinräumiger Arbeitsmarktregionsebene könnte entsprechend zu weiterführenden Erkenntnissen führen.

Bei der *regionalen Typisierung* wurde als Clusteranalyse eine MBC durchgeführt (McNicolas 2016, S. 360). Diese empfiehlt sich bei der Analyse von räumlichen Strukturen, bietet im Ergebnis jedoch nur eine Wahrscheinlichkeit für die Einteilung in bestimmte Cluster (He et al. 2010, S. 2). Ein detaillierter Vergleich der Modelloptionen wäre im Rahmen dieser Arbeit zwar möglich, jedoch

abweichend von der Zielformulierung gewesen. Für fortführende Analysen bietet sich jedoch eine weitere Überprüfung der Eignung an.

Die regionalen *Wirkungszusammenhänge* wurden anhand von Regressionsanalysen und Mehrebenenmodellen getestet. Ein ausführlicher Vergleich und damit einhergehende die Analyse der Eignung dieser Verfahren zur in dieser Arbeit formulierten Zielsetzung hat nicht stattgefunden. Es gibt jedoch Hinweise darauf, dass die Wahl von funktionalen Untersuchungsräumen zusätzliche Erkenntnisse mit sich gebracht hätte. Dieser Ansatz wird unter anderem in Kapitel 14.2 zum Forschungsausblick adressiert. Im räumlichen Regressionsmodell wurde die Ländlichkeit nicht mit aufgenommen, da diese auf Basis der für die Kreise gerechneten Indexwerte beruht. So haben benachbarte Gemeinden, wenn sie in den gleichen Kreisen liegen, übereinstimmende Werte. Dies macht das Einbeziehen dieser Variable obsolet.

14.2 Forschungsausblick

Die in Kapitel 14.1 aufgeführten Limitationen der Ergebnisse dieser Dissertation, zeigen die Grenzen der Arbeit auf. Unter Berücksichtigung dieser Grenzen, bilden die Ergebnisse eine gute Basis für weitere Forschungen. Im Folgenden werden die vielseitigen Möglichkeiten von weiterführenden Forschungsoptionen präsentiert und diskutiert.

Zunächst wird auf die identifizierten HCs eingegangen. Die Erhebung und Analyse der Webdaten und damit verbundenen hier verwendeten Aus- und Verwertungsmethodik im regionalen Innovationskontext bieten viele weitere Anwendungsmöglichkeiten. Beispielsweise ließe sich das Vorgehen der Identifizierung des Untersuchungsgegenstandes aus dem verarbeitenden und produzierenden Gewerbe (WZ C) auf alle WZ übertragen. Darüber hinaus würden vergleichende Analysen mit innovativen, international agierenden KMU, die als Nicht-HC zu klassifizieren sind, weiterführende Informationen zur Gewichtung der Ergebnisse im gesamten unternehmerischen Kontext liefern. Beispielsweise wäre zu untersuchen, inwieweit die Nicht-HCs, Champions und HCs einen differenzierten Effekt auf die Innovationsleistung ihrer Regionen ausüben.

Durch regelmäßiges Crawling der Webdaten und die Anwendung der Identifizierung könnte eine Zeitreihendatenbank entstehen. Erkenntnisse über die Entwicklung der HC-Landschaft nach Branche und Raum kann beispielsweise auch Aussagen über die nicht (mehr) erfolgreichen HCs liefern. Dies ist bisher eine unbekannte Größe, denn im Vordergrund der Analysen stehen die HCs, welche ihre Marktposition halten und ausbauen. Neugründungen oder Unternehmensschließungen könnten Hinweise auf die (zeitlich-) strukturellen Entwicklungen in Regionen geben. Genauso ließen sich durch die Erfassung der auf den Webseiten adressierten

Zusammenfassendes Fazit

Themen Trends und sich entwickelnde Unternehmensstrategien der HCs ableiten. Durch das Scraping der gesamten Webseiten-URLs wäre eine Analyse der Verlinkungen zwischen den verschiedenen Unternehmensseiten möglich. Es ließen sich Unternehmensnetzwerke analysieren und feststellen, inwieweit Verbindungen zwischen regionalen und überregionalen HCs und Nicht-HCs existieren. Eine solche Erkenntnis könnte nachweisen, inwieweit HCs im unternehmerischen Kontext tatsächlich als „hidden“ gelten. Gibt es unterschiedlich stark vernetzte HCs und steht dies ggf. im Zusammenhang mit der regionalen Verortung? Bezugnehmend auf Bathelt et al. (2004, S. 12) könnten Global Pipelines identifiziert werden und deren Effekte untersucht werden.

Fortführende thematisch neu ausgerichtete Fragestellungen ließen sich durch webdatenbasierte Analysen anhand der hier vorgestellten Methodik beantworten. Die Kombination der Keyword-Suche und des Klassifikationsalgorithmus bietet eine Chance flächendeckende differenziertere Ergebnisse zu erreichen. Hierzu zählt beispielsweise die Analyse, inwieweit Unternehmen CSR-Maßnahmen anwenden und ob dies einen Unterschied bezüglich der regionalen Spillover-Effekte macht. Beispielsweise könnten die durch Rietmann (2021b) klassifizierten vier HC-Digitalisierungstypen durch ein Verfahren wie es in Kapitel 7.3 zur Identifizierung von Champions automatisiert auf die identifizierten HCs übertragen werden. Die Methode könnte auf den gesamten deutschsprachigen Raum ausgeweitet oder durch das Neutrainieren in anderen Sprachen auch für andere Länder entsprechende Erkenntnisse bringen. Auch eine auf die Ergebnisse der vorliegenden Arbeit aufbauenden Verbindung von qualitativer sowie quantitativer Methoden bietet neue Möglichkeiten (BBSR 2019, S. 59). Inhaltlich sind hier kaum Grenzen gesetzt. Im Grunde ließe sich ein Mixed-Methods-Vorgehen sich auf diverse in Kapitel 4.2 vorgestellte Fragestellungen anwenden.

Durch die Einnahme neuer räumlicher Blickwinkel im Kontext der entwickelten Methode, sowie durch Erweiterung dieser können weitere Forschungsfragen beantwortet werden. Dazu zählt u.a. inwieweit sich die Ergebnisse verändern, wenn die Untersuchungsregionen funktionale, statt amtliche wären. Welchen Effekt bringt die Anwesenheit von HCs in sog. Arbeitsmarktregionen mit sich? Dazu wäre es zunächst notwendig Arbeitsmarktregionen auf Basis von Gemeindedaten zu identifizieren. Die Verfügbarkeit von öffentlich zugänglichen, sozioökonomischen Daten auf Gemeindeebene ist jedoch sehr begrenzt. Die Berechnung von Arbeitsmarktregionen nach dem Beispiel des BBSRs wäre auch auf Basis der Informationen auf Gemeindeebene möglich (Milbert 2016). Diese Erkenntnis ist ein weiterer Hinweis darauf, dass die räumliche Untersuchungsebene der Arbeit in fortführenden Untersuchungen durch funktionale Regionen ersetzt und mit ihnen verglichen werden sollte.

Zusammenfassendes Fazit

Die Erkenntnis aus der Regression mit Zählvariablen war, dass die Steigerung der Ländlichkeit nachweislich nicht die Ansiedlung von HCs fördert. Dies gibt wie beschrieben erneut einen Hinweis auf die Zufälligkeit ihrer Standortentscheidung geben kann. Diese Erkenntnis bietet eine gute Ausgangslage für einen anschließenden qualitativen Forschungsansatz. Das Forschungsinteresse könnte beispielsweise sein, tiefergreifende Informationen über die Wechselwirkungen zwischen dem Standort und den Unternehmen zu analysieren. Beispielsweise durch den Vergleich von strukturstarken und -schwachen Regionen. Alternativ wäre auch der Vergleich von HCs-reichen und -armen Regionen sinnvoll. Inwieweit HCs als Chance für schwächer entwickelte Räume gelten ließe sich beispielsweise an Regionstyp 9 untersuchen. Dieser weist mit 0,09 im Mittel den höchsten HCs Wert je 1.000 EW auf. Generell ist er aber im Vergleich zu den anderen Regionstypen als eher schwächer entwickelt zu zählen.

