

Prognosen für die Anzahl der sozialversicherungspflichtig Beschäftigten in Deutschland bis zum Jahr 2015

Erstellung eines Prognosesystems auf regionaler Ebene
unter Verwendung einer neu entwickelten
Berufsklassifikation

Dissertation zur Erlangung des Grades eines Doktors der
Wirtschaftswissenschaften (Dr. rer. pol.) der Fakultät für
Wirtschaftswissenschaften der Universität Bielefeld

vorgelegt von
Dipl.-Volksw. Oliver Jones

1. Gutachter : Prof. Dr. Harry Haupt
2. Gutachter : apl. Prof. Dr. Hans Peter Wolf

Datum der mündlichen Prüfung: 29.04.2014

Danksagung

An erster Stelle danke ich meinem Betreuer Professor Harry Haupt. Während unserer Zusammenarbeit in den letzten vier Jahren hat Prof. Haupt mein Verständnis für die Ökonometrie vertieft und mich bei fachlichen Problemen hervorragend unterstützt. Das Vertrauen, dass er in mich gesetzt hat, war unschätzbar wertvoll und ohne dieses hätten die Selbstzweifel, die nicht wenige Doktoranden und Doktorandinnen von Zeit zu Zeit überkommen, vielleicht irgendwann überhand genommen. Hätte er nicht gesagt, dass es Zeit wird, alles zusammenzuschreiben und abzugeben, würde ich wahrscheinlich noch heute an der Dissertation "runddoktoren". Ich hätte mir keinen besseren Betreuer wünschen können.

Da man nicht wegen jedem kleinen Problem zu seinem Betreuer rennen möchte, muss man sich woanders – vorrangig bei seinen Arbeitskollegen – nach Hilfe umschauen. Und auch da habe ich unglaubliches Glück gehabt. Vor allem Christian Heinze danke ich für die unzähligen Gespräche, seine unermüdliche Hilfe in Sachen R und manchmal einfach nur dafür geduldig zuzuhören, während ich ein Problem detailliert erläuterte. Auch wenn es zu Beginn etwas entmutigend war mit jemandem das Büro zu teilen, der viel mehr weiß als man selbst, habe ich das sehr schnell schätzen gelernt. Ich habe sehr viel von ihm gelernt und nebenbei jede Menge Spaß dabei gehabt.

Ebenso bedanke ich mich bei Dr. Hans Ludsteck vom IAB für die hervorragende Zusammenarbeit während des Forschungsprojektes.

Last but not least, ganz vielen Dank an meinen Zweitbetreuer apl. Prof. Peter Wolf und Prof. Dietmar Bauer, der in letzter Minute als dritter Prüfer für meine Disputation eingesprungen ist.

Inhaltsverzeichnis

Zusammenfassung	1
1. Einleitung	3
2. Problemstellung	7
2.1. Prognoseaufgabe	7
2.2. Berufliche und regionale Gliederung	8
2.3. Identifikation geeigneter Methoden/Modelle	10
3. Datengrundlage	15
3.1. Berufe	17
3.2. Regionen	18
3.3. Erstellung der Zeitreihen	19
3.4. Anzahl der Berufe-Regionen-Kombinationen	21
3.5. Generierung von erklärenden Variablen	22
4. Explorative Datenanalyse	25
4.1. Anteile der Nicht-Berufe	25
4.2. Anteile und Verteilungen der Missings	27
4.3. Beschäftigtenanzahlen für die Berufe-Regionen-Kombinationen	29
4.4. Beschäftigtenentwicklung auf verschiedenen Gliederungsebenen	29
4.5. Fazit	33
5. Neue Berufsgruppierung	35
5.1. Gesichtspunkte einer Aktualisierung der KldB 1988	35
5.2. Ähnlichkeit der Berufe	37
5.3. Homogenität hinsichtlich der Bildungsabschlüsse	44
5.4. Aggregation der Berufsklassifikation	47
5.5. Implementation und Ergebnisse	48

6. Methoden und Modelle	57
6.1. Literatur zu Arbeitsmarktprognosen	57
6.2. Modellierungsstrategien und ihre Annahmen	73
6.3. Parametrische Modellierung	76
6.4. Nichtparametrische Methoden	78
6.5. Semiparametrische Modellierung	80
6.6. Hierarchische Aggregation von Prognosen	82
7. Konzeption der empirischen Analyse	87
7.1. Auswahl der Prädiktoren und deren Fortschreibung	87
7.2. Vergleich von Prognosen	88
8. Resultate für die Prognosevergleiche	99
8.1. Blossfeld-Berufe und Bundesländer	99
8.2. Jones-Berufe und Agenturbezirke	104
8.3. Fazit und Punktprognose bis ins Jahr 2015	110
9. Intervallprognosen	115
9.1. Berechnung der 1-Schritt-Prognoseintervalle	115
9.2. Steigende Unsicherheit für p -Schritt-Prognosen	119
9.3. Empirische Ergebnisse	119
10. Fazit	125
Literaturverzeichnis	129
A. Appendix	139
A.1. Alternative Schätzungen für die Prognosefehlervarianz	139
A.2. Tabellen	145
A.3. Abbildungen	174

Zusammenfassung

Neben Prognosen der Gesamtzahl der sozialversicherungspflichtig Beschäftigten besteht ein großer Bedarf an Prognosen auf regionaler Ebene für die unterschiedlichen Berufsfelder. Solche Prognosen werden beispielsweise in Entscheidungsprozessen der Arbeitsmarktpolitik genutzt oder auch im Zuge der Berufsberatung verwendet. In dieser Arbeit werden Prognosen für sämtliche Arbeitsagenturbezirke für die Jahre von 2011 bis 2015 erstellt, wobei eine neue Berufsgruppierung konzipiert und verwendet wird. Für den daraus resultierenden Grad an Disaggregation entstehen ca. 45.000 Berufe-Regionen-Kombinationen. Die separate Betrachtung von Voll- und Teilzeitbeschäftigung ergibt ca. 90.000 Zeitreihen, für die Prognosen erstellt werden müssen.

In der Dissertation werden geeignete Prognosemethoden bzw. -modelle identifiziert und bezüglich ihrer Prognose-tauglichkeit verglichen. Wegen der Umsetzbarkeit werden ausschließlich Methoden verwendet, die weitestgehend automatisiert funktionieren. Zum Einsatz kommen moderne parametrische und nichtparametrische Paneldatenmethoden sowie Innovation-State-Space-Ansätze. Um die Prognosequalität abzuschätzen, werden artifizielle Out-of-Sample-Prognosen für die konkurrierenden Methoden und naive Benchmarks erstellt und verglichen. Die Vergleiche werden auf verschiedenen Aggregationsniveaus, z. B. die Betrachtung von Bundesländern anstatt Agenturbezirken, durchgeführt und mit mehreren Kriterien bewertet.

Bei der Auswahl der Spezifikation der parametrischen Paneldatenmodelle zeigt sich, dass Modellselektionskriterien, die auf der Anpassungsgüte beruhen, nicht die Spezifikation wählen, deren Prognosegüte am besten ist. Ebenso wenig überraschend ist das Ergebnis, dass die Prognosegenauigkeit mit dem Grad an Disaggregation und dem Prognosehorizont abnimmt. Für einen Prognosehorizont von einem Jahr liegen die mittleren absoluten prozentualen Prognosefehler im einstelligen Bereich. Für einen Prognosehorizont von fünf Jahre liegen diese in einem Bereich von ca. 17 Prozent. Der naive Benchmark, also die Fortschreibung des

letzten beobachteten Werts, wird in der Regel geschlagen, wenn auch nur knapp. Da das hier vorgestellte Prognosesystem nur minimale manuelle Eingriffe erfordert, ist dies dennoch ein Gewinn, der ohne großen Aufwand erzielt werden kann.

Neben dem Vergleich der Kriterien zur Abschätzung der Prognosegüte werden Boxplots der Prognosefehler erstellt. Diese zeigen deutlich, dass automatisch generierte Prognosen zu mitunter sehr großen Fehlern führen können. Um den potentiellen Nutzern der Prognosen diese Unsicherheit vor Augen zu führen, werden Prognoseintervalle berechnet. In einigen Fällen sind diese besonders weit und weisen somit auf die Notwendigkeit hin, die Prognosen bzw. die zugrunde liegende Beschäftigungsentwicklung genauer zu analysieren.

1. Einleitung

„Was nutzt eine global gute Konjunktur, wenn jemand in einer Ecke der Republik festgehalten ist, die gerade eine Krise durchläuft?“

Blien et al. (2002, S. 293)

Nicht viel! Dieser „Jemand“ stellt sich nun möglicherweise die Frage, was er oder sie¹ im Rückblick hätte anders machen sollen. Hätte man vor fünf Jahren doch lieber in die Großstadt ziehen sollen, anstatt das Einfamilienhaus auf dem Land zu kaufen? Entscheidungen bezüglich des Wohnortes werden oft vor einem mehrjährigen Planungshorizont getroffen, da Umzüge hohe Kosten verursachen können. Außer den Kosten ist auch das Kappen der sozialen Bindungen ein Faktor, der einen Umzug unattraktiv macht oder diesen sogar ausschließt.

Neben der Entscheidung für den Wohnort wird auch die Berufswahl bzw. Entscheidung für eine bestimmte Ausbildung vor einem mehrjährigen Planungshorizont getroffen. Ob die Entscheidung richtig war, stellt sich erst im Nachhinein heraus. Zum einen muss man eine Stelle bekommen und zum anderen muss man den Job mögen. Wie ein Wechsel des Wohnortes ist auch eine berufliche Neuorientierung mit hohen Kosten verbunden.

Dass es aus persönlicher Sicht wünschenswert wäre, direkt die richtigen Entscheidungen bezüglich Wohnort und Ausbildung zu treffen, ist offensichtlich. Aber auch der Staat hat ein Interesse daran, die Zahl solcher Fehlentscheidungen zu minimieren. Denn was nützt eine Vielzahl arbeitsloser Informatiker in der ländlichen Uckermark, wenn in Walldorf händeringend diese Berufsgruppe gesucht wird?

In Deutschland wird flächendeckend eine Berufsberatung durch die Bundesagentur für Arbeit (BA) angeboten. In persönlichen Beratungsgesprächen werden neben konkreten Fragen zu Ausbildungs- und Studieninhalten auch Strategien

¹Durchweg geschlechtsneutrale Bezeichnungen bzw. die weibliche und männliche Form zu verwenden, führt zu mitunter sehr umständlich zu lesenden Formulierungen. Daher wird zumeist lediglich die männliche Form verwendet, ohne die Absicht, Personengruppen auszuschließen, die sich nicht mit der männlichen Form identifizieren.

1. Einleitung

zur Wahl des passenden Berufs oder Studiums besprochen, vgl. BA (2013a). Bei der letztendlichen Entscheidung für oder gegen einen Beruf spielen aber auch die wirtschaftlichen Aussichten eine Rolle. Um diese Informationen zu liefern, hat die BA Bedarf an Prognosen über die regionalen Beschäftigungsentwicklungen der verschiedenen Berufe. Ebenso erfordert eine aktive Arbeitsmarktpolitik wissenschaftlich fundierte Prognosen, vgl. BA (2007).

Die vorliegende Dissertation ist im Rahmen des vom Institut für Arbeitsmarkt- und Berufsforschung (IAB) finanzierten Forschungsprojekts „Projektion berufsspezifischer Arbeitsnachfrage“ entstanden. Das IAB ist die Forschungseinrichtung der BA. Im Mai 2013 hat das IAB 211 laufende Projekte auf seiner Website aufgelistet und diese thematisch in 17 Forschungsbereiche gegliedert. Dem Bereich „Regionale Arbeitsmärkte“ sind 42 Projekte zugeordnet. Für den Bereich „Berufliche Arbeitsmärkte“ sind hingegen lediglich 5 Projekte aufgelistet, vgl. IAB (2013). Dieses Ungleichgewicht² zu Lasten des beruflichen Fokus kann als Indiz dafür gesehen werden, dass sich die Analyse beruflicher Arbeitsmarktaspekte schwieriger gestaltet als die Analyse regionaler Arbeitsmarktaspekte. Problematisch ist nicht nur die Definition, was ein Beruf ist, sondern auch die praktische Messbarkeit dessen.