Anhand der neu identifizierten HC-Datenbasis konnte eine wichtige Grundlage für die weitere HC-Forschung gelegt werden. War die Identifizierung bisher mit großem individuellem Aufwand sowie einer gewissen Subjektivität verbunden, bietet der hier verfolgte Ansatz einen Entwurf eines nachvollziehbaren und vergleichbaren Vorgehens. Auch die Einnahme verschiedener räumlicher Perspektiven hat zu vielversprechenden Erkenntnissen zu HCs und deren Rolle im innovativen räumlichen Kontext geführt. Um individuelle Schlussfolgerungen und politischer Handlungsempfehlungen wurde im Rahmen dieser Arbeit abgesehen². Ziel war es viel eher neue Perspektiven einzunehmen und einen methodischen Ansatz zu verwenden, welcher diese individualisiert zulässt.

² Im Rahmen des Forschungsprojektes „Hidden Champions als zentrales Element für die Stabilisierung ländlicher Regionen in Zeiten der Digitalisierung“ (HiDi), gefördert vom BULE, erscheint in den kommenden Monaten ein White Book, welches diese Thematik gemeinsam mit den Erkenntnissen der qualitativen Analysen von Dr. Carsten Rietmann und Leon Worbs (Leibniz-Universität Hannover) adressiert.

15 Literatur

- Abbasiharofteh, M.; Krüger, M.; Kinne, J.; Lenz, D.; & Resch, B. (2023). The digital layer: alternative data for regional and innovation studies. *Spatial Economic Analysis*, S. 1-23.
- Allen, M. P. (1997). *Understanding Regression Analysis*. Springer Science & Business Media.
- Allen, T. J.; Gloor, P.; Fronzetti Colladon, A.; Woerner, S. L. & Raz, O. (2016). The power of reciprocal knowledge sharing relationships for startup success. *Journal of Small Business and Enterprise Development*, 23(3), S. 636-651.
- Anselin, L. (1988). *Spatial econometrics: methods and models (Vol. 4)*. Springer Science & Business Media, Niederlande.
- Anselin, L. (1995). Local indicators of spatial association - LISA. *Geographical analysis*, 27(2), S. 93-115.
- Audretsch, D. B. & Feldman, M. P. (2004). The geography of innovation and spillovers. *Handbook of regional and urban economics (Vol 4)*, S. 2713-2739.
- Audretsch, D. B.; Lehmann, E. E. & Schenkenhofer, J. (2018). Internationalization strategies of hidden champions: lessons from Germany. *Multinational Business Review*, 26(1), S. 2-24.
- Autio, E.; Nambisan, S.; Thomas, L. D. & Wright, M. (2018). Digital affordances, spatial affordances, and the genesis of entrepreneurial ecosystems. *Strategic Entrepreneurship Journal*, 12(1), S. 72-95.
- Backhaus, K.; Erichson, B.; Plinke, W. & Weiber, R. (2011). *Multivariate Analysemethoden. Eine anwendungsorientierte Einführung*, 13. Aufl. Springer, Berlin, Heidelberg.
- Backhaus, K.; Erichson, B.; Plinke, W. & Weiber, R. (2016). *Multivariate Analysemethoden*. Springer, Berlin, Heidelberg.
- Balland, P.-A.; Boschma, R. & Frenken, K. (2015). Proximity and innovation: From statics to dynamics. *Regional Studies*, 49(6), S. 907-920.
- Bathelt, H.; Cohendet, P.; Henn, S. & Simon, L. (2017). 'Innovation and Knowledge Creation: Challenges to the Field'. In: Bathelt, H.; Cohendet, P.; Henn, S. & Simon, L. (Hrsg.). *The Elgar Companion to Innovation and Knowledge Creation*. Edward Elgar Publishing, Cheltenham, UK; Northampton, MA, USA, S. 1-25.

Literatur

- Bathelt, H. & Glückler, J. (2017). Toward a relational economic geography. In: Martin, R. (Hrsg.). *Economy*. Routledge, London, S. 73-100.
- Bathelt, H. & Henn, S. (2017). National and regional innovation systems. In: Bathelt, H.; Cohendet, P.; Henn, S. & Simon, L. (Hrsg.). *The Elgar companion to innovation and knowledge creation*. Edward Elgar Publishing, Cheltenham, UK; Northampton, MA, USA, S. 457-471.
- Bathelt, H.; Malmberg, A. & Maskell, P. (2004). Clusters and knowledge: local buzz, global pipelines and the process of knowledge creation. *Progress in human geography*, 28(1), S. 31-56.
- Bathelt, H. & Schuldt, N. (2010). International trade fairs and global buzz, part I: Ecology of global buzz. *European Planning Studies*, 18(12), S. 1957-1974.
- Bathelt, H. & Turi, P. (2011). Local, global and virtual buzz: The importance of face-to-face contact in economic interaction and possibilities to go beyond. *Geoforum*, 42(5), S. 520-529.
- Bates, D.; Mächler, M.; Bolker, B. & Walker, S. (2015). Fitting Linear Mixed-Effects Models Using lme4. *Journal of Statistical Software*, 67(1), S. 1-48.
- Benz, L.; Block, J. & Johann, M. (2020). Börsennotierte Hidden Champions. *Zfo - Zeitschrift Führung Und Organisation*, 5, S. 291-295.
- Benz, L., Block, J., & Johann, M. (2021). Hidden champions as a determinant of regional development: An analysis of German districts. *ZFW-Advances in Economic Geography*, (0).
- Beugelsdijk, S. & Cornet, M. (2002). 'A far friend is worth more than a good neighbour': Proximity and innovation in a small country. *Journal of Management and Governance*, 6(2), S. 169-188.
- Bivand, R. S.; Pebesma, E. J. & Gómez-Rubio, V. (2008). *Applied Spatial Data Analysis with R*. Springer, New York.
- Bivand, R. S.; Pebesma, E. J. & Gómez-Rubio, V. (2013). *Applied Spatial Data Analysis with R*. Springer, New York.
- Blackburn, J.; Merrilees, B.; Tiessen, J. & Lindman, M. (2001). Hidden (SME) champions: The role of innovation and strategy. In: *Proceedings of the Australian and New Zealand Marketing Academy Conference*, S. 1-5.

Literatur

- Block, J. H. (2019). Rural entrepreneurship: between start-ups, hidden champions and family businesses. *Business, Economics, Sustainability, Leadership and Innovation*, 3, S. 14-19.
- Boschma, R. (2005). Proximity an Innovation: A critical Assessment, *Regional Studies*, 39 (1), S. 61-74.
- Braček Lalić, A.; Purg, D. (Hrsg.) (2021). *Hidden Champions in Dynamically Changing Societies*. Springer International Publishing, Cham.
- Brkic, N. & Berberovic, D. (2013). Hidden Champions of Bosnia and Herzegovina. In: McKierman, P. & Purg, D. (Hrsg.). *Hidden Champions in CEE and Turkey: Carving Out a Global Niche*. Springer: Berlin, Heidelberg, S. 141-162.
- Brydges, T. & Hrac, B. J. (2019). The locational choices and interregional mobilities of creative entrepreneurs within Canada's fashion system. *Regional Studies*, 53(4), S. 517–527.
- Brökel, T.; Balland, P. A.; Burger, M. & Van Oort, F. (2014). Modeling knowledge networks in economic geography: a discussion of four methods. *The annals of regional science*, 53(2), S. 423-452.
- Bundesamt für Kartographie und Geodäsie (BKG) (2016). Gemeindegrenzen 2016. GeoBasis-DE. opendata-esri-de.opendata.arcgis.com/datasets/esri-de-content:gemeindegrenzen-2016/about (03.08.2023).
- Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Bundesamt für Bauwesen und Raumordnung (BBR) (2018). *Hidden Champions als Impulsgeber für die Kleinstadtentwicklung? Dokumentation des Workshops am 24. Januar 2018*. Bonn.
- Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Bundesamt für Bauwesen und Raumordnung (BBR) (2019). *Hidden Champions und Stadtentwicklung. Die wirtschaftliche und gesellschaftliche Bedeutung innovativer Unternehmen für Kleinstädte in peripherer Lage*. Stand August 2019, 1. Auflage. Bonn.
- Bundesministerium für Wirtschaft und Klimaschutz (BWK) (2023). *Bund-Länder-Gemeinschaftsaufgabe. Regionale Wirtschaftsstrukturen verbessern*. www.bmwk.de/Redaktion/DE/Dossier/regionalpolitik.html (20.05.2023).
- Bundesministerium für Wirtschaft und Energie (BMWi) (2019). *Industriestrategie 2023. Leitlinien für eine deutsche und europäische Industriepolitik*.

Literatur

- www.bmwk.de/Redaktion/DE/Publikationen/Industrie/industriestrategie-2030.pdf?__blob=publicationFile (03.08.2023).
- Bureau van Dijk (2020). Markus Datenbank. login.bvdinfo.com/R0/MarkusNeo (03.08.2023).
- Buse, S.; Tiwari, R. (2014). Global Innovation Strategies of German Hidden Champions in Key Emerging Markets (85).
- Büchler, J. P. (2017). Fallstudienkompendium Hidden Champions. Springer Gabler, Wiesbaden.
- Büchler, J. P. & Müller, C. (2017). Autoneum - Hochleistungskultur für Innovation. In: Büchler, J.-P. (Hrsg.). Fallstudienkompendium Hidden Champions. Innovationen für den Weltmarkt. Springer Gabler, Wiesbaden, S. 37-54.
- Blomström, M. & Kokko, A. (2001). Foreign Direct Investment and Spillovers of Technology. *International Journal of Technology Management* (22), S. 435-454.
- Çetindamar, D. & Kozanoglu, H. (2012). Competitiveness of Turkish hidden champions. In: 2012 Proceedings of PICMET'12: Technology Management for Emerging Technologies, S. 2072-2077.
- Chang, H. J. & Ko, Y. H. (2014). An analysis of key success factors of hidden champions in Korea: Case study focusing on IT industry. *International Business Review*, 18(2), S. 25-56.
- Collins, J. (2016). *Good to Great: Why Some Companies Make the Leap and Others Don't*. Random House Business: London.
- Cleff, T. (2015). *Deskriptive Statistik und Explorative Datenanalyse*. Springer Gabler, Wiesbaden.
- Clemens, K. (2015). Geocoding with openstreetmap data. *GEOProcessing 2015*, 10. personales.upv.es/thinkmind/dl/conferences/geoprocessing/geoprocessing_2015/geoprocessing_2015_1_10_30013.pdf (06.08.2023).
- Crevoisier, O. (2014). Beyond territorial innovation models: the pertinence of the territorial approach. *Regional Studies*, 48(3), S. 551-561.
- Cyberbond Europe GmbH (2023). Cyberbond -Kurz und knapp. www.cyberbond.de/das-unternehmen/kurz-und-knapp/ (24.04.2023).

Literatur

- Daneyko, P. & Golenchenko, P. (2013). Hidden Champions of Belarus. In Hidden Champions. In: McKierman, P. & Purg, D. (Hrsg.). Hidden Champions in CEE and Turkey: Carving Out a Global Niche. Springer, Berlin, Heidelberg, S. 127-140.
- Danson, M. & De Souza, P. (Hrsg.) (2012). Regional development in Northern Europe: Peripherality, marginality and border issues. Routledge, London, New York.
- Dapena A. D.; Vásquez, E. F. & Morollón, F. R. (2016). The role of spatial scale in regional convergence: the effect of MAUP in the estimation of β -convergence equations. *Ann Reg Sci*, (56), S. 473–489.
- Dedrick, R. F.; Ferron, J. M.; Hess, M. R.; Hogarty, K. Y.; Kromrey, J. D.; Lang, T. R.; Niles, J.D. & Lee, R. S. (2009). Multilevel modeling: A review of methodological issues and applications. *Review of Educational Research*, 79(1), S. 69-102.
- Deng, D. & Wan, Z. (2006). Focus On Understanding of Chinese Hidden Champions. Zhejiang University Press, Hangzhou, China.
- Depalov, V. R.; Todorović, M. & Marinković, S. (2013). Hidden Champions of Serbia. In: McKierman, P. & Purg, D. (Hrsg.). Hidden Champions in CEE and Turkey: Carving Out a Global Niche. Springer, Berlin, Heidelberg, S. 307-330.
- Din, F.-U.; Dolles, H. & Middel, R. (2013). Strategies for small and medium-sized enterprises to compete successfully on the world market: Cases of Swedish hidden champions. *Asian Business & Management*, 12(5), S. 591–612.
- Dinis, A. (2006). Marketing and innovation: Useful tools for competitiveness in rural and peripheral areas. *European Planning Studies*, 14(1), S. 9–22.
- Ding, K. (2008). How to become successful Hidden Champions: Case Study of Japanese SMEs. *Business Frontier*, 27(1).
- Doloreux, D. (2003). Regional innovation systems in the periphery: The case of the beauce in Québec (Canada). *International Journal of Innovation Management*, 7(1), S. 67–94.
- Doloreux, D. & Shearmur, R. (2012). Collaboration, information and the geography of innovation in knowledge intensive business services. *Journal of economic geography*, 12(1), S. 79-105.

Literatur

- Döring, T. (2004). Räumliche Wissens-Spillovers und regionales Wirtschaftswachstum. *Journal of Contextual Economics–Schmollers Jahrbuch*, (1), S. 95-137.
- Dörr, J. O.; Kinne, J.; Lenz, D.; Licht, G. & Winker, P. (2021). An integrated data framework for policy guidance in times of dynamic economic shocks. ZEW-Centre for European Economic Research Discussion Paper, (21-062).
- Dr. Doeblin Gesellschaft für Wirtschaftsforschung mbH (2019). Reputationsindex MDax: Spitzenplätze für Puma, Fielmann und Hugo Boss. www.wp-online.de/studien/info_2021_oP.php (20.09.2021).
- Dr. Hoenle AG (2023). Bogenoffset. www.hoenle.de/bogenoffset (19.04.2023).
- Dubois, A. (2016). Transnationalising entrepreneurship in a peripheral region—The translocal embeddedness paradigm. *Journal of Rural Studies*, (46), S. 1–11.
- Eckey, H. F.; Kosfeld, R. & Türck, M. (2006). Räumliche Ökonometrie. *WiSt-Wirtschaftswissenschaftliches Studium*, 35(10), S. 548-554.
- Eckey, H. F.; Kosfeld, R. & Türck, M. (2007a). Regionale Entwicklung mit und ohne räumliche Spillover-Effekte. *Jahrbuch für Regionalwissenschaften*, (27), S. 23-42.
- Eckey, H.-F.; Schwengler, B. & Türck, M. (2007b). Vergleich von deutschen Arbeitsmarktregionen. IAB Discussion Paper: Beiträge zum wissenschaftlichen Dialog aus dem Institut für Arbeitsmarkt- und Berufsforschung, 3/2007. Nürnberg.
- Eder, J. & Trippel, M. (2019). Innovation in the periphery: Compensation and exploitation strategies. *Growth and Change*, 50(4), S. 1511-1531.
- Eder, J. (2019a). Innovation in the periphery: A critical survey and research agenda. *International Regional Science Review*, 42(2), S. 119-146.
- Eder, J. (2019b). Peripheralization and knowledge bases in Austria: towards a new regional typology. *European Planning Studies*, 27(1), S. 42-67.
- Eisenwerk Hansenclever & Sohn GmbH (2020). Unternehmen. www.hasenclever.com/das-eisenwerk (19.04.2023).
- Enders, C. K. & Tofighi, D. (2007). Centering predictor variables in cross-sectional multilevel models: a new look at an old issue. *Psychological methods*, 12(2), S. 121-138.