Im Rahmen dieser Arbeit sind nicht nur Regionen oder nur Berufe betrachtet worden, sondern alle Kombinationen, die sich daraus ergeben. Das bedeutet, dass Prognosen für sämtliche Berufe in sämtlichen Regionen gemacht werden. Wählt man beispielsweise als regionale Gliederung die 16 Bundesländer und die berufliche Gliederung nach Blossfeld (1985) mit 12 Berufsfeldern, ergeben sich $12 \times 16 = 192$ Berufe-Regionen-Kombinationen. Wie die Beispiele zu Beginn angedeutet haben, kommen in dieser Arbeit sehr viel feinere Gliederungen zum Einsatz. Als regionale Einheiten werden die Zuständigkeitsgebiete der Arbeitsagenturen (Agenturbezirke) gewählt. Die verwendete berufliche Gliederung beruht auf einer Modifikation der Berufsordnungen der Klassifikation der Berufe aus dem Jahr 1988 (KldB 1988). Letztendlich sind somit für ca. 45.000 Berufe-Regionen-Kombinationen Prognosen erstellt worden.

Um Missverständnisse zu vermeiden, werden an dieser Stelle ein paar Wortbedeutungen festgelegt. Der Begriff Prognose bezeichnet laut Duden Fremdwörterbuch die „Vorhersage einer zukünftigen Entwicklung (...) aufgrund kritischer Beur-

²Diese ungleiche Aufteilung spiegelt nicht zwangsläufig die Priorisierung der drei Bereiche am IAB exakt wider, da nicht beurteilt werden kann, wieviele Ressourcen in den jeweiligen Projekten gebunden sind.

teilung des Gegenwärtigen“ (DUDEN, 2001, S. 801). Diese Definition lässt völlig offen, auf welche Art und Weise die Prognose erstellt wird. Im Gabler-Wirtschafts-Lexikon werden als Prognosen nur solche Vorhersagen bezeichnet, die auf objektiven Verfahren beruhen, vgl. Stichwort „Projektion“ in Gabler-Wirtschafts-Lexikon (1997, S. 3115). In Übereinstimmung mit zwei anderen Wirtschaftslexika, vgl. Hansmann (1987, S. 1525) und Standop (2006, S. 4756), wird hier die allgemeinere Definition aus dem Duden verwendet. Im Kontext der Zeitreihenanalyse wird oft der Begriff Informationsmenge verwendet, um auszudrücken, was Gegenstand der „Beurteilung des Gegenwärtigen“ ist. Die Informationsmenge enthält nicht nur Daten, die zum Zeitpunkt der Prognose verfügbar sind, sondern auch eventuell verfügbares Wissen über zukünftige Ereignisse, wie z. B. das Inkrafttreten von Gesetzen. Die Begriffe Projektion und Extrapolation werden verwendet, um explizit herauszustellen, dass objektive quantitative Verfahren zur Berechnung der Vorhersagen verwendet wurden.

Aufgrund der großen Zahl von Prognosen, die erstellt werden, ist es offensichtlich, dass keine Verfahren verwendet werden können, die ein hohes Maß an manueller (subjektiver) Kalibrierung erfordern. Doch auch in Situationen, in denen lediglich quantitative (weitestgehend objektive) Verfahren zur Wahl stehen, bleibt die Entscheidung für ein bestimmtes Verfahren oft eine subjektive Entscheidung. Der Schwerpunkt dieser Dissertation liegt darauf, ein System zu entwickeln, bei dem die Auswahl eines Prognoseverfahrens anhand objektiver Maßstäbe erfolgt. Zentrales Kriterium ist dabei die Genauigkeit der resultierenden Prognosen.

2. Problemstellung

Als Erstes wird in Abschnitt 2.1 die Zielgröße der Prognoseaufgabe beschrieben und die verwendete Notation eingeführt. In den beiden daran anschließenden Abschnitten werden zentrale Aspekte genannt, die bei der Festlegung des beruflichen und regionalen Gliederungsschemas sowie der Auswahl möglicher Prognosemethoden berücksichtigt werden.

2.1. Prognoseaufgabe

Die vorliegende Arbeit ist im Rahmen eines Forschungsprojekts¹, finanziert durch das IAB, unter Leitung von Prof. Harry Haupt, entstanden. Im Rahmen dieses Projekts sind Informationen zu sämtlichen sozialversicherungspflichtigen Beschäftigungsverhältnissen in der Bundesrepublik für die Jahre 1984 bis 2010 vom IAB zur Verfügung gestellt worden. Betrachtet werden nur die Beschäftigungsverhältnisse, die zum Stichtag 30. Juni jeden Jahres bestehen. Für mehrfach sozialversicherungspflichtig Beschäftigte wird nur die Hauptbeschäftigung (höherer Lohn) verwendet. Die Prognosen beziehen sich also auf die Anzahl der Arbeitskräfte mit mindestens einer sozialversicherungspflichtigen Beschäftigung und nicht auf die Anzahl der Beschäftigungsverhältnisse². Im Folgenden wird nur der Begriff *Beschäftigte* verwendet, womit aber immer sozialversicherungspflichtig Beschäftigte gemeint sind.

Das Ziel ist es, Punkt- und Intervallprognosen für die Beschäftigtenzahlen der Berufe-Regionen-Kombinationen zu erstellen. Die Beschäftigtenzahl für einen Beruf b in Region r zum Zeitpunkt t wird durch

$$y_{brt} \quad \text{mit } b = 1, 2, \dots, B \quad r = 1, 2, \dots, R \quad t = 1, 2, \dots, T$$

¹Die Projektbezeichnung lautet „Projektion berufsspezifischer Arbeitsnachfrage“.

²Die Gruppen der Selbstständigen und Beamten werden nicht berücksichtigt und es werden keine Prognosen für diese erstellt.

2. Problemstellung

oder, falls die explizite Angabe des Berufes und der Region nicht relevant ist,

$$y_{it} \quad \text{mit } i = 1, 2, \dots, N \quad N = B \cdot R \quad t = 1, 2, \dots, T$$

notiert. Je nach verwendeter Berufsklassifikation und regionaler Gliederung ergibt sich eine unterschiedliche Anzahl an Berufe-Regionen-Kombinationen N (siehe Abschnitt 3.4). Auf der letztendlich gewählten Aggregationsebene werden 259 Berufsgruppen (siehe Kapitel 5) und 176 Agenturbezirke (die Berliner Bezirke werden zusammengefasst) unterschieden. Somit resultieren 45.584 Berufe-Regionen-Kombinationen. Für die Berufsberatung und die Gestaltung von arbeitsmarktpolitischen Maßnahmen ist die Trennung nach Beschäftigten in *Vollzeit* und *Teilzeit* wichtig. Daraus ergibt sich die Notwendigkeit $2 \times 45.584 = 91.168$ Prognosen zu erstellen. Der Prognosehorizont p beträgt zwischen 1 und 5 Jahren.

2.2. Berufliche und regionale Gliederung

Regionen Grundvoraussetzung für eine Analyse von lokalen Arbeitsmärkten ist deren Abgrenzung. Aus praktischen Gründen kamen nur die Agenturbezirke oder Kreise und kreisfreien Städte als regionale Gliederung in Frage. Die vom IAB zur Verfügung gestellten Daten eignen sich für beide Gliederungen gleichermaßen. Eine detaillierte Beschreibung der Daten wird in Kapitel 3 gegeben. Vor dem Hintergrund einer möglichen Nutzung des hier entwickelten Prognosesystems durch die BA oder das IAB werden als regionale Gliederungseinheiten die Agenturbezirke verwendet. Diese Entscheidung ist in Abstimmung mit dem am IAB zuständigen Projektbetreuer getroffen worden.

Die Verwendung der Agenturbezirke bietet verschiedene Vorteile. So ist es in der regionalen Arbeitsmarktforschung (für Deutschland) gängige Praxis, die Agenturbezirke als regionale Gliederung zu verwenden. Damit ist es möglich, die Prognosen des hier entwickelten Prognosesystems mit denen anderer Arbeiten zu vergleichen. Ein weiterer Vorteil ergibt sich aus der relativen Größe der 176 Agenturbezirke. Zwischen den 412 Kreisen und kreisfreien Städten kommt es mitunter zu starken Pendlerströmen, welche einen Hinweis darauf geben, dass sich die lokalen Arbeitsmärkte über die Grenzen der Kreise erstrecken. Für die Agenturbezirke tritt dieses Phänomen nicht so stark zutage. Ausschlaggebend sind jedoch die möglichen Nutzer des hier entwickelten Prognosesystems, die Entscheidungsträger und Be-

rufsberater in den Agenturen für Arbeit. Für diese sind die lokalen Entwicklungen in ihrem Zuständigkeitsgebiet, den Agenturbezirken, relevant. Aus diesem Grund wurde auch eine Aggregation der Kreise und kreisfreien Städte von vornherein ausgeschlossen.

Berufe Wie bei der Abgrenzung der Regionen wird aus praktischen Gründen bei der beruflichen Gliederung auf die in den Sozialversicherungsdaten verwendete Berufsklassifikation, die KldB 1988, zurückgegriffen. Aus verschiedenen Gründen wird diese jedoch modifiziert. Die Definition der Berufe nach der KldB 1988 folgt keinem einheitlichen Muster. Als Unterscheidungsmerkmal kann z. B. entweder das vorwiegend bearbeitete Material, oder auch die hierarchische Position im Unternehmen dienen. Ein weiteres Problem liegt darin, dass die verwendete Klassifikation die aktuelle Berufslandschaft nicht mehr hinreichend gut abbildet, vgl. Statistik der Bundesagentur für Arbeit (2010), Thema: „Einführung einer neuen Klassifikation der Berufe“. Für neu entstandene Berufe existieren keine Codes und so werden wahrscheinlich viele Beschäftigte in der IT-Branche trotz sehr unterschiedlicher Aufgaben und Qualifikationen mit dem Code (774) „Datenverarbeitungsfachleute“ gemeldet. Auch der Code (781) „Bürofachkräfte“ bildet ein Sammelbecken für Beschäftigte mit stark unterschiedlichen Qualifikationsanforderungen.

Aus den eben genannten Gründen ist die KldB 1988 im Hinblick auf die Verwendung der Prognosen nicht geeignet. In Kapitel 5 wird daher eine Modifikation der KldB 1988 vorgestellt.

Berufe-Regionen-Kombinationen Bei gleichzeitiger Betrachtung von Berufen und Regionen könnte eine berufsspezifische Abgrenzung der lokalen Arbeitsmärkte Sinn ergeben. Um ein Beispiel aus Schwartz (1973, S. 1160) aufzugreifen: Der Arbeitsmarkt für Tellerwäscher ist geografisch klein, der für Astrophysiker global. Ein solches Vorhaben ist im Rahmen dieser Dissertation aus zeitlichen Gründen weder möglich noch aus Sicht der potentiellen Nutzer (BA und IAB) der Prognosen gewünscht.

2.3. Identifikation geeigneter Methoden/Modelle

Die Suche nach der besten Prognosemethode ist erst möglich, wenn festgelegt ist, was mit *beste* Methode gemeint ist. In diesem Abschnitt werden theoretische und praktische Aspekte angesprochen, anhand derer diese Festlegung geschieht.

Prognostizierbarkeit und Konsequenz der Prognosefehler Die grundlegende Annahme ist, dass der zukünftige Wert y_{iT+p} , $p \geq 1$, nicht mit Sicherheit exakt vorhersagbar ist. Als Prognosefehler wird die Differenz zwischen der vorhergesagten und tatsächlichen Beschäftigtenzahl bezeichnet:

$$e_{iT+p|T} = y_{iT+p} - \hat{y}_{iT+p|T}$$

Der Wert $\hat{y}_{iT+p|T}$ stellt dabei die Prognose dar, die mit der zum Zeitpunkt T verfügbaren Informationsmenge (oder einer Teilmenge davon) erstellt wurde. Die übliche Vorstellung ist, dass Prognosen Entscheidungen beeinflussen. Wird beispielsweise ein starker Anstieg der Beschäftigtenzahl für die Berufe-Regionen-Kombination i vorhergesagt, könnte es sein, dass in dieser Region die Berufsberater der BA die Empfehlung ausgeben, eine Ausbildung in diesem Beruf aufzunehmen. Stellt sich heraus, dass die Prognosen zu hoch gegriffen waren, existiert jetzt möglicherweise ein Überangebot an Arbeitskräften. Der Prognosefehler hat dazu geführt, dass einige Personen keine Anstellung gefunden haben und Arbeitslosengeld beziehen müssen. Der Prognosefehler hat somit Kosten für die Arbeitslosenversicherung verursacht. Es ist ein Verlust entstanden. Angenommen, die Prognose einer Methode A führt zu einem geringeren Verlust als die Prognose einer Methode B, so wird im Sinne der Verlustminimierung die Methode A als besser bezeichnet. Voraussetzung eines solchen Vergleichs ist die Zuordnung von Prognosefehler und Verlust. In Abschnitt 7.2 wird dies weiter diskutiert.

Informationsmenge Ist zum Beispiel bekannt, dass die Subventionen für einen bestimmten Industriezweig gestrichen werden, kann diese Information für die Prognose genutzt werden. Dies ist eine ganz spezifische Information über relevante Entwicklungen in einer Region oder einem Berufsfeld. Solche Informationen werden auch als Expertenwissen bezeichnet. Es kann genutzt werden, um die Prognosen eines statistisch-mathematischen Modells zu modifizieren. Beispielsweise können die Modellparameter auf bestimmte Werte festgelegt werden oder die ur-

sprüngliche Prognose wird direkt nach oben oder nach unten abgeändert. Da abhängig vom gewählten Aggregationsniveau sehr viele Prognosen erstellt werden müssen, können keine Methoden angewandt werden, welche ein hohes Maß an menschlichen Eingriffen bei ihrer Erstellung verlangen. Im Hinblick auf die Akzeptanz und Verwendung einer Prognosemethode bzw. der resultierenden Prognosen, kann jedoch nicht außer Acht gelassen werden, dass die potentiellen Nutzer der Prognosen Expertenwissen besitzen. Daher wird in Kapitel 6 u. a. eine Methode vorgestellt, welche ein nachträgliches Einbinden von Expertenwissen ermöglicht.

Anstelle von Expertenwissen könnten auch sogenannte Früh- oder Leitindikatoren zur Prognose herangezogen werden. Ein möglicher Indikator ist z. B. die Anzahl der Beschäftigten in Zeitarbeit, siehe BA (2013b). Aufgrund des hohen Aufwands, Indikatoren auf Ebene der Berufe-Regionen-Kombinationen zusammenzutragen, können im Rahmen dieser Arbeit solche Methoden nicht berücksichtigt werden.

Erklärungsgehalt versus Prognosegüte Eine andere Art der Information bezieht sich auf den Zusammenhang von verschiedenen Variablen. Aus theoretischen Überlegungen zu kausalen Zusammenhängen können Strukturgleichungsmodelle aufgestellt werden. Solche Modelle versuchen die betrachteten Vorgänge möglichst gut zu erklären. Typisch sind hierbei Gleichungssysteme von Angebot und Nachfrage. Die Arbeitskräftenachfrage hängt unter anderem vom Preis für Arbeit, also dem Lohn, ab. Der Lohn beeinflusst neben der Nachfrage auch das Angebot an Arbeitskräften. Der Lohn wiederum wird im Zusammenspiel von Nachfrage und Angebot gebildet. Die einzelnen Strukturgleichungen bilden ein Gleichungssystem, welches versucht, die komplexen Beziehungen zwischen den Variablen abzubilden. Zur Schätzung solcher Modelle werden Daten zu sehr vielen Variablen benötigt. Ein Modell, welches die Vergangenheit bzw. die beobachteten Daten gut beschreibt, liefert aber nicht zwangsläufig auch sehr gute Prognosen. Es besteht die Gefahr der sogenannten Überanpassung.

Die in dieser Arbeit zur Verfügung stehenden Daten sind in Kapitel 3 beschrieben. Es handelt sich um anonymisierte Individualdaten aus den Sozialversicherungsmeldungen. Mit diesen werden verschiedene Zeitreihen zu den Berufe-Regionen-Kombinationen gebildet. Zusätzlich lassen sich einige Kennzahlen wie z. B. der Anteil der weiblichen Beschäftigten für die einzelnen Berufe-Regionen-Kombinationen generieren. Die Daten reichen zwar nicht aus, um Strukturgleichungssysteme zu schätzen, jedoch können parametrische Paneldatenmodelle ge-

2. Problemstellung

schätzt und zur Prognose verwendet werden.

Kenntnis der Datengrundlage Eine genaue Kenntnis der Datengrundlage ist hilfreich dabei, einige Modelle a priori auszuschließen bzw. sich etwaiger Beschränkungen in der Anwendung bewusst zu sein. Alle Modelle sind nur Approximationen einer viel komplexeren Wirklichkeit. Verschiedene Modellierungen können unterschiedliche Annahmen über die Wirklichkeit verlangen. Zum Beispiel wird bei Verwendung der einfachen exponentiellen Glättung unterstellt, dass die Zeitreihe keinem globalen Trend folgt, sondern nur leichten Niveauänderungen im Zeitablauf unterliegt. Ein theoretischer Vergleich ist in solchen Fällen nur über die Argumentation für oder gegen die Plausibilität der jeweiligen Annahmen möglich. Eine solche Argumentation wird um so belastbarer, je genauer die Kenntnis der Realität ist. Eine solche Kenntnis kann man wiederum nur über Analysen der Datengrundlage gewinnen. Auf diesen Punkt wird in Kapitel 4 eingegangen.

Aus Konsistenzgründen müssten Beschäftigtenzahlen mit einem Zählmodellen prognostiziert werden. Rein intuitiv lässt sich leicht argumentieren, dass es bei der Prognose sehr großer Zahlen unerheblich ist, ob die Wertemenge der Prognosefunktion auf die natürlichen Zahlen beschränkt ist oder auch die reellen Zahlen umfasst. In Abschnitt 4.3 wird untersucht, ob und in welchem Ausmaß Berufs-Regionen-Kombinationen mit Beschäftigtenzahlen im einstelligen und niedrigen zweistelligen Bereich existieren.

Methoden In Kapitel 6 werden die zum Vergleich ausgewählten Methoden und Modelle vorgestellt. Bei der Auswahl der Methoden sind die eben aufgeführten Punkte mit eingeflossen. Da der Fokus dieser Arbeit auf Prognose und nicht auf Erklärung liegt, ist die Prognosegüte das zentrale Kriterium bei der Entscheidung für die letztendlich verwendete Methode. Um die Prognosegüte abzuschätzen, werden artifizielle *Out-of-Sample*-Prognosen mit allen Methoden erstellt und untereinander verglichen. Eine artifizielle *Out-of-Sample*-Prognose ist dadurch charakterisiert, dass die Informationsmenge künstlich reduziert wird. Die zur Verfügung stehenden Daten werden in einen Schätz- und einen Validierungsdatensatz aufgeteilt. Lediglich der Schätzdatensatz wird zur Berechnung der Prognose verwendet. Die resultierenden Prognosen werden dann mit dem Validierungsdatensatz verglichen. Die Konzeption der empirischen Vergleiche ist in Kapitel 7 beschrieben. Die Resultate werden in Kapitel 8 erörtert.

Technische Anmerkungen: „[P]roducing a bright, shiny result from the raw beginnings of a research project involves a lot of work that is almost never seen or acknowledged. [...] Just getting the data ready for analysis often represents a significant component of a research project.“, Murrell (2009, S. xix). In einem großen Teil der Fachliteratur zur empirischen Wirtschaftsforschung wird das Hauptaugenmerk trotzdem auf die Resultate und nicht auf die Dokumentation der Analyse gelegt. Bei dem Versuch, die Resultate von Reinhart und Rogoff (2010) zu replizieren, stieß der Doktorand Thomas Herndon auf einen Fehler, der Reinhart und Rogoff bei der Datenanalyse unterlaufen war. Mediales Aufsehen³ erregte der Fall, da die Korrektur der Fehler die Schlussfolgerungen von Reinhart und Rogoff (2010) bezüglich des negativen Zusammenhangs von Staatsverschuldung und Wirtschaftswachstum in Frage stellte, siehe Herndon et al. (2013).

Bei der Wahl der Software zur Datenanalyse ist Grundvoraussetzung, dass sie die Möglichkeit bietet, die gesamte Analyse nachvollziehbar zu machen. Es wurden die Programme Stata und R verwendet. Für die einzelnen Schritte der Datenaufbereitung, der explorativen Datenanalyse, der Parameterschätzungen und der Berechnung der Prognosen stehen fertige Funktionen zur Verfügung. Aufgrund der Datenmenge und dem daraus resultierenden großen Speicherbedarf können manche dieser Standardfunktionen nicht genutzt werden. In diesen Fällen ist es nötig, die zu erledigende Aufgabe in mehrere kleinere Schritte zu zerlegen. Ähnliches gilt für die Evaluierung der verschiedenen Prognosemethoden.

Wie bei den Zwischenberichten, die an das IAB gesendet wurden, wird in dieser Dissertation der Versuch unternommen, die Analysen möglichst transparent darzustellen. Bei vielen Abbildungen und Tabellen wird auf das Stata- oder R-Skript verwiesen, mit dem diese entstanden sind bzw. mit denen die relevanten Daten erzeugt wurden. Sämtliche Stata- und R-Skripte sind auf der beigelegten CD-ROM zu finden. Trotz der transparenten Darstellung der Analysen sind diese nicht replizierbar, da die verwendeten Daten aus Datenschutzgründen nicht veröffentlicht werden dürfen.

Der Großteil der hier präsentierten Resultate beruht auf Analysen der Daten für die Jahre bis 2008, da die Daten der Jahre 2009 und 2010 erst gegen Ende des Forschungsprojekts nachgeliefert wurden. Vor Erstellung der finalen Prognosen sind die wichtigsten Analysen unter Berücksichtigung aller Daten (bis einschließ-

³Hier ein Linksammlung von Reaktionen auf den Fall:

<http://backtofullemployment.org/2013/04/16/the-reinhart-rogoff-reassessment/>

2. Problemstellung

lich 2010), wiederholt worden. Da sich die Resultate nur marginal unterscheiden, wurden nicht sämtliche Tabellen und Grafiken neu erstellt bzw. aktualisiert.

3. Datengrundlage

Im Rahmen des IAB-Forschungsprojekts „Projektion berufsspezifischer Arbeitsnachfrage“ sind Auszüge aus der Beschäftigten-Historik (BeH) zur Verfügung gestellt worden. Die BeH ist eine Datenbank, welche am IAB erstellt und gepflegt wird. Sie enthält Informationen zu sämtlichen sozialversicherungspflichtigen Beschäftigungsverhältnissen in der Bundesrepublik seit dem Jahr 1975. Die uns vorliegenden Auszüge beziehen sich auf die Jahre 1984 bis 2010 und enthalten Angaben zu den Personen, die am Stichtag 30. Juni eines Jahres sozialversicherungspflichtig beschäftigt waren. Bei Mehrfachbeschäftigten ist nur die Meldung mit dem höheren Tagesentgelt enthalten. Folgende Merkmale wurden aus der BeH extrahiert (in den eckigen Klammern steht der Variablenname, wie er im Datensatz verwendet wird, Zahlen in runden Klammern bezeichnen Codierungen/Ausprägungen):

Tabelle 3.1.: Datengrundlage: Variablenliste

Geschlecht:	männlich (1); weiblich (2)
[sex]	Missing enthalten? NEIN
Beruf:	Ebene der Berufsordnungen (3-Steller)
[beruford]	344 Ausprägungen, wovon einige jedoch keine Berufe bezeichnen. Im Folgenden werden diese Pseudo-Berufs-Codes mit „Nicht-Berufe“ bezeichnet. Die Nicht-Berufe sind in Tabelle A.6 auf Seite 148 aufgelistet.
	Missing enthalten? JA – Codierung nicht einheitlich ¹

¹Folgende Missings-Codes treten auf: (-99), (0) und (999).