Literatur

- Ermann, U.; Lang, T. & Megerle, M. (2011). Weltmarktführer abseits der Agglomerationsräume. aktuell.nationalatlas.de/wp-content/uploads/12_11_Weltmarktfuehrer.pdf (13.09.2021).
- Europäische Kommission (2001). Green Paper, Promoting a European Framework for Corporate Social Responsibility. ec.europa.eu/commission/presscorner/detail/en/DOC_01_9 (19.06.2023).
- Farhauer, O. & Kröll, A. (2009). Verfahren zur Messung räumlicher Konzentration und regionaler Spezialisierung in der Regionalökonomik. Passauer Diskussionspapiere-Volkswirtschaftliche Reihe, 58(9). Universität Passau.
- Feubli, P. & Gachet, E. (2015). The Hidden Swiss Champions: Small but World Class. Credit Suisse. www.credit-suisse.com/corporate/en/articles/news-and-expertise/thehidden-swiss-champions-small-but-world-class-201506.html (19.06.2023).
- Fitjar, R. D. & Rodríguez-Pose, A. (2011a). Innovation in the periphery: Firms, values and innovation in Southwest Norway. *European Planning Studies*, 19(4), S. 555–574.
- Fitjar, R. D. & Rodríguez-Pose, A. (2011b). When local interaction does not suffice: Sources of firm innovation in Urban Norway. *Environment and Planning A*, 43(6), S. 1248–1267.
- Fitjar, R. D. & Rodríguez-Pose, A. (2017). Nothing is in the air. *Growth and Change*, 48(1), S. 22–39.
- Fitjar, R. D. & Rodríguez-Pose, A. (2020). Where cities fail to triumph: The impact of urban location and local collaboration on innovation in Norway. *Journal of Regional Science*, 60(1), S. 5–32.
- Florida, R.; Adler, P. & Mellander, C. (2017). The city as innovation machine. *Regional Studies*, 51(1), S. 86–96.
- Frankfurter Allgemeine Zeitung (2019). Deutschlands Innovationsführer. www.faz.net/asv/deutschlands-innovationsfuehrer/ (20.07.2023).
- Freimark, A. J.; Habel, J.; Hülsbömer, S.; Schmitz, B. & Teichmann, M. (2019). Hidden Champions - Champions of Digital Transformation? IDG Business Media, München.

Literatur

- Frietsch, R. (2015). Global Champions und Hidden Champions: Internationale Konzerne und KMU im Innovationswettbewerb. Fraunhofer ISI Discussion Papers - Innovation Systems and Policy Analysis 45, Fraunhofer ISI, Karlsruhe.
- Fryges, H. (2006). Hidden champions — How young and small technology-oriented firms can attain high export-sales ratios. ZEW — Centre for European Economic Research Discussion Paper (06-045).
- Garaus, C.; Güttel, W. H.; Konlechner, S.; Koprax, I.; Lackner, H.; Link, K. & Müller, B. (2016). Bridging knowledge in ambidextrous HRM systems: Empirical evidence from hidden champions. *The International Journal of Human Resource Management*, 27(3), S. 355-381.
- Gertler, M. S. (1993). Implementing advanced manufacturing technologies in mature industrial regions: towards a social model of technology production. *Regional Studies*, 27(7), S. 665-680.
- Glaeser, E. (2011). *Triumph of the city: How urban spaces make us human*. Pan Macmillan, London.
- Glückler, J. (2013). Knowledge, networks and space: Connectivity and the problem of non-interactive learning. *Regional Studies*, 47(6), S. 880-894.
- Glückler, J. (2014). How controversial innovation succeeds in the periphery? A network perspective of BASF Argentina. *Journal of Economic Geography*, (14), S. 903–927.
- Glückler, J. & Bathelt, H. (2017). Institutional context and innovation. In: Bathelt, H.; Cohendet, P.; Henn, S. & Simon, L. (Hrsg.). *The Elgar Companion to Innovation and Knowledge Creation*. Cheltenham, UK; Northampton, MA, USA: Edward Elgar Publishing, S. 121-137.
- Glückler, J.; Shearmur, R. & Martinus, K. (2022). From liability to opportunity: Reconceptualizing the role of periphery in Innovation. SPACES online. www.spaces-online.com/index_2022.php (06.08.2023)
- Grabher, G. & Ibert, O. (2014). Distance as asset? Knowledge collaboration in hybrid virtual communities. *Journal of Economic geography*, 14(1), S. 97-123.
- Grabher, G. (2018). Marginality as strategy: Leveraging peripherality for creativity. *Environment and Planning A: Economy and Space*, 50(8), S. 1785-1794.

Literatur

- Grammer AG (2023). Innovation hat Tradition. www.grammer.com/presse/artikelansicht/innovation-hat-tradition.html (19.04.2023).
- Grave, E.; Bojanowski, P.; Gupta, P.; Joulin, A. & Mikolov, T. (2018). Learning word vectors for 157 languages. *arXiv preprint arXiv:1802.06893*.
- Grillitsch, M. & Nilsson, M. (2017). Firm performance in the periphery: on the relation between firm-internal knowledge and local knowledge spillovers. *Regional Studies*, 51(8), S. 1219-1231.
- Guo, S. (2005). Analyzing grouped data with hierarchical linear modeling. *Children and Youth Service Review* (27), S. 637–652.
- Guttman, L. (1954). Some necessary conditions from common-factor analysis. *Psychometrika*, 19(2), S. 149-161.
- Gök, A.; Waterworth, A. & Shapira, P. (2015). Use of web mining in studying innovation. *Scientometrics*, 102(1), S. 653-671.
- Hass, F. S. & Arsanjani, J. J. (2021). The Geography of the Covid-19 Pandemic: A Data-Driven Approach to Exploring Geographical Driving Forces. *International Journal of Environmental Research and Public Health*, 18(6), S. 1-19.
- Heinrich Wagner Sinto Maschinenfabrik GmbH (2023): Unternehmen. www.wagner-sinto.de/unternehmen/ (24.04.2023).
- Héroux-Vaillancourt, M.; Beaudry, C. & Rietsch, C. (2020). Using web content analysis to create innovation indicators—What do we really measure? *Quantitative Science Studies*, 1(4), S. 1601-1637.
- Herstatt, C.; Tiwari, R. & Buse, S. (2017). Innovating for emerging markets? An assessment of German hidden champions' strategies. In: Burr, M. & Stephan, M. (Hrsg.). *Technologie, Strategie und Organisation*. Springer Gabler, Wiesbaden, S. 219-238.
- He, X.; Cai, D.; Shao, Y.; Bao, H. & Han, J. (2010). Laplacian regularized gaussian mixture model for data clustering. *IEEE transactions on knowledge and data engineering*, 23(9), S. 1406-1418.