3. Datengrundlage

- Arbeitsort: Ebene der Arbeitsamtgeschäftsstellen (5-Steller)
[aogst] Etwa 590 Geschäftsstellen vor der Wiedervereinigung, danach ca. 780.
Die ersten 3 Stellen von [aogst] geben das Arbeitsamt an.
Etwa 140 Ämter vor der Wiedervereinigung, danach ca. 180.
Missing enthalten? JA – Code (-9999)
- [aokreis] Angabe des Kreises bzw. der kreisfreien Stadt (5-Steller)
328 Kreise bis zum Jahr 1989, zwischen 1990 und 1992 kommen die Ost-Kreise hinzu (414 Kreise – Berlin getrennt), ab dem Jahr 1999 sind es 413 Kreise (Berlin zusammengelegt)
Missing enthalten? JA – Code (-9999)
- Alter: 10 Alterskategorien (5-Jahres-Intervalle)
[agecat] Bis 20 (20), 21–25 (25), ..., 61 oder älter (65)
Missing enthalten? NEIN
- Arbeitszeit: Numerischer Schlüssel (1-Steller)
[berufstg] Vollzeit: (0), (1), (2), (3), (4), (7)
Große Teilzeit (mindestens 18 Std./Woche): (9)
Kleine Teilzeit (weniger als 18 Std./Woche): (8)
Diese Variable gibt auch die Stellung im Beruf an.²
Missing enthalten? JA – Code (.)
- Tageslohn: Bis 1998 in DM, ab 1999 in EUR
[tagentg] Zensiert an der Beitragsbemessungsgrenze. Der Wert 0 bedeutet nicht Missing, sondern ist eine legitime Angabe.
Missing enthalten? In unserem Auszug NEIN, in der BeH JA
- Branche: Branchenschlüssel (3-Steller)
[wz73] Enthalten in den Jahren 1984 bis 1999
[wz73]&[wz93] Enthalten im Jahr 2000
[wz93] Enthalten in den Jahren 2001 und 2002

²Azubi (0), nicht Facharbeiter (1), Facharbeiter (2), Meister/Techniker (3), Angestellter (4), Heimarbeiter/Hausgewerbetreibender (7), Kleine Teilzeit (8), Große Teilzeit (9)

- [wz93]&[wz03] Enthalten im Jahr 2003
 [wz03] Enthalten in den Jahren 2004 und 2008
 Missing enthalten? JA – Code (-99) und wahrscheinlich (0)³
- Betriebsgröße: Anzahl der Mitarbeiter (6 Kategorien)
 [escat] 1–10 (1), 11–20 (2), 21–50 (3), 51–100 (4), 101–500 (5),
 >500 (6)
 Missing enthalten? NEIN
- Wohnort: Kreise und kreisfreie Städte
 [wokreis] Die Wohnorte sind erst ab dem Jahr 1999 enthalten (413
 Kreise). Die Variable ist aber jedes Jahr enthalten (alle Ein-
 träge Missing vor dem Jahr 1999).
 Missing enthalten? JA – Code (-9999)
- Ausbildung: Höchster Bildungsstand (3 Kategorien)
 [edimp] Keine Ausbildung (1), abgeschlossene Berufsausbildung (2),
 Fachhochschule oder Hochschule (3)
 Missing enthalten? JA – Code (.)
 [limp] Index, der angibt, ob der Wert von [edimp] imputiert wurde.
 imputiert (1); original (0)

Da wir Prognosen der Beschäftigtenzahlen für Regionen und Berufe erstellen, werden als erstes die uns interessierenden Variablen zur Berufs- und Arbeitsortangabe näher beschrieben. Dabei beziehen sich die Analysen auf die vom IAB übermittelten Daten.

3.1. Berufe

Die Berufsangabe bei der Meldung zur Sozialversicherung geschieht anhand der Klassifizierung der Berufe in der Version des Jahres 1988 (KldB 1988) auf Ebene der Berufsordnungen. Die KldB 1988 beruht auf der vom Statistischen Bundesamt und der BA entwickelten Klassifizierung der Berufe aus dem Jahr 1970, vgl. BA

³In den Jahren 1999 und 2000 taucht bei der Variable [wz73] der Code (0) auf. Da aber in den beiden Jahren keine Meldungen mit dem Missing-Code (-99) enthalten sind und die (0) nicht in den anderen Jahren auftaucht, ist die (0) wahrscheinlich ein Missing-Code.

3. Datengrundlage

(2011a). Die Angabe der Berufsordnung besteht aus einem dreistelligen numerischen Code. Daher bezeichnet man diese Berufe auch als „3-Steller“, wenn von den Berufsordnungen gesprochen wird.⁴ Die ersten beiden Zahlen des 3-Steller-Codes geben die sogenannten Berufsgruppen an. Hier spricht man dann von den 2-Stellern.⁵

In Tabelle A.1 auf Seite 145 ist aufgelistet, wieviele verschiedene Codes in den einzelnen Jahren verwendet werden. Die Anzahl der verwendeten 3-Steller-Codes in den BeH-Auszügen schwankt zwischen 339 und 344, siehe Spalte „3-Steller/BeH Auszüge“. Da die Codierung fehlender Werte in den BeH-Auszügen nicht einheitlich ist, werden diese im Weiteren alle auf Null (0) gesetzt. Nun schwankt die Anzahl der verwendeten 3-Steller-Codes zwischen 339 und 343, siehe Spalte „3-Steller/einheitlicher Missing-Code“. Die Spalte „3-Steller/neue & veraltete Codes“ zeigt an, welche Codes hinzugekommen sind oder nicht mehr verwendet werden.⁶

Insgesamt sind 338 Berufs-Codes durchgängig in allen Jahren vorhanden. Diese umfassen aber auch Codes, welche wir als „Nicht-Berufe“ bezeichnen (z. B. Behinderte). Die Klassifikation Altersteilzeit (996) tritt nur in den Jahren von 1989 bis 1999 auf.⁷ In den Jahren 1989, 1995 und 1996 ist je ein neuer Beruf aufgetreten: Ausgleichsbezieher (997), Pflegepersonen (888) und dann Haushaltshilfen (924). Im Jahr 1991 tauchen ca. 4000 Meldungen mit dem Berufs-Code (677) auf. Dieser kann keinem Beruf zugeordnet werden und wird daher im Weiteren auf Missing umcodiert. Die Entscheidung, wie mit den Meldungen zu den Nicht-Berufen umgegangen wird, hängt auch von der Anzahl der entsprechenden Meldungen ab, siehe dazu Abschnitt 4.1.

3.2. Regionen

Für die Arbeitsortangabe werden zwei verschiedene Gebietsstrukturen verwendet. Zum einen die politische Gebietsstruktur auf Ebene der Kreise und kreisfreien Städte und zum anderen die Gebietsstruktur der Bundesagentur für Arbeit auf Ebene der Geschäftsstellen der Arbeitsagenturen.

⁴In den Dateinamen der .do-Dateien wird die Abkürzung `b3` verwendet, um anzuzeigen, dass die Berufe auf Ebene der 3-Steller verwendet werden.

⁵Dementsprechend wird in den .do-Dateien die Abkürzung `b2` verwendet.

⁶Auszählung mit `anzahl-beruford.do` durchgeführt.

⁷Ab dem Jahr 2000 werden diese Meldungen über die Variable `Personengruppe` identifiziert.

Aus der Angabe auf Kreisebene (numerischer 5-Steller) lässt sich anhand der ersten beiden Stellen das Bundesland und aus der dritten Stelle der Regierungsbezirk ablesen. Der 5-stellige Code der Agenturgeschäftsstellen gibt mit den ersten drei Stellen die Arbeitsagentur an. Die ca. 170 Arbeitsagenturen lassen sich 10 Regionaldirektionen zuordnen. Die Regionaldirektionen orientieren sich weitestgehend an den Bundesländern, siehe Abbildung A.5 auf Seite 174. Die Zuordnung lässt sich jedoch nicht anhand des Codes ablesen. Eine Liste mit der Zuordnung von Arbeitsagenturen und den zuständigen Regionaldirektionen findet sich auf der Internetseite der BA, siehe BA (2011b).

In Tabelle A.3 auf Seite 146 ist aufgelistet, wieviele verschiedene Codes in den einzelnen Jahren verwendet werden.⁸ Auf Kreisebene schwankt die Zahl zwischen 329 und 415. In den Jahren von 1990 bis 1992 kommen die Kreise aus den neuen Bundesländern hinzu. Ab dem Jahr 1999 existieren keine Meldungen mehr für den Kreis Berlin-West. Auf Ebene der Agenturen schwankt die Zahl zwischen 146 und 180.⁹ Auch bei den Arbeitsagenturen kam es lediglich in Berlin zu Umstrukturierungen und der Vergabe neuer Codes. Daher werden im Weiteren die Berliner Kreise und Arbeitsagenturen zusammengelegt. Dies wird auch in anderen am IAB durchgeführten Arbeiten zu regionalen Arbeitsmärkten gemacht, vgl. beispielsweise Blien et al. (2010), Blien und Hirschenauer (2005) oder Schanne et al. (2008).

3.3. Erstellung der Zeitreihen

Um Beschäftigtenprognosen differenziert nach Berufen und Regionen zu erstellen, werden Zeitreihen der Beschäftigtenzahlen zu diesen Kombinationen benötigt. In einem ersten Schritt erstellt man für jedes Jahr Häufigkeitsmatrizen, welche diese Beschäftigtenzahlen enthalten. Anstatt lediglich die Beschäftigtenzahlen zu notieren, wird zwischen Männern und Frauen, den Alterskategorien und der wöchentlichen Arbeitszeit unterschieden. Die resultierenden Häufigkeitsmatrizen bestehen aus 88 Spalten und sind als Stata-Daten-Dateien gespeichert. Mit diesen Häufigkeitsmatrizen werden die Zeitreihen erzeugt.

Häufigkeitsmatrizen Die Stata-Daten-Dateien enthalten 91 Variablen. Die ersten drei enthalten das Jahr, die Berufs- und die Arbeitsortangabe. Die restlichen

⁸Auszählung mit `anzahl-kreise.do` durchgeführt.

⁹Auszählung mit `anzahl-aoaa.do` durchgeführt.

3. Datengrundlage

88 Variablen enthalten die Beschäftigtenzahlen der Häufigkeitsmatrix. In Tabelle A.4 auf Seite 147 ist die resultierende Datenstruktur skizziert. Die Berufe sind dabei auf Ebene der Berufsordnungen und die Regionen auf Ebene der Arbeitsagenturen gewählt worden. Für andere Aggregationsniveaus ergeben sich dementsprechend mehr oder weniger Berufe-Regionen-Kombinationen. Die Angabe des Berufs und der Region geschieht anhand der numerischen Codes aus der BeH, wobei der Missing-Code einheitlich auf Null gesetzt wird.

Für jede mögliche Berufe-Regionen-Kombination existiert eine Zeile in der Häufigkeitsmatrix, auch dann, wenn gar keine Meldungen mit dieser Kombination vorhanden sind. Die Zeilen sind so sortiert, dass zuerst der kleinste Berufs-Code mit allen Regionen kombiniert wird. Danach wird der zweitkleinste Berufs-Code mit allen Regionen kombiniert, dies setzt sich fort, bis sämtliche Kombinationen gebildet wurden. Diese Struktur ist in Tabelle A.4 auf Seite 147 durch die grau unterlegten Blöcke verdeutlicht.

In der ersten Zeile stehen somit die Anzahlen der Beschäftigten, für die im Jahr 1984 weder der Beruf noch der Arbeitsort gemeldet wurden. Die zweite Zeile enthält die Anzahlen der Beschäftigten in der Region AA 1, für die keine Berufsangabe vorliegt. Technische Anmerkung: In den gespeicherten Häufigkeitsmatrizen steht anstelle von „AA 1“ der entsprechende Agentur-Code; gleiches gilt für die Spalte Berufe.

Betrachten wir nun die Spalten der Häufigkeitsmatrix. Die ersten beiden Spalten sind einfach zu interpretieren: Sie enthalten die Anzahl der männlichen und weiblichen Beschäftigten. Da jede Meldung eine Angabe zum Geschlecht enthält, ergeben die beiden Spaltensummen zusammen die Gesamtzahl der Meldungen (also sozialversicherungspflichtig beschäftigte Personen) für das Jahr.

Die nächsten sechs Spalten beziehen sich auf die Arbeitszeit, wobei VZ für Vollzeit, GTZ für Große Teilzeit (18 oder mehr Std. die Woche, aber nicht VZ) und KTZ für Kleine Teilzeit (weniger als 18 Std. die Woche) steht, wieder differenziert nach Geschlecht. Da es bei der Variable zur Arbeitszeit [berufstg] Meldungen ohne Angabe gibt, werden die Spaltensummen zusammen kleiner sein als die Gesamtzahl der Meldungen des Jahres.

Die nächsten 20 Spalten sind nur angedeutet, sie beziehen sich auf die Altersverteilung innerhalb der Berufe-Regionen-Kombinationen. Es werden 10 Alterskategorien unterschieden. Die Angaben sind auch wieder separat für Männer und Frauen erstellt. Da es keine fehlenden Angaben beim Alter gibt, entspricht die

Summe der 20 Spaltensummen der Gesamtzahl an Meldungen des Jahres.

Die 60 weiteren Spalten ergeben sich, indem die Altersverteilung nach Arbeitszeit und Geschlecht differenziert wird, siehe Tabelle A.5 auf Seite 148. Werden diese 60 Spaltensummen addiert, erhält man die gleiche Zahl wie bei der Addition der 6 Spaltensummen zur Arbeitszeit. Anhand der Spaltensummen kann die Korrektheit der Häufigkeitsmatrizen grob getestet werden.

Zeitreihen Für jedes Jahr von 1984 bis 2010 wird eine solche Häufigkeitsmatrix erstellt und gespeichert. Die Zeitreihen der Berufe-Regionen-Kombinationen werden erstellt, indem die einzelnen Häufigkeitsmatrizen zusammengefügt werden. In Tabelle A.7 auf Seite 149 ist die so erstellte Datei beschrieben, d. h., es werden die Variablennamen aufgelistet und einige Kennzahlen des Datensatzes genannt. Es ist zu erkennen, dass die Datei 91 Variablen und ca. 1,4 Millionen Zeilen enthält. Die Größe der Datei ist in etwa 334 Megabyte.

3.4. Anzahl der Berufe-Regionen-Kombinationen

Die Anzahl der Berufe-Regionen-Kombinationen errechnet sich durch

$$\text{Anzahl Berufe} \times \text{Anzahl Regionen.}$$

Je nach Aggregationsniveau schwankt die Anzahl der Berufe-Regionen-Kombinationen sehr stark. In Tabelle A.8 auf Seite 150 sind die Anzahlen der Berufe und Regionen auf den unterschiedlichen Aggregationsniveaus aufgeführt. Anhand der vorliegenden Daten ist die schwächste Disaggregation die Betrachtung der 12 Berufsklassen nach Prof. Blossfeld und dem Arbeitsort auf Ebene der alten und neuen Bundesländer (Ost/West). Die stärkstmögliche Disaggregation ist die Betrachtung der Berufe auf Ebene der Berufsordnungen und dem Arbeitsort auf Kreisebene. Auf diesem Aggregationsniveau müssten für $413 \text{ (Kreise)} \times 341 \text{ (Berufe)} = 140.833$ Berufe-Regionen-Kombinationen Projektionen erstellt werden. Rein technisch ist dies zwar machbar, würde aber einen unvermeidbaren Aufwand bei der Pflege der Projektionen erfordern, da diese nicht sinnvoll automatisierbar sind. Für die Zwecke der folgenden Exploration werden angesichts dieser Größenordnungen nur Methoden in Betracht gezogen, welche zum größten Teil automatisiert arbeiten. Dies betrifft vor allem Spezifikationssuche und -test.

3. Datengrundlage

Anzumerken bleibt, dass die letztendlich verwendete Aggregationsebene der Berufe nicht in der Tabelle A.8 aufgeführt ist, da diese speziell im Rahmen des IAB-Forschungsprojekts entwickelt wurde. Das resultierende Aggregationsniveau liegt zwischen den 3-Stellern und den 2-Stellern, demzufolge werden 260 Berufe unterschieden.

Berufsordnungen – Arbeitsagenturen In Tabelle A.9 auf Seite 151 ist aufgelistet, wieviele Berufe und Arbeitsagenturen es in den Jahren von 1984 bis 2008 gab und daraus konkludiert, wieviele verschiedene Berufe-Regionen-Kombinationen es auf dieser Aggregationsebene gibt. Zu beachten ist, dass bei der Anzahl der Berufe und Arbeitsagenturen die tatsächliche Anzahl und die Kategorie „Ohne Angabe“ zusammengezählt werden.

Dabei wurden die Arbeitsagenturen nicht nur gezählt, sondern auch überprüft, ob einige Ämter geschlossen wurden. Dies war nur in Berlin der Fall. Dort kam es immer wieder zu Neuabgrenzungen der Agenturbezirke und Umbenennungen. Daher werden die Berliner Arbeitsamt-Codes durch den selbst gewählten einheitlichen Code (970) ersetzt.

3.5. Generierung von erklärenden Variablen

Zur Erklärung der Beschäftigtenzahlen lassen sich, ähnlich wie in Modellen zur Erklärung der Arbeitslosigkeit, im Prinzip nahezu beliebig viele Kovariablen finden und mitunter auch auf regional disaggregierter Ebene approximieren. Ein Problem dabei ist, dass diese Kovariablen als Voraussetzung für eine Prognose zunächst selbst – für alle interessierenden Berufe-Regionen-Kombinationen – prognostiziert werden müssen. Bevor ein großer Aufwand betrieben wird, um möglichst viele Prädiktoren zusammenzutragen, werden folgende 5 Kovariablen aus den BeH-Auszügen generiert:

- Verteilung der Beschäftigten nach Geschlecht:
`fem.share` Anteil der weiblichen Beschäftigten
- Verteilung der Beschäftigten nach Altersklassen:
`young.num` Anzahl der Beschäftigten mit einem Alter bis zu 25 Jahren
`old.num` Anzahl der Beschäftigten, die älter als 55 Jahre sind

3.5. Generierung von erklärenden Variablen

- Verteilung der Unternehmen nach Größenklassen:
`smaco.share` Anteil der Beschäftigten, die in Unternehmen mit höchstens 10 Arbeitnehmern arbeiten
- Tageslohn (rechtszensiert an der Beitragsbemessungsgrenze) der Beschäftigten:
`dwage.med` Median des Tageslohns

Die Variablen `fem.share`, `young.num` und `old.num` lassen sich mit sehr geringem Rechenaufwand auf Basis der erstellten Häufigkeitsmatrizen für jede Berufs-Regionen-Kombination berechnen. Die Variablen `smaco.share` und `dwage.med` müssen auf Basis der BeH-Auszüge berechnet werden.

4. Explorative Datenanalyse

Zu Beginn des IAB-Forschungsprojekts war noch nicht entschieden, für welche Aggregationsebene die Prognosen erstellt werden sollten. Als regionale Gliederung standen von Anfang an die Agenturbezirke fest. Als berufliche Gliederung wurden zu Beginn die 3-Steller der KldB 1988 genutzt. Die Neugruppierung der 3-Steller erfolgte erst gegen Ende des Projektes und daher sind einige der explorativen Analysen auf Ebene der 3-Steller durchgeführt worden.

4.1. Anteile der Nicht-Berufe

Bei der Meldung von Beschäftigten, die keinem Beruf zuzuordnen sind, stehen einige Kategorien zur Verfügung, die wir hier als Nicht-Berufe bezeichnen. Diese umfassen z. B. Behinderte oder mithelfende Familienangehörige. Eine Liste dieser Nicht-Berufe ist in Tabelle A.6 auf Seite 148 zu finden. Die Nicht-Berufe sind zwar nicht direkt von Interesse, z. B. für die Berufsberatung, jedoch ist ein Löschen dieser Meldung nicht unproblematisch. Je nachdem, wieviele Meldungen vorhanden sind, würde ein Löschen dieser Meldungen die Gesamtzahl der Beschäftigten innerhalb einzelner Regionen oder in Deutschland insgesamt stark verringern. Die resultierenden Prognosen könnten sich also substantziell von Prognosen aus anderen Quellen unterscheiden. Um diesen Effekt abzuschätzen, werden im Folgenden die Zeitreihen der Nicht-Berufe untersucht.

In den Abbildungen A.6, A.7 und A.8 auf den Seiten 175 und 176 sind die prozentualen Anteile der Meldungen zu den verschiedenen Nicht-Berufen abgetragen. Die Anteile bewegen sich zwischen 0 und 0,6 Prozent. Für das Jahr 2008 machen sie zusammen ca. 1,4 Prozent der Gesamtbeschäftigung aus. Im Jahr 2010 sind es ca. 1,5 Prozent. Aufgrund dieser Größenordnung werden sie nicht einfach gelöscht, sondern im Folgenden weiter analysiert.

Die Zeitreihen der zehn Nicht-Berufe lassen kein einheitliches Muster erkennen. Einige Zeitreihen enthalten eindeutig Ausreißer, z. B. die Jahre 1987 und

4. Explorative Datenanalyse

1998 bei Behinderten (555) und Rehabilitanden (666), bei anderen sind deutliche Strukturbrüche im Jahr 1991 zu erkennen, z. B. Niveauanhebung bei Azubis ohne Berufsangabe (981) und mithelfenden Familienangehörigen (971). Einen stetig ansteigenden Verlauf haben die Praktikanten und Volontäre (982).

Obwohl die prozentualen Anteile der meisten Nicht-Berufe relativ klein sind, ist es doch von Interesse zu untersuchen, ob die Anomalien (d. h. Ausreißer und Niveauverschiebungen) sich in einigen Regionen konzentrieren. Sollte das der Fall sein, könnte dies eventuell bei der Konstruktion der Projektionsmodelle berücksichtigt werden. In Abbildung A.9 auf Seite 177 sind die regionalen Verteilungen der auffälligsten Anomalien dargestellt. Es wurden jeweils die Anteile eines Nicht-Berufes an der Gesamtzahl an Meldungen einer Region berechnet und diese in einem Box- und Rugplot dargestellt. Anstatt nur ein Rug sind zwei Rugs erstellt worden. Der blaue besteht aus den Anteilswerten in den westdeutschen Agenturbezirken und der rote steht für die ostdeutschen Bezirke. Das kleine schwarze \times kennzeichnet den Anteilswert in der Kategorie „ohne Arbeitsortangabe“.

Es ist zu erkennen, dass die regionale Verteilung der Meldungen zu den Nicht-Berufen in den meisten der untersuchten Jahre rechtsschief ist, d. h., es gibt einige starke Ausreißer, auf die bei der Prognose eventuell gesondert eingegangen werden könnte. Weiterhin ist in den Jahren 1991 und 1992 ein großer Unterschied zwischen den ostdeutschen und den westdeutschen Bezirken zu erkennen. Da dies die Jahre sind, in denen zum ersten Mal Daten in Ostdeutschland erhoben wurden, häufen sich Meldungen ohne exakte Berufsbezeichnung, Codes (981),(991) und (971). Die Ausreißer und Niveauanhebungen in den Zeitreihen für diese Codes sind also auf Schwierigkeiten bei der Abgabe der Meldungen in Ostdeutschland zurückzuführen. Daher könnte es möglicherweise sinnvoll sein, die Daten aus Ostdeutschland erst ab dem Jahr 1993 zu verwenden.

Neben der regionalen Verteilung ist es noch wichtig zu untersuchen, ob sich der Anstieg der Meldungen auf einige Regionen konzentriert. Dazu wird für alle Regionen die Differenz zwischen dem Anteil der Meldungen zu einem Nicht-Beruf in dem Jahr vor dem Ausreißer und dem Jahr des Ausreißers berechnet. Diese Differenzen sind in Abbildung A.10 auf Seite 179 abgetragen. Auch hier sind wieder Boxplots mit zwei Rugs (blau für Westdeutschland; rot für Ostdeutschland) erstellt worden.

Und wieder sind für die Jahre 1991 und 1992 große Unterschiede zwischen Ost- und Westdeutschland zu erkennen. Die Vermutung, dass es einige Regionen gibt,

in denen der Anstieg stärker ausfällt als in anderen, wird eindeutig bestätigt. Weiterhin fällt auf, dass es wahrscheinlich einige falsche Arbeitsortangaben im Jahr 1990 gibt. Da erstmalig Daten aus Ostdeutschland im Jahr 1991 erfasst wurden, dürften in den Grafiken mit Differenzen zwischen den Jahren 1990 und 1991 keine roten Striche auftauchen, weil hier die Differenz zwischen etwas nicht Existentem und einer Zahl als nicht existent definiert ist. Dies kann als weiteres Indiz dafür gesehen werden, dass die Daten erst ab dem Jahr 1993 verwendet werden sollten.