Literatur

- Hilz, C. (2013). Strategisches Management und Hidden Champions. In: Landes, M. & Steiner, E. (Hrsg.). *Psychologie der Wirtschaft*. Springer VS, Wiesbaden, S. 579-587.
- Hox, J.; Moerbeek, M. & Van de Schoot, R. (2017). *Multilevel analysis: Techniques and applications*. Routledge, London.
- Hundt, C. & Holtermann, L. (2020). The role of national settings in the economic resilience of regions—Evidence from recessionary shocks in Europe from 1990 to 2014. *Growth and Change*, 51(1), S. 180-206.
- Indikatoren und Karten zur Raum- und Stadtentwicklung (INKAR) (2020). „Indikatoren und Karten zur Raum- und Stadtentwicklung.“ Bundesinstitut für Bau-, Stadt- und Raumforschung (BBSR) im Bundesamt für Bauwesen und Raumordnung (BBR) (Hrsg.). Bonn.
- Ingenieurtechnik und Maschinenbau GmbH (2023). *Maritime Technologie Made in Germany*. www.img-tech.de (24.04.2023).
- Institut für Mittelstandsforschung (IfM) (2023). *KMU-Definition der Europäischen Union*. www.ifm-bonn.org/definitionen/kmu-definition-der-eu-kommission (11.05.2023).
- Johann, M. S.; Block, J. H. & Benz, L. (2021). Financial performance of hidden champions: Evidence from German manufacturing firms. *Small Business Economics*, (59), S. 873-892.
- Juhász, S. & Lengyel, B. (2018). Creation and persistence of ties in cluster knowledge networks. *Journal of Economic Geography*, 18(6), S. 1203-1226.
- Jungwirth, G. (2010). Die Marketing-Strategien der mittelständischen österreichischen Weltmarktführer. In: Meyer, J.-M. (Hrsg.). *Strategien von kleinen und mittleren Unternehmen*. Josef Eul Verlag, Köln, S. 179-199.
- Jungwirth, G. & König, D. (2019). Corporate Social Responsibility in medium-sized Hidden Champions from Austria. *Ekonomiaz. Revista vasca de Economía*, 95(1), S. 203-227.
- Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and psychological measurement*, 20(1), S. 141-151.
- Kaiser, H. F. & Rice, J. (1974). Little jiffy, mark IV. *Educational and psychological measurement*, 34(1), S. 111-117.

Literatur

- Kamp, B. (2018). Expanding international business via smart services: Insights from hidden champions' in the machine tool industry. In: van Tulder, R.; Verbeke, A. & Piscitello, L. (Hrsg.). *International business in the information and digital age. Progress in international business research 13*, Emerald Publishing, Bringley, UK, S. 273–293.
- Kamp, B. (2019). Assessing the economic relevance of International Niche Market Leaders: empirical indicators and strategic reflections from the Basque Country. *Ekonomiaz Revista Vasca de Economía*, 95(1), S. 229-253.
- Kaudela-Baum, S.; P.-Y. Kocher & Scherrer, S. (2014). Innovationen fördern. In: *die Gestaltung von Freiräumen als Führungsaufgabe von Hidden Champions. Zeitschrift Führung und Organisation*, 2(2014), S. 74-79.
- Kiese, M. (2018). Cluster. In: *Akademie für Raumforschung und Landesplanung (ARL) (Hrsg.). Handwörterbuch der Stadt- und Raumentwicklung. Hannover*, S. 351-357.
- Kinne, J. & Axenbeck, J. (2018). Web mining of firm websites: A framework for web scraping and a pilot study for Germany. *ZEW-Centre for European Economic Research Discussion Paper (18-033)*.
- Kinne, J. & Axenbeck, J. (2020). Web mining for innovation ecosystem mapping: a framework and a large-scale pilot study. *Scientometrics*, 125(3), S. 2011-2041.
- Kinne, J. & Lenz, D. (2021). Predicting innovative firms using web mining and deep learning. *PloS one*, 16(4).
- Kinne, J. & Resch, B. (2017). Analyzing and predicting micro-location patterns of software firms. *ISPRS International Journal of Geo-Information*, 7(1), S. 1-21.
- Kirner, E. & Zenker, A. (2011). Are Knowledge Angels the secret behind the success of Hidden Champions and Hidden Innovators. *EvoREG Research Note*, 15, S. 1-7.
- KISICO Kirchner, Simon & Co GmbH (2023). Unternehmen. www.kisico.de/unternehmen/ (24.04.2023).
- Klepper Faltbootwerft (2023). Klepper Geschichte. klepper.de/klepper-geschichte (19.04.2023).
- Kriesch, L. J. (2023). Web Mining und Natural Language Processing als methodisches Komplement in der Wirtschaftsgeographie. *Dissertation. Justus-Liebig-Universität Gießen*.

Literatur

- Krüger, M.; Kinne, J.; Lenz, D. & Resch, B. (2020). The Digital Layer: How innovative firms relate on the Web. ZEW-Centre for European Economic Research Discussion Paper, (20-003).
- Kume, V. & Kume, A. (2013). Hidden Champions of Albania. In Hidden Champions. In: McKierman, P. & Purg, D. (Hrsg.). Hidden Champions in CEE and Turkey: Carving Out a Global Niche. Springer, Berlin, Heidelberg, S. 109-126.
- Küpper, P. (2016). Abgrenzung und Typisierung ländlicher Räume. Thünen Working Paper, (68), Thünen-Institut, Braunschweig.
- Lahti, A. (2014). International trade, entrepreneurship, and monopolistic competition: German hidden champions and global markets. *China-USA Bus Rev*, 13(9), S. 592-613.
- Landau, C.; Karna, A. & Täube, F. (2016). The internationalization of hidden champions: setting the context for advancing research on emerging market strategies for German Mittelstand firms. In: Merchant, H. (Hrsg.). *Handbook of Contemporary Research on Emerging Markets*. Cheltenham, UK; Northampton, MA, USA, S. 292-316.
- Lang, T.; Görmar, F.; Graffenberger, M. & Vonnahme, L. (2019). Hidden Champions und Stadtentwicklung: die wirtschaftliche und gesellschaftliche Bedeutung innovativer Unternehmen für Kleinstädte in peripherer Lage. Bundesamt für Bauwesen und Raumordnung, Bonn.
- Langenscheidt, F. & Venohr, B. (Hrsg.) (2010). *Lexikon der deutschen Weltmarktführer: die Königsklasse deutscher Unternehmen in Wort und Bild*. Gabal, Offenbach am Main.
- Legendijk, A. & Lorentzen, A. (2007). Proximity, knowledge and innovation in peripheral regions. On the intersection between geographical and organizational proximity. *European Planning Studies*, 15(4), S. 457-466.
- Lehmann, E. E.; Schenkenhofer, J. & Wirsching, K. (2019). Hidden champions and unicorns: A question of the context of human capital investment. *Small Business Economics*, (52), S. 359-374.
- Leibniz-Zentrum für Europäische Wirtschaftsforschung GmbH Mannheim (ZEW) (2023). Mannheimer Innovationspanel (MIP). kooperationen.zew.de/zew-fdz/datenangebot/mannheimer-innovationspanel-mip (29.05.2023).

Literatur

- Leibniz-Zentrum für Europäische Wirtschaftsforschung GmbH Mannheim (ZEW) (2016-2018). Mannheim Innovation Panel - The Annual German Innovation Survey. Retrieved March 30, 2019 www.zew.de/WS109-1 (03.06.2023).
- Li, Y.; Arora, S.; Youtie, J. & Shapira, P. (2018). Using web mining to explore Triple Helix influences on growth in small and mid-size firms. *Technovation*, (76), S. 3-14.
- Li, Q. H. & Li, C. S. (2008). On hidden champion enterprises: Strategic logic, business model and critical success factors. *Journal of Southeast University (Philosophy and Social Science)*, 6(10).
- Liefner, I. & Schätzl, L. (2017). *Theorien der Wirtschaftsgeographie*. UTB, Paderborn.
- Lehmann, E. E.; Schenkenhofer, J. & Wirsching, K. (2019). Hidden champions and unicorns: a question of the context of human capital investment. *Small Business Economics*, (52), S. 359–374.
- Lorentzen, A. (2007). The geography of knowledge sourcing—A case study of polish manufacturing enterprises. *European Planning Studies*, 15(4), S. 467–486.
- Lundvall, B. A. (1992). *National systems of innovation: towards a theory of innovation and interactive learning*. Pinter, London.
- Malte, A. & Ratadiya, P. (2019). Evolution of transfer learning in natural language processing. arXiv preprint [arXiv:1910.07370](https://arxiv.org/abs/1910.07370).
- Margarian, A. (2013). A Constructive Critique of the Endogenous Development Approach in the European Support of Rural Areas. *Growth and Change* 44(1), S. 1–29.
- Martin, R. & Sunley, P. (1998). Slow convergence? The new endogenous growth theory and regional development. *Economic Geography*, 74(3), S. 201-227.
- Mayer, H. & Baumgartner, D. (2014). The role of entrepreneurship and innovation in peripheral regions. *DisP-The Planning Review*, 50(1), S. 16-23.
- Mayer, H.; Habersetzer, A. & Meili, R. (2016). Rural-urban linkages and sustainable regional development: The role of entrepreneurs in linking peripheries and centers. *Sustainability*, 8(8), S. 745-758.