4.2. Anteile und Verteilungen der Missings

In Abbildung A.11 auf Seite 181 sind die prozentualen Anteile der Meldungen ohne Angabe zum Beruf, Arbeitsort oder der Stellung im Beruf abgetragen. Die Grafik wird dominiert durch den einmaligen Ausreißer im Jahr 1991. Bei allen betrachteten Variablen schnellte der Anteil der fehlenden Angaben auf ca. 12% empor. Dies ist auf das erstmalige Erfassen der Beschäftigten in den neuen Bundesländern zurückzuführen.

Des Weiteren ist der Anteil der Meldungen abgetragen, bei denen weder der Beruf noch der Arbeitsort erfasst wurde. Der Anteil ist visuell kaum von dem der Anteile der fehlenden Berufsangaben oder der fehlenden Arbeitsortangaben zu unterscheiden. Im Jahr 1998, als die elektronische Erfassung eingeführt wurde und es wieder zu einem kurzzeitigen Anstieg unvollständiger Meldungen kam, sind jedoch kaum Meldungen vorhanden, bei denen beide Angaben fehlen.

Im Weiteren wird überprüft, ob sich Meldungen ohne Berufsangabe in einigen Regionen übermäßig stark häufen und ob Meldungen ohne Arbeitsortangabe verstärkt bei bestimmten Berufen auftreten.

Meldungen ohne Berufsangabe Unter der Annahme, dass Meldungen ohne Berufsangabe rein zufällig auftreten, sollte ihr Anteil in allen Regionen in etwa gleich groß sein. Ebenso sollten die Anteile gleichmäßig um den Mittelwert verteilt sein. Zu fast keinem Zeitpunkt ist dies der Fall. Die lückenhaften Meldungen konzentrieren sich in einigen wenigen Regionen.

Betrachten wir zuerst Westdeutschland, siehe Tabelle A.10 auf Seite 152. Bis ins Jahr 1990 erscheinen Meldungen ohne Berufsangabe maximal in 5% der Agenturbezirke. Jedes Jahr treten relativ gesehen die meisten lückenhaften Meldungen in

4. Explorative Datenanalyse

Bonn auf. In den 1990ern verdichten sich lückenhafte Meldungen in immer mehr Regionen, jedoch bleibt Bonn die Region, in der ihr Anteil mit Abstand am größten ist. Besonders stechen die Jahre 1997 und 1998 hervor, in denen der Anteil besonders hoch ist. Die Schiefe ist auch weiterhin positiv. Ab dem Jahr 2000 treten lückenhafte Meldungen wieder nur in maximal 22 % der Regionen auf und die Anteile sind wieder auf einem sehr niedrigen Niveau. Jedoch gibt es weiterhin jedes Jahr eine Region, deren Anteil an lückenhaften Meldungen sehr viel größer ist als die der anderen Regionen.

In Ostdeutschland zeigt sich ein etwas anderes Bild, siehe Tabelle A.11 auf Seite 154. Im Jahr 1991, als zum ersten Mal die Meldungen der neuen Bundesländer erfasst wurden, fehlte die Berufsangabe bei sehr vielen Meldungen. Die Schiefe der Verteilung ist sogar negativ. Im Laufe der Zeit entwickelte sich jedoch auch in den neuen Bundesländern das gleiche Muster, dass in Westdeutschland vorherrscht: eine stark rechtsschiefe Verteilung mit einem starken Ausreißer.

Festzuhalten bleibt, dass es zu Beginn der Erfassung in den neuen Bundesländern und insbesondere in den Jahren 1997 und 1998 in Bonn und im Jahr 1998 auch in Köln¹ zu einem extrem starken Anstieg an Meldungen ohne Berufsangaben kam.

Meldungen ohne Arbeitsort In Tabelle A.12 auf Seite 155 sind für jedes Jahr die drei Berufe mit den größten Anteilen an Meldungen ohne Arbeitsortangabe aufgelistet. Weiterhin ist die Schiefe der beruflichen Verteilung der Meldungen ohne Arbeitsortangabe angegeben. Für alle Jahre ist die Verteilung rechtsschief, d. h. es gibt sehr viele Berufe, in denen Meldungen ohne Berufsangabe nicht vorkommen und/oder es kommt zu relativ vielen Ausreißern.

Besonders auffällig sind die Jahre 1991 und 1993 bis 1998 (grau markiert). Wie schon bei den Meldungen ohne Berufsangabe ist auch hier im Jahr 1991 ein extrem starker Anstieg an Meldungen ohne Arbeitsortangabe zu verzeichnen. Dies ist auch das Jahr mit dem kleinsten Schiefe-Wert, jedoch deutet der Wert von 5,8 immer noch auf eine rechtsschiefe Verteilung hin. Dies lässt darauf schließen, dass die Berufsstruktur in den neuen Bundesländern zumindest im Jahr 1991 noch stark abweichend von der der alten Bundesländer war.

In den Jahren 1993 bis 1998 stechen die Berufs-Codes 555 (Behinderte), 666

¹Köln ist im Jahr 1998 die Region mit dem zweitgrößten Anteil an Meldungen ohne Berufsangabe (12,7%), siehe `analyse-missing.do`.

(Rehabilitanden) und 888 (Pflegepersonen) mit sehr großen Anteilen an Meldungen ohne Arbeitsortangabe hervor.

4.3. Beschäftigtenanzahlen für die Berufe-Regionen-Kombinationen

Um einen Eindruck über die Größenordnungen der Beschäftigtenanzahlen zu gewinnen, werden acht Größenklassen definiert und für jedes Jahr ausgezählt, wieviele Berufe-Regionen-Kombinationen in die jeweiligen Klassen fallen. Die Beschäftigtenzahl für eine bestimmte Berufe-Regionen-Kombination wird auch Zellenbelegung genannt. Die Ergebnisse sind in Abbildung A.12 auf Seite 182 dargestellt. Im Allgemeinen sind die Anteile über die Zeit recht konstant. Die einzige Ausnahme ist wieder das Jahr 1991. Dort ist der Anteil an Berufe-Regionen-Kombinationen ohne Beschäftigte mit 17,9% mehr als dreimal so hoch wie in den Folgejahren. Für ca. 20% der Berufe-Regionen-Kombinationen sind maximal 10 Beschäftigte gemeldet. Die exakten Prozentangaben sind in der Tabelle A.13 auf Seite 156 aufgeführt.

Für Zeitreihen mit Werten im einstelligen oder niedrigen zweistelligen Bereich wäre zu überlegen, diese mit Zählmodellen zu prognostizieren. Die eben vorgestellten Auszählungen beziehen sich auf die 3-Steller aus der KldB 1988. Für die zur Prognose verwendete Neugruppierung der 3-Steller wird die Analyse in Abschnitt 5.5 weitergeführt.

4.4. Beschäftigtenentwicklung auf verschiedenen Gliederungsebenen

Aufgrund der möglichen Verwendung der Projektionen seitens der BA, z. B. strategische Planung/Steuerung des Weiterbildungs- und Umschulungsangebotes, muss zwischen Vollzeit- und Teilzeitstellen unterschieden werden. Bei Teilzeitbeschäftigten lässt sich weiterhin zwischen Großer und Kleiner Teilzeit unterscheiden, wobei 18 Std./Woche die Grenze ist. Die Beschäftigten in Kleiner Teilzeit werden nicht weiter berücksichtigt. Zum einen sind diese sehr viel anfälliger für konjunkturelle Schwankungen (z. B. kein Kündigungsschutz für geringfügig entlohnte Beschäftigte) und zum anderen wird erwartet, dass die Validität der Angaben z. B. zu dem

4. Explorative Datenanalyse

Beruf oder der Bildung recht schwach ist (besonders für die geringfügig entlohnten Beschäftigten). Im Weiteren sind mit Teilzeitbeschäftigten immer Beschäftigte in Großer Teilzeit gemeint.

Zuerst werden die Zeitreihen der Beschäftigtenzahlen für Deutschland insgesamt geplottet und dann schrittweise räumlich sowie beruflich disaggregiert. Dadurch werden unterschiedliche Muster in Ost- und Westdeutschland sowie in verschiedenen Berufsklassen erkennbar.

Ein besonderes Augenmerk wird dabei auf eventuelle Strukturbrüche um die Jahre 1990 und 1999 gelegt. Mit der Wiedervereinigung Deutschlands im Jahr 1990 sind grundlegende wirtschaftliche Rahmenbedingungen verändert worden. Es ist möglich, dass sich diese in den Zeitreihen der Beschäftigtenentwicklung erkennen lassen. Im Jahr 1999 trat die Meldepflicht für geringfügig entlohnte Beschäftigte in Kraft. Auch wenn diese Meldungen fast komplett in die Kategorie Kleine Teilzeit fallen, ist nicht auszuschließen, dass sich Effekte bei den übrigen Beschäftigten zeigen.

4.4.1. Regionale Gliederung

Als Erstes werden die Beschäftigtendaten nur regional differenziert.

Ost- und Westdeutschland In Abbildung A.13 auf Seite 183 sind die Beschäftigtenzahlen für die Jahre 1984 bis 2008 abgetragen. Es wird zwischen Vollzeit und Großer Teilzeit unterschieden. Die Kurve für Deutschland insgesamt enthält sämtliche Beschäftigte, auch die, bei deren Meldung die Arbeitsortangabe fehlt. Da die Anzahl der Beschäftigten in Westdeutschland etwa viermal so groß ist wie in Ostdeutschland, ist die Ost-Zeitreihe mit einer individuellen Skala dargestellt (linke Ordinate für Ostdeutschland). Als Startpunkt für den Osten ist das Jahr 1992 gewählt worden.

Für die Beschäftigten in Voll- und Teilzeit ist bis zum Jahr 1992 in Westdeutschland ein ansteigender Verlauf zu beobachten. Für die Teilzeitbeschäftigten setzt sich der Trend fast linear fort. Bei den Vollzeitbeschäftigten kehrt sich dieser Trend jedoch ab dem Jahr 1992 mit einer nahezu identischen, aber jetzt negativen Steigung um. In den Jahren von 1998 bis 2001 und ab 2005 steigt die Beschäftigung. Allerdings wird das vorherige Niveau nicht wieder erreicht.

Für die Beschäftigungsentwicklung in Ostdeutschland sind ähnliche Trends wie in Westdeutschland zu erkennen. Ein offensichtlicher Unterschied ist jedoch bei

4.4. Beschäftigtenentwicklung auf verschiedenen Gliederungsebenen

den Vollzeitbeschäftigten auszumachen. Der Aufschwung, der im Westen zwischen 1998 und 2001 zu beobachten ist, schlägt im Osten eher positiv auf die Teilzeitbeschäftigung durch. Ab 2005 ist bei den Vollzeitbeschäftigten wieder in beiden Regionen ein positives Wachstum zu erkennen.

Bundesländer Als nächstfeinere räumliche Disaggregation betrachten wir die Bundesländer. In Abbildung A.14 auf Seite 184 ist sehr gut zu erkennen, dass sich das West-Muster in sämtlichen alten Bundesländern wiederfindet. Das Gleiche gilt für die neuen Bundesländer, in denen sich das Ost-Muster widerspiegelt.

Regierungsbezirke Für Bundesländer, in denen Regierungsbezirke existieren, sind in den Abbildungen A.15 auf Seite 185 und A.16 auf Seite 186 die Zahlen der Vollzeitbeschäftigten dargestellt. Die Grafiken sind spaltenweise angeordnet. Ganz oben ist die Zeitreihe des Bundeslandes zu sehen und darunter folgen die der entsprechenden Regierungsbezirke. Im Großen und Ganzen sind die Muster relativ stabil, jedoch treten auch Unterschiede zutage. Besonders gravierend ist dies bei den Regierungsbezirken Oberbayern [9100] mit einem global positiven Trend und dem Regierungsbezirk Oberfranken [9400] mit einem global negativen Trend, siehe Abbildung A.16 auf Seite 186. Diese gegenläufigen Entwicklungen führen dazu, dass die Zahl der Vollzeitbeschäftigten in Bayern um ein Niveau schwankt.