Literatur

- Meili, R. & Shearmur, R. (2019). Diverse diversities—Open innovation in small towns and rural areas. *Growth and Change*, 50(2), S. 492–514.
- Meta Platforms, Inc. (2023). Meta-Plattform-Nutzungsbedingungen. www.developers.facebook.com/terms/ (11.07.2023).
- Metropolregion Hamburg (2023). Alle 11 Metropolregionen im Kurzportrait. www.deutsche-metropolregionen.org (26.04.2023).
- Milbert, A (2017). BBSR-Typisierung als Beitrag für die wissenschaftliche und politische Debatte. www.teltow.de/fileadmin/user_upload/DL_12_2015.pdf (05.08.2023).
- minCam GmbH (2023). Die Firma minCam. www.mincam.de/ueber-uns-mincam (24.04.2023).
- Miner, G.; Elder IV, J.; Fast, A.; Hill, T.; Nisbet, R. & Delen, D. (2012). *Practical text mining and statistical analysis for non-structured text data applications*. Academic Press, Waltham, MA.
- McNicholas, P. D. (2016). „Model-Based Clustering“. *Journal of Classification*, (33), S. 331-373.
- McKiernan, P. & Purg, D. (2013). *Hidden champions in CEE and Turkey*. Springer, Berlin, (10), 978-3.
- MORSA Wachswarenfabrik Sallinger GmbH (2021). Welcome at MORSA GmbH – Experts in Wax since 1647. www.morsa.de (19.04.2023).
- Moulaert, F. & Sekia, F. (2003). Territorial innovation models: a critical survey. *Regional Studies*, 37(3), S. 289-302.
- Muller, E.; Zenker, A. & Héraud, A. (2009). Entering the KIBS's black box: There must be an angel! (Or is there something like a knowledge angel?). Working Papers Firms and Region No. R7/2009. Karlsruhe: Fraunhofer ISI.
- Müller, C. (2018). Der Weltmarktführer-Index für die DACH-Region. In: Büchler, J. P. (Hrsg.). *Fallstudienkompendium Hidden Champions – Innovationen für den Weltmarkt*. Wiesbaden: Springer Gabler, S. 223–229.
- Muñoz, E. P.; Ripoll-i-Alcon, J. & Silvente, V. B. (2017). Hidden champions in Spain: The path to successful business decisions. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 24, S. 190-208.

Literatur

- NOVOFOL Kunststoffprodukte GmbH & Co KG (2023). Innovationskraft ist unser Motor. www.nowofol.com/de/warum-nowofol/innovation/ (24.04.2023).
- OpenStreetMap Contributors (2023). Nominatim – OpenStreetMap Wiki wiki.openstreetmap.org/wiki/Nominatim (25.04.2023).
- Oughton, C.; Landabaso, M. & Morgan, K. (2002). The regional innovation paradox: Innovation policy and industrial policy. *The Journal of Technology Transfer*, 27(1), S. 97–110.
- Palii, N. & Oksenyuk, V. (2013). Hidden Champions of Ukraine. In *Hidden Champions in CEE and Turkey: Carving Out a Global Niche* (S. 407-427). Springer: Berlin, Heidelberg.
- Petrov, A. (2011). Beyond Spillovers. Interrogating Innovation and Creativity in the Peripheries. In: Bathelt, H.; Feldman, M. P. & Kogler, D. (Hrsg.). *Beyond Territory. Dynamic Geographies of Knowledge*, Routledge, London.
- Petraite, M. & Dlugoborskyte, V. (2017). Hidden Champions from Small Catching-Up Country: Leveraging Entrepreneurial Orientation, Organizational Capabilities and Global Networks. In: Sindakis, S. & Theodorou, P. (Hrsg.). *Global Opportunities for Entrepreneurial Growth. Coopetition and Knowledge Dynamics within and across Firms*. Emerald Publishing Limited, Bingley, S. 91–122.
- Pittrof, M. (2011). *Die Bedeutung der Unternehmenskultur als Erfolgsfaktor für Hidden Champions*. Gabler, Wiesbaden.
- Polèse, M. & Shearmur, R. (2002). The periphery in the knowledge economy. The spatial dynamics of the canadian economy and the future of non-metropolitan regions in Quebec and the Atlantic provinces. Montreal, Canada: INRSUrbanisation Culture et Société.
- Porter, M. E. (2013). *Wettbewerbsstrategie: Methoden zur Analyse von Branchen und Konkurrenten*. Campus Verlag, Frankfurt am Main.
- Purg, D. & Rant, M. (Hrsg.) (2011): *Hidden Champions in CEE and Dynamically Changing Environments*, CEEMAN, Bled.
- Purg, D.; Saginova, O.; Skorobogatykh, I. & Musatova, Z. (2016). Family Owned Hidden Champions in Russia: Innovations, Human Capital and Internationalization. *Indian Journal of Science and Technology*, 9(12), S. 1-10.

Literatur

- Rallet, A. & Torre, A. (1999). Is geographical proximity necessary in the innovation networks in the era of the global economy? *GeoJournal*, (49), S. 373–380.
- Rallet, A. & Torre, A. (2017). Geography of innovation, proximity and beyond. In: Bathelt, H.; Cohendet, P.; Henn, S. & Simon, L. (Hrsg.). *The Elgar Companion to Innovation and Knowledge Creation*. Edward Elgar Publishing, Cheltenham, UK; Northampton, MA, USA, S. 421-439.
- Rammer, C.; Kinne, J. & Blind, K. (2020). Knowledge proximity and firm innovation: A microgeographic analysis for Berlin. *Urban Studies*, 57(5), S. 996-1014.
- Rammer, C. & Spielkamp, A. (2015). Hidden champions – driven by innovation: empirische Befunde auf Basis des Mannheimer Innovationspanels. ZEW - Leibniz-Zentrum für Europäische Wirtschaftsforschung: Mannheim.
- Rammer, C. & Spielkamp, A. (2019a). The distinct features of hidden champions in Germany: A dynamic capabilities view. *ZEW Discussion Papers*, Nr. 19-012, ZEW - Leibniz-Zentrum für Europäische Wirtschaftsforschung: Mannheim.
- Rammer, C. & Spielkamp, A. (2019b). German Hidden Champions: competitive strategies, knowledge management and innovation in globally leading niche players. *Ekonomiaz, Revista vasca de Economía*, 95(1), S. 65-87.
- Rant, M. B. & Černe, S. K. (2017). Becoming a hidden champion: From selective use of customer intimacy and product leadership to business attractiveness. *The South East European Journal of Economics and Business*, 12(1).
- Rasche, C. (2003). Was zeichnet die "Hidden Champions" aus? Erfolgreich im Schatten der Großen, Berlin: Kolleg für Leadership und Management, S. 217-237.
- Reidolf, M. & Graffenberger, M. (2019). How local resources shape innovation and path development in rural regions. Insights from rural Estonia. *Journal of Entrepreneurship, Management and Innovation*, 15(3), S. 131-162.
- Rey, S. J.; Arribas-Bel, D. & Wolf, L. J. (2020). *Geographic Data Science with Python*.
- Richardson, L. (2007). Beautiful soup documentation. *April*.
buildmedia.readthedocs.org/media/pdf/beautiful-soup-4/latest/beautiful-soup-4.pdf
(06.08.2023)