In den Abbildungen A.17 auf Seite 187 und A.18 auf Seite 188 sind die Zahlen für die Teilzeitbeschäftigten abgetragen. Hier ist das Muster in allen betrachteten Bundesländern bei räumlicher Disaggregation stabil.

Ein Vergleich anhand der eben betrachteten Zeitreihenplots gibt einen ersten Eindruck über das generelle Muster – Auf- und Abwärtstrends und deren Beständigkeit – der Beschäftigtenentwicklung. Aufgrund der Skalenunterschiede müssen für jeden Plot, d. h. für jeden Regierungsbezirk, individuelle Skalen der Ordinaten verwendet werden. Daher ist kein Vergleich über die Größenordnung der Trends möglich. Dieses Problem wird gelöst, indem die jährlichen prozentualen Veränderungsraten berechnet werden. Diese sind in den Abbildungen A.19 bis A.22 auf den Seiten 189–192 dargestellt. Im Allgemeinen bestätigt sich der Eindruck von der Beständigkeit der Muster. Weiterhin ist festzustellen, dass auch das Niveau der relativen Veränderungen bei räumlicher Disaggregation in etwa konstant bleibt.

Fazit Die Muster der Beschäftigtenentwicklung scheinen bei regionaler Disaggregation bis zur Ebene der Regierungsbezirke erhalten zu bleiben. Dieses Ergebnis ist nicht überraschend. Regierungsbezirke sind wohl großräumig und bevölkerungsreich genug, um die Muster, welche bei Betrachtung der Bundesländer bzw. Ost- und Westdeutschland zu finden sind, zu replizieren. Vereinzelt sind jedoch auch Unterschiede zu finden. Daher ist zu vermuten, dass bei noch stärkerer Disaggregation andere Muster zu finden sind.

4.4.2. Regionale und berufliche Gliederung

Abschließend wird zusätzlich die berufliche Dimension mit aufgenommen, wobei wir uns auf die Berufsklassifikation nach Blossfeld (1985) beschränken, da die Ebene der 88 Berufsgruppen zu detailliert für eine visuelle Prüfung ist. In Tabelle A.15 auf Seite 158 ist die Zuordnung von Berufsordnungen (3-Steller der KldB 1982) zu den sogenannten Blossfeld-Berufen zu finden.

Ost- und Westdeutschland Um einen Eindruck von den Größenordnungen zu vermitteln, werden zu Beginn die Zeitreihen auf einer einheitlichen Skala dargestellt, siehe Abbildung A.23 auf Seite 193. Wie erwartet, stellen die Beschäftigten in den Agrarberufen die kleinste Gruppe dar (gültig für Voll- und Teilzeit). Bei den Vollzeitbeschäftigten sind die Berufsklassen [2], [3], [6] und [11] am stärksten besetzt. Bei den Teilzeitbeschäftigten sind es eher die Klassen [6], [8], [10] und [11].

Die Darstellung mit individuellen Skalen je Beruf erlaubt es, die Muster der Zeitreihen deutlicher zu erkennen. Bei den Vollzeitbeschäftigten sind Aufwärtstrends, eher stagnierende Verläufe und negative Trends zu beobachten, siehe Abbildung A.24 auf Seite 194. Bei den Teilzeitbeschäftigten sind fast durchweg glatte positive Trends zu finden. Einzige Ausnahme sind die Agrarberufe und einfachen manuellen Berufe, siehe Abbildung A.25 auf Seite 195.

Bundesländer Als Nächstes soll überprüft werden, inwieweit die spezifischen Muster der Berufe-Regionen-Kombinationen bei räumlicher Disaggregation erhalten bleiben. Aufgrund der stark unterschiedlichen Beschäftigtenzahlen in den Bundesländern werden diese in große, mittlere und kleine Länder gruppiert. In den Abbildungen A.26 bis A.28 auf den Seiten 196–198 sind die Zeitreihen für Vollzeitbeschäftigte eingezeichnet. (Die Daten der neuen Bundesländer sind erst ab

dem Jahr 1992 aufgenommen, um das abrupte steile Ansteigen von 1991 zu 1992 zu vermeiden.) Die Zeitreihen der Teilzeitbeschäftigten sind in den Abbildungen A.29 bis A.31 auf den Seiten 199–201 zu finden. Die Muster scheinen recht stabil zu sein.

Regierungsbezirke In sieben Bundesländern existieren Regierungsbezirke oder Landesdirektionen.² Für diese Bundesländer sind für jede Berufsklasse zwei Abbildungen erstellt worden, siehe Abbildungen A.32 bis A.79 auf den Seiten 202–249. Die eine Abbildung enthält die Zeitreihen der Beschäftigtenzahlen, die andere zeigt die jährlichen prozentualen Veränderungsdaten. Jede dieser Abbildungen enthält 36 Grafiken. Die Anordnung der Grafiken erfolgt spaltenweise. Die erste Grafik einer Spalte gehört zu einem Bundesland, die restlichen Grafiken in der Spalte gehören zu den Regierungsbezirken des Bundeslandes. Einzige Ausnahme sind die Grafiken der vorletzten Spalte, diese gehören zu Bayern. Im Allgemeinen sind auch hier die Muster einigermaßen stabil, z. B. Semiprofessionen in Vollzeit und qualifizierte Dienstleistungsberufe in Teilzeit, siehe Abbildung A.46 auf Seite 216 und Abbildung A.68 auf Seite 238. Relativ unterschiedliche Beschäftigungsentwicklungen sind z. B. bei den einfachen manuellen Berufen in Teilzeit in Abbildung A.58 auf Seite 228 zu erkennen.

4.5. Fazit

Die Wiedervereinigung im Jahr 1990 hat tiefgreifende politische und ökonomische Veränderungen mit Auswirkungen auf das gesamte Bundesgebiet nach sich gezogen. Besonders für die neuen Bundesländer ist die Verfügbarkeit und Zuverlässigkeit sehr vieler Daten bis etwa 1993 nicht umfassend gewährleistet. Doch auch für die alten Bundesländer haben sich die Rahmenbedingungen geändert. Viele der Zeitreihen für die Vollzeitbeschäftigten zeigen eine Trendwende um das Jahr 1992.

Zwei nahe liegende Möglichkeiten, mit diesem Problem umzugehen, sind zum einen die Modellierung von zurückliegenden Brüchen und zum anderen das Weglassen der Daten vor dem Bruch. Die Modellierung von zurückliegenden Brüchen für die Prognose des rechten Randes ist immer dann irrelevant und kontraproduktiv,

²Die Regierungsbezirke in Rheinland-Pfalz wurden zwar im Jahr 2000 aufgelöst, da es jedoch nicht zu Neuabgrenzungen der Kreise kam, können die Daten weiterhin zu den alten Regierungsbezirken zusammengefasst werden.

4. Explorative Datenanalyse

wenn es nicht gelingt, für jede Berufe-Regionen-Kombination eventuelle Strukturbruchzeitpunkte exakt zu datieren und eine möglichst gute Approximation der funktionalen Form für die resultierenden Perioden zu finden. Weiterhin geht es im Rahmen der vorliegenden Fragestellung nie um die Schätzung und Interpretation von Modellen, sondern lediglich um die Prognose der Beschäftigtenzahlen. Aus statistischer Sicht ist festzuhalten, dass die in Kapitel 6 vorgestellten Methoden keinen langen Zeithorizont T benötigen oder die Modellierung des Strukturbruches für die Prognose gleichbedeutend mit dem Weglassen der Daten vor dem Bruch ist.

Daher werden zur finalen Modellschätzung nur Daten ab 1993 für die abhängige Variable, und dementsprechend ab dem Jahr 1992 für die verzögerte abhängige Variable, genutzt. Wir verwenden ein balanciertes Panel, also $T = 16$ für alle Berufe-Regionen-Kombinationen.³

³Die beiden Berufe, die erst ab 1995 bzw. 1996 existieren (Pflegerpersonen (888) und Haushaltshilfen (924)), werden separat fortgeschrieben. Meldungen mit der Berufsangabe Altersteilzeit (996) werden gar nicht berücksichtigt, da dieser Code nur bis zum Jahr 1999 verwendet wurde.

5. Neue Berufsgruppierung

5.1. Gesichtspunkte einer Aktualisierung der KldB 1988

Bis heute existiert in der Wissenschaft weder eine einheitliche Definition des Begriffes *Beruf* noch wie Berufe unterschieden bzw. abgegrenzt werden sollten, vgl. Matthes et al. (2008). Die in den Daten verwendete Klassifikation der Berufe, die KldB 1988, auf der Aggregationsebene der 3-Steller, stammt aus dem Jahr 1988. Vor dem Hintergrund der sich verändernden Strukturen und Anforderungen auf dem Arbeitsmarkt, bezogen auf die geforderten Fähigkeiten und Qualifikationen, muss die KldB 1988 als veraltet angesehen werden. Ebenso werden Berufe nicht nach einheitlichen Unterscheidungsmerkmalen klassifiziert. Die Umstellung bei der Sozialversicherungsmeldung auf die neue Klassifizierung der Berufe (KldB 2010) geschah im 2. Quartal 2011, siehe Statistik der Bundesagentur für Arbeit (2010). Da sich die KldB 1988 jedoch nicht eindeutig in die neue KldB 2010 umschlüsseln lässt, wird in dieser Arbeit eine andere Klassifikation verwendet. Die Aggregationsebene der 2-Steller für die KldB 1988 ist nicht hierarchisch und somit unbrauchbar. Die von Tiemann et al. (2008) konstruierten 54 Berufsfelder gruppieren Berufe ohne Berücksichtigung der Bildungsanforderungen und scheiden damit für dieses Projekt ebenfalls aus. Matthes et al. (2008) aggregieren die 3-Steller zu 20 Gruppen, welche sie Berufssegmente nennen. Vor dem Hintergrund der etwaigen Nutzung der Prognosen bei der Berufsberatung durch die BA ist eine Aggregation in nur 20 Berufssegmente zu grob. Gleiches gilt für die Einteilung nach Blossfeld (1985) in 12 Berufsgruppen und die 5 Qualifikationsklassen nach Cordes (2010).

Im Hinblick auf die Verwendung in einem Projektionsansatz auf Regionalebene wird aus diesen Gründen vorgeschlagen, die 3-Steller neu zu gruppieren. Dabei ist es nicht das Ziel, Berufe manuell und subjektiv neu zu definieren, sondern einen Algorithmus unter Berücksichtigung aktueller Veränderungen in der Berufestruk-

5. Neue Berufsgruppierung

tur zu entwickeln, mit dem die 3-Steller nach objektiven Kriterien neu gruppiert werden. Zentraler Aspekt ist dabei eine hinreichende Ähnlichkeit der zu aggregierenden 3-Steller-Berufe. Folgende drei Punkte sind zu beachten:

1. Es soll eine hinreichende Ähnlichkeit der zu aggregierenden 3-Steller-Berufe gegeben sein.
2. Nach Möglichkeit sollten die zusammengefassten Berufe homogen hinsichtlich der schulischen Bildungsabschlüsse sein.
3. Die durch das Zusammenfassen entstandenen Berufsklassen sollen ausreichend groß sein (bezogen auf die Beschäftigtenzahl).

Im Folgenden werden diese drei Gesichtspunkte noch näher ausgeführt, bevor die empirische Umsetzung der Punkte 1. und 2. für den vorliegenden Fall in jeweiligen Unterabschnitten dieses Abschnitts diskutiert wird. Ziel dieses Abschnitts ist es, daraus eine hinsichtlich der Implementation weitestgehend automatisierbare Vorgehensweise zur Bestimmung einer aktuellen Berufsklassifikation abzuleiten. Im letzten Unterabschnitt wird eine mögliche Vorgehensweise vorgestellt, bei der die Bedingung ausreichend großer Zellen (Punkt 3.) erfüllt ist.