Literatur

- Rietmann, C. (2021a). Hidden Champions and their integration in rural regional innovation systems: Insights from Germany. *ZFW–Advances in Economic Geography*, (0), S. 1-20.
- Rietmann, C. (2021b). Digital pioneers in the periphery? Toward a typology of rural Hidden Champions in times of digitalization. *Journal of Small Business & Entrepreneurship*, S. 1-21.
- Rietmann, C. (2022a). Hidden Champions as a central element for the stabilization of rural areas in times of digitalization.
- Rietmann, C. (2022b). Corporate responsibility and place leadership in rural digitalization: the case of Hidden Champions. *European Planning Studies*, S. 1-21.
- Rodríguez-Pose, A. & Fitjar, R. D. (2013). Buzz, archipelago economies and the future of intermediate and peripheral areas in a spiky world. *European Planning Studies*, 21(3), S. 355-372.
- Romer, P. M. (1990). Endogenous technological change. *Journal of Political Economy*, 98(52), S. 71-102.
- Rusu, B. (2013). Hidden Champions from Romania. In: McKierman, P. & Purg, D. (Hrsg.). *Hidden Champions in CEE and Turkey: Carving Out a Global Niche*. Springer: Berlin, Heidelberg, S. 261-278.
- Saginova, O.; Musatova, Z. & Skorobogatykh, I. (2019). Hidden Champions in Russia: Surviving and Developing 2011-2019. *Small Firm Internationalisation and International Entrepreneurship*, S. 5-10.
- Santa, M. & Kekenovski, L. (2013). Hidden Champions of the Republic of Macedonia. In: McKierman, P. & Purg, D. (Hrsg.). *Hidden Champions in CEE and Turkey: Carving Out a Global Niche*. Springer: Berlin, Heidelberg, S. 245-260.
- Sariyev, N. (2022). An assessment of selected tax burdens and reliefs of hidden champions: Theoretical comparison between Slovakia and Ireland. *Journal of Governance & Regulation*, 11(2), S. 346–354.
- Sauka, A. (2013). Hidden Champions of Latvia. In: McKierman, P. & Purg, D. (Hrsg.). *Hidden Champions in CEE and Turkey: Carving Out a Global Niche*. Springer: Berlin, Heidelberg, S. 219-244.

Literatur

- Schätzl, L. (2000). *Wirtschaftsgeographie 2: Empirie*. UTB, Stuttgart.
- Schenkenhofer, J. (2022). Hidden champions: A review of the literature & future research avenues. *Management Review Quarterly*, 72(2), S. 417-482.
- Schenkenhofer, J. & Wilhelm, D. (2020). Fuelling Germany's Mittelstand with complementary human capital: the case of the Cooperative State University Baden-Württemberg. *European Journal of Higher Education*, 10(1), S. 72-92.
- Schlepphorst, S.; Schlömer-Laufen, N. & Holz, M. (2016). Determinants of hidden champions: Evidence from Germany. IfM Bonn: Working Paper (3/16). www.econstor.eu/bitstream/10419/146411/1/86797303X.pdf (04.08.2023).
- Schulze, P. M. (2008). Zur Messung der räumlichen Autokorrelation. openscience.ub.uni-mainz.de/bitstream/20.500.12030/691/1/1553.pdf (04.08.2023).
- Schumpeter, J. A. (1911). *Theorie der wirtschaftlichen Entwicklung: eine Untersuchung über Unternehmervergewinn, Kapital, Kredit, Zins und den Konjunkturzyklus*. Duncker & Humblot: München, Leipzig.
- Scrucca, L.; Fop, M.; Murphy, T. B. & Raftery, A. E. (2016). mclust 5: clustering, classification and density estimation using Gaussian finite mixture models. *The R Journal* 8(1), S. 289-317.
- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*, 6(2), S. 461–464.
- Seibold, L. K. C., Lantelme, M. & Kormann, H. (2019). *German Family Enterprises – A Sourcebook of Structure, Diversity, Growth and Downfall*. Springer Nature Switzerland AG, Cham.
- Shearmur, R. (2012). Are cities the font of innovation? A critical review of the literature on cities and innovation. *Cities*, (29), S. 9-18.
- Shearmur, R. & Doloreux, D. (2016). How open innovation processes vary between urban and remote environments: Slow innovators, market-sourced information and frequency of interaction. *Entrepreneurship & Regional Development*, 28(5-6), S. 337-357.
- Simon, H. (1996a): *Die heimlichen Gewinner – Hidden Champions, Erfolgsstrategien unbekannter Weltmarktführer*. Campus Verlag, Frankfurt, New York.

Literatur

- Simon, H. (1996b). You don't have to be German to be a "hidden champion". *Business Strategy Review*, 7(2), S. 1-13.
- Simon, H. (2007). *Hidden Champions des 21. Jahrhunderts. Die Erfolgsstrategien unbekannter Weltmarktführer*. Campus Verlag GmbH, Frankfurt am Main.
- Simon, H. (2009). *Hidden champions of the twenty-first century: Success strategies of unknown world market leaders*. New York: Springer.
- Simon, H. (2012). *Hidden Champions Aufbruch nach Globalia. Die Erfolgsstrategien unbekannter Weltmarktführer*. Campus Verlag GmbH, Frankfurt am Main.
- Simon, H. (2018). *Hidden Champions: Innovative Speerspitze der Globalisierung*. In: Büchler, J.-P. (Hrsg.). *Fallstudienkompendium Hidden Champions. Innovationen für den Weltmarkt*. Springer Gabler, Wiesbaden, S. 3-19.
- Simon, H. (2020). *Erfolgsfaktoren von Hidden Champions bei der Digitalisierung*. In: Bruhn, M.; Burmann, C. & Kirchgeorg, M. (Hrsg.). *Marketing Weiterdenken. Zukunftspfade für eine marktorientierte Unternehmensführung*. Wiesbaden: Springer Gabler, S. 151-161.
- Simon, H. (2021). *Hidden Champions – Die neuen Spielregeln im chinesischen Jahrhundert*. Campus Verlag GmbH, Frankfurt am Main.
- Simon, H. & Huber, F. (2007). *Hidden Champions - Lernen von mittelständischen Marktführern. Mittelstand hat Zukunft - Praxishandbuch für eine erfolgreiche Unternehmenspolitik*, Gabler, Wiesbaden, S. 41-56.
- Simon, H. & Lippert, S. (2007). *Hidden Champions des 21. Jahrhunderts Deutschland und Japan im Vergleich*. *Japanmarkt*, 4(1), S: 8-15.
- Simon, H. & Zatta, D. (2008). *Growth Strategies from the Hidden Champions*. In: Da-Cruz P. & Cappallo, S. (Hrsg.). *Gesundheitsmegamarkt Indien*. Gabler, Wiesbaden.
- Skorobogatykh, I. I.; Saginova, O. V. & Musatova, Z. B. (2013). *Hidden Champions of Russia*. In: McKierman, P. & Purg, D. (Hrsg.). *Hidden Champions in CEE and Turkey: Carving Out a Global Niche*. Springer: Berlin, Heidelberg, S. 279-305.
- Sotarauta, M.; Horlings, I. & Liddle, J. (2012). *Leadership and Change in Sustainable Regional Development*. Routledge, London.

Literatur

- Statistisches Bundesamt (2023). Kleine und mittlere Unternehmen. www.destatis.de/DE/Themen/Branchen-Unternehmen/Unternehmen/Kleine-Unternehmen-Mittlere-Unternehmen/_inhalt.html (04.04.2023).
- Statistische Ämter des Bundes und der Länder (2020a). Bevölkerung nach Geschlecht – Stichtag 31.12. - regionale Tiefe: Gemeinden (ab 2016).
- Statistische Ämter des Bundes und der Länder (2020b). Bodenfläche nach Art der tatsächlichen Nutzung – Stichtag 31.12. - regionale Tiefe: Gemeinden (ab 2016). 33111-01-01-5.
- Statistische Ämter des Bundes und der Länder (2020c). Sozialversicherungspflichtig Beschäftigte am Arbeits- und Wohnort, Ein- und Auspendler über Gemeindegrenzen -Stichtag 30.06. - regionale Ebenen. 13111-08-02-5-B.
- Statistische Ämter des Bundes und der Länder (2020d). IST-Aufkommen, Grundbeträge, Hebesätze, Realsteueraufbringungskraft, Gewerbesteuerumlage, Gewerbesteuer netto, Gemeindeanteil an der Einkommensteuer, Gemeindeanteil an der Umsatzsteuer und Steuereinnahmekraft Jahressumme - regionale Tiefe: Gemeinden. 71231-01-03-5.
- Statistik der Bundesagentur für Arbeit (2018). Sozialversicherungspflichtig Beschäftigte (SvB) am Arbeitsort (AO) nach Wirtschaftsabschnitten WZ 2008.
- Stocker, M. & Szlávik, P. (2013). Hidden Champions of Hungary. In: McKierman, P. & Purg, D. (Hrsg.). Hidden Champions in CEE and Turkey: Carving Out a Global Niche. Springer: Berlin, Heidelberg, S. 201-217.
- Thünen-Institut für Ländliche Räume (2018). „Landatlas“. www.landatlas.de (22.12.2022).
- Tiwari, R. & Buse, S. (2014). German Mittelstand discovers BRIC: A survey of product strategies of German 'Hidden Champions' in China and India. *Indo-German Economy*, 5(1), S. 5-11.
- Tutz, G. (2010). Regression für Zählvariablen. In: Wolf, C.; Best, H. (Hrsg.). *Handbuch der sozialwissenschaftlichen Datenanalyse*. Springer VS, Wiesbaden, S. 887-904.
- Tödting, F. & Trippel, M. (2005). One size fits all?: Towards a differentiated regional innovation policy approach. *Research policy*, 34(8), S. 1203-1219.
- Urban, D. (2022). Mehrebenenanalyse: die wichtigsten 23 Modelle zur Analyse von dichotomen und metrischen Zwei- und Drei-Ebenen-Effekten (unter Verwendung von Mplus). (2.

Literatur

- Auflage). Schriftenreihe des Instituts für Sozialwissenschaften der Universität Stuttgart - SISS. (51). Stuttgart: Universität Stuttgart, Fak. 10 Wirtschafts- und Sozialwissenschaften, Institut für Sozialwissenschaften.
- Vaughan, L. & Yang, R. (2013). Web traffic and organization performance measures: Relationships and data sources examined. *Journal of informetrics*, 7(3), S. 699-711.
- Venohr, B. & Bruche, G. (2015). German Mittelstand Champions in Asia-Catching the Next Wave of Growth. Available at SSRN 2725336.
- Venohr, B. & Kamp, B. (2019). Global niche market leaders in emerging Asia and the necessity to become market insiders. *Ekonomiaz. Revista vasca de Economía*, 95(1), S. 111-133.
- Venohr, B.; Meyer, K. E. (2007). The German miracle keeps running: How Germany's hidden champions stay ahead in the global economy, Working Paper, No. 30, Fachhochschule für Wirtschaft Berlin, IMB Institute of Management Berlin.
- Venohr, B. & Meyer, K. (2009). Uncommon common sense. *Business Strategy Review*, 20(1), S. 38-43.
- Virkkala, S. (2007). Innovation and networking in peripheral areas—A case study of emergence and change in rural manufacturing. *European Planning Studies*, 15(4), S. 511-529.
- Vonnahme, L. & Lang, T. (2019). Peripher global: Ergebnisse der standardisierten Befragung zu Innovationsaktivitäten von Weltmarktführern in Deutschland. Leipziger Universitätsverlag.
- Voudouris, I.; Lioukas, S.; Makridakis, S. & Spanos, Y. (2000). Greek Hidden Champions: Lessons from Small, Littleknown Firms in Greece. *European Management Journal* 18(6), S. 663-674.
- Walravens, A. & Filipović, N. (2013). Three Bivalent Performance Factors of Hidden Champions: Ownership, Organizational Culture and Organizational Governance. In: McKierman, P. & Purg, D. (Hrsg.). *Hidden Champions in CEE and Turkey: Carving Out a Global Niche*. Springer: Berlin, Heidelberg, S. 37-52.
- Whittington, K. B.; Owen-Smith, J. & Powell, W. W. (2009). Networks, propinquity, and innovation in knowledge-intensive industries. *Administrative science quarterly*, 54(1), S. 90-122.

Literatur

- Wieland, T. & Fuchs, H. (2018). Regionalökonomische Disparitäten im Spiegel vom Raumtypisierungen. Standort, 42(3), S. 152–163.
- Willy Zahn Maschinenbau GmbH (2023). Zahn Hydraulik und Maschinenbau www.zahn-olpe.de (01.04.2023).
- WirtschaftsWoche (2020). Die 500 heimlichen Weltmarktführer 2021. Sonderheft Nr. 1, S. 1–98.
- Wittenstein, D. (2022). Managing Digital Transformation: Evidence from Hidden Champions and Measurement Approaches. Evidence from Hidden Champions and Measurement Approaches. Wiesbaden: Springer Fachmedien.
- Witt, A. (2015) Global Hidden Champions: The Internationalisation Paths, Entry Modes and Underlying Competitive Advantages of Germany's and Britain's Global 'top three' Niche Players. University of Edinburgh, Scotland, UK.
- Witt, A. & Carr, C. (2013). A critical review of Hidden Champions and emerging research findings on their international strategies and orientations. The Changing Geography of International Business, S. 95-113.
- Witt A, Carr C (2013) A critical review of Hidden Champions and emerging research findings on their international strategies and orientations. In: Cook G, Johns J (Hrsg.) The Changing Geography of International Business. Palgrave MacMillan, Houndmills, Basingstoke, UK, S. 95–113.
- Yoon, B. (2013). How do hidden champions differ from normal small and medium enterprises (SMEs) in innovation activities? Journal of Applied Sciences Research, 9(13), S. 6257-6263.
- Yosun, T. & Çetindamar, D. (2013). Hidden Champions of Turkey. In: McKierman, P. & Purg, D. (Hrsg.). Hidden Champions in CEE and Turkey: Carving Out a Global Niche. Springer: Berlin, Heidelberg, S. 245-260.
- Yu, H. & Chen, Y. (2009). Factors Underlying Hidden Champions in China: Case Study.. University of Halmstad.
- Yogeshwar, R. (Hrsg.) (2019). Top 100 2019 – Innovationschampions: Die innovativsten Unternehmen im Mittelstand. München: Redline.

Literatur

- Youtie, J.; Hicks, D.; Shapira, P. & Horsley, T. (2012). Pathways from discovery to commercialisation: using web sources to track small and medium-sized enterprise strategies in emerging nanotechnologies. *Technology Analysis & Strategic Management*, 24(10), S. 981- 995.
- Zastempowski, M. (2011). The innovative potential of the hidden champions of the Polish economy. *Contemporary Management Quarterly*, 4(1), S. 52-58.
- Zhu, H.; Liu, R. & Chen, B. (2023). The Rise of Specialized and Innovative Little Giant Enterprises Under China's 'Dual Circulation' Development Pattern: An Analysis of Spatial Patterns and Determinants. *Land*, 12(1), S. 259-285.

Eidesstattliche Erklärung

Ich erkläre: Ich habe die vorgelegte Dissertation selbstständig und ohne unerlaubte fremde Hilfe und nur mit den Hilfen angefertigt, die ich in der Dissertation angegeben habe. Alle Textstellen, die wörtlich oder sinngemäß aus veröffentlichten Schriften entnommen sind, und alle Angaben, die auf mündlichen Auskünften beruhen, sind als solche kenntlich gemacht. Ich stimme einer evtl. Überprüfung meiner Dissertation durch eine Antiplagiat-Software zu. Bei den von mir durchgeführten und in der Dissertation erwähnten Untersuchungen habe ich die Grundsätze guter wissenschaftlicher Praxis, wie sie in der „Satzung der Justus-Liebig-Universität Gießen zur Sicherung guter wissenschaftlicher Praxis“ niedergelegt sind, eingehalten.

Ort, Datum

Unterschrift