Ad. 1. Die Ähnlichkeit von Berufen bezieht sich auf die geforderten Qualifikationen und Fähigkeiten, die deren Ausübung erfordern. Eine solche Ähnlichkeit festzustellen, verlangt eine genaue Kenntnis der Berufe, wie sie beispielsweise ein Berufsberater der BA hat. Die Berufsbezeichnung kann Hinweise darauf geben, welche Berufe sich ähnlich sind. Jedoch lässt sich die Ähnlichkeit nicht quantifizieren. Eine nahe liegende Möglichkeit, die Ähnlichkeit von 3-Steller-Berufen statistisch abzuschätzen, besteht darin, die Übergangsraten zwischen den Berufen zu betrachten. Solche Übergänge lassen sich mit den uns vorliegenden anonymisierten Daten nicht auszählen. Aus diesem Grund ist von Herrn Dr. Ludsteck eine anonymisierte Übergangsmatrix am IAB erstellt und an uns übersandt worden. In dieser sind die Summen der jährlichen absoluten Berufswechsel zwischen den Berufen enthalten. Da eine neue Klassifikation die oben aufgeführten aktuellen Änderungen auf dem Arbeitsmarkt reflektieren soll, werden nur die Übergangsraten der Jahre 2004 bis 2008 betrachtet. Hier gilt es einen Algorithmus herauszuarbeiten, mit dem sequentiell eine disjunkte Aufteilung aller Berufe in Gruppen ähnlicher Berufe ermittelt werden kann.

Ad. 2. Es gibt Berufe, z. B. Ärzte, wo davon auszugehen ist, dass die Bildungsabschlüsse homogen sind. Es gibt aber auch Berufe, z. B. Verkäufer, für die eine große Bandbreite an Vorbildung – von Personen ohne Berufsausbildung bis hin zu Hochschulabsolventen – beobachtet werden kann. Die Beantwortung der Frage, ob Berufe (paarweise) homogen hinsichtlich des Merkmals Bildungsabschluss sind, ist nicht trivial, da im Prinzip empirische und im zeitlichen Wandel befindliche Verteilungen dieses ordinalen Merkmals miteinander verglichen werden müssen. Sie wird zudem durch nicht unerheblich viele fehlende Werte und, nur in wenigen Fällen offensichtliche Fehler in den Daten erschwert. Die zentrale Frage ist also, wie sich Entscheidungskriterien zur Bestimmung der Homogenität formulieren und operationalisieren lassen.

Ad. 3. Im Hinblick auf die Verwendung der neuen Berufsklassifikation zur Prognose, ist die ausreichende Besetzung der resultierenden Berufe-Regionen-Kombinationen in gewisser Weise als Nebenbedingung zu sehen. Es entsteht eine Art trade-off-Problem: Mit zunehmend stärkerer Aggregation wird eine ausreichende Besetzung einzelner Zellen wahrscheinlicher. Dies wird aber nur erreicht, wenn die Anforderungen an Ähnlichkeit und Homogenität zunehmend niedriger gewählt werden. Mangels harter Kriterien müssen zur Lösung dieses trade-offs plausible Schwellenwerte vorgegeben werden. Auf Ebene der 3-Steller gibt es eine große Anzahl an Berufen, für die jeweils nur sehr wenige Beschäftigte gemeldet sind. Im Jahr 2008 ist von den 342 Berufen knapp die Hälfte so schwach besetzt, dass die Beschäftigten in diesen Berufen zusammen nicht einmal 5 Prozent aller im Jahr 2008 gemeldeten Personen ergeben. Es gibt aber auch sehr stark besetzte Berufe. Allein drei dieser Berufe machen zusammen knapp 20 Prozent aller Beschäftigten im Jahr 2008 aus. Mit über 4 Millionen Beschäftigten stehen die Bürofachkräfte an erster Stelle. Danach kommen die Verkäufer mit ca. 1,9 Millionen und die Raum- und Hausratreiniger mit ca. 1,1 Millionen. In Analogie zu den Überlegungen bei der Aggregation von Berufen sollte in diesen Fällen geprüft werden, inwieweit eine Aufspaltung gemäß der Bildungsstrukturen möglich ist.

5.2. Ähnlichkeit der Berufe

Berufswechsel lassen sich aus zwei verschiedenen Perspektiven betrachten. Die eine Sichtweise ist rückwärts gerichtet und zeigt, welche Berufe die Beschäftigten vor dem Wechsel (d. h. im Vorjahr) ausgeübt haben. Hier wird von Ursprungsbe-

5. Neue Berufsgruppierung

rufen gesprochen. Die andere Sichtweise ist vorwärts gerichtet und zeigt, in welche Berufe (Zielberufe) die Beschäftigten wechseln. Die beiden Perspektiven sind in Abbildung 5.1 beispielhaft anhand des Berufes Maurer skizziert.

Zielberufe: Es wird nur die linke Seite der Abbildung 5.1 betrachtet. Die Zahlen an den Pfeilen zeigen, wie viele von den 167.353 Personen, die 2007 als Maurer gearbeitet haben, in die entsprechenden Zielberufe gewechselt sind. Da Berufswechsel relativ selten vorkommen, ist die absolute Mehrheit der Beschäftigten im Jahr 2008 wieder als Maurer beschäftigt. Es sind zwar nur Berufswechsel zu den Landwirten, Weinbauern und Ärzten skizziert, doch die Auslassungspunkte verdeutlichen, dass die Berufswechsel für sämtliche andere Berufe erfasst werden.

Ursprungsberufe: Bei der rechten Hälfte der Abbildung 5.1 liegt der Fokus auf den Personen, die 2008 als Maurer gearbeitet haben. Es wird angegeben, welche Berufe sie im Jahr 2007 ausgeübt haben. Die Zahlen über den Pfeilen stehen für die entsprechenden Anzahlen.¹

¹Die Gesamtanzahl der Maurer ist korrekt, die Übergangszahlen sind jedoch fiktiv.

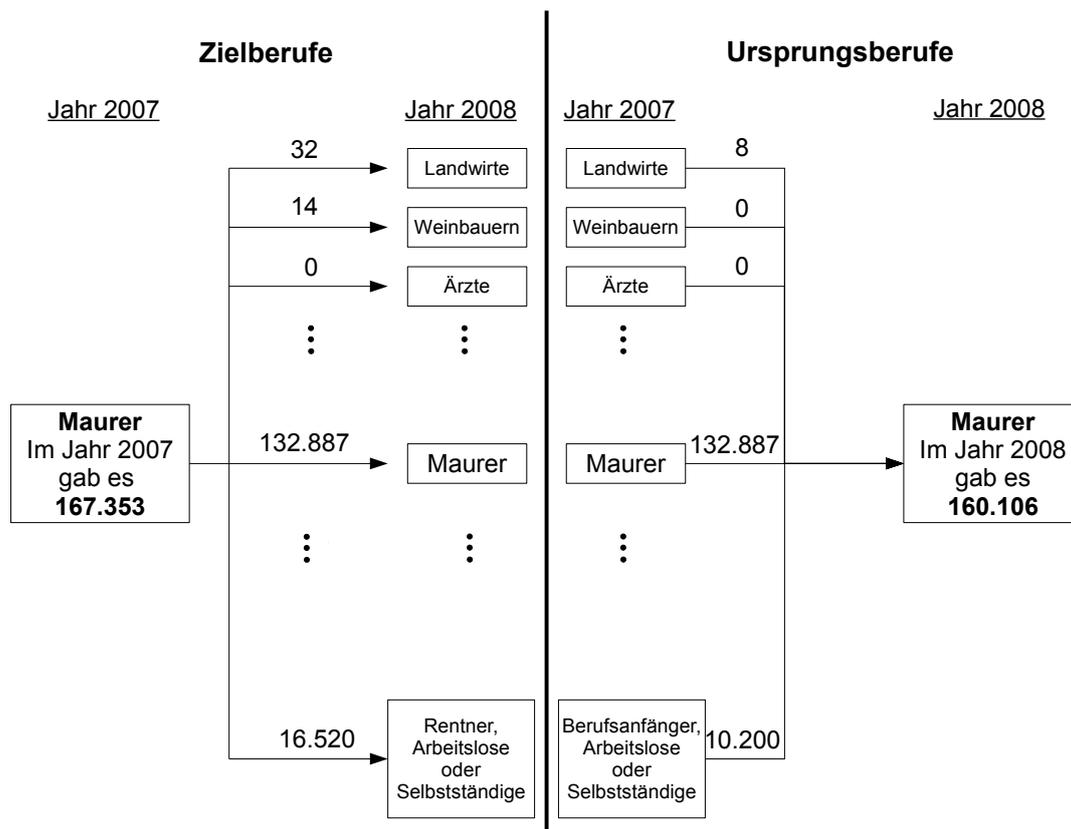


Abbildung 5.1.: Die zwei Perspektiven für die Berufswechsel

In Tabelle 5.1 ist die am IAB erstellte Übergangstabelle skizziert. Sie besteht aus 3 Spalten und 117.648 Zeilen². Die Spalte „source“ gibt den alten Beruf an und in der Spalte „destin“ steht der neue Beruf. In der abgebildeten Sortierung ist die Sichtweise der Zielberufe gewählt und **destin** ist als Zielberuf zu interpretieren. In der dritten Spalte steht die Anzahl der Personen für die entsprechenden Berufswechsel. Der dicke Punkt bedeutet, dass diese Personen entweder im Vorjahr oder im Zieljahr nicht gemeldet waren (z. B. Arbeitslose, Berufsanfänger, Rentner oder Selbstständige). Die Zahlen in den runden Klammern hinter der Berufsbezeichnung geben die Codierung in der Datentabelle an. Für Berufspaare mit einer Anzahl an Übergängen zwischen 1 und 9 sind die Angaben aus Datenschutzgründen gelöscht und durch die Angabe < 10 ersetzt.

In Abbildung A.80 auf Seite 250 sind zwei Boxplots der Übergangszahlen darge-

²Auf Ebene der 3-Steller werden 341 Berufe unterschieden. Zusätzlich gibt es die Kategorie „nicht beschäftigt“ • und Missing (0), somit ergeben sich $(341 + 2) \times (341 + 2) - 1 = 117.648$ Zeilen. Die Eins wird abgezogen, weil die Kombination **source** = • und **destin** = • nicht existiert.

Tabelle 5.1.: Anzahl der Berufswechsel – Summe der jährlichen Übergänge für die Jahre von 2004 bis 2008 – Perspektive: Zielberufe

source	destin	Personen (n)
• (-1)	Missing (0)	2.570
• (-1)	Landwirte (11)	23.462
• (-1)	Weinbauern (12)	1.801
• (-1)	Tierzüchter (21)	5.053
⋮	⋮	⋮
• (-1)	Ausgleichsgeldbezieher (997)	1.552
Missing (0)	• (-1)	4.116
Missing (0)	Missing (0)	8.976
Missing (0)	Landwirte (11)	< 10
Missing (0)	Weinbauern (12)	< 10
⋮	⋮	⋮
Missing (0)	Ausgleichsgeldbezieher (997)	< 10
Landwirte (11)	• (-1)	15.866
Landwirte (11)	Missing (0)	< 10
Landwirte (11)	Landwirte (11)	59.374
Landwirte (11)	Weinbauern (12)	60
⋮	⋮	⋮
Landwirte (11)	Ausgleichsgeldbezieher (997)	< 10
Weinbauern (12)	• (-1)	1.331
⋮	⋮	⋮

5. Neue Berufsgruppierung

stellt.³ Der obere Boxplot zeigt die Übergangszahlen für tatsächliche Berufswechsel (`source` \neq `destin`) und der untere beruht auf den Verbleibszahlen (`source` = `destin`). Verwendet man die Verbleibszahlen als Proxy für die Anzahl an Beschäftigten in den jeweiligen Berufen, werden die Größenunterschiede zwischen den Berufen sehr deutlich. Aufgrund der großen Anzahl an Berufskombinationen, bei denen keine oder sehr wenige Wechsel beobachtet worden sind⁴, erkennt man in der oberen Grafik nur Punkte und keine Box. Die größte Anzahl an Wechseln⁵ zwischen zwei Berufen wird für die Verkäufer und Bürofachkräfte mit ca. 75.000 beobachtet. Die Bürofachkräfte sind es auch, die den größten Ausreißer bei dem unteren Boxplot verursachen. Im Laufe der fünf Jahre wurden insgesamt ca. 13 Mio. Meldungen mit der Berufsangabe Bürofachkraft gemacht, was ca. 3,25 Mio. Beschäftigten pro Jahrespaar (2004/2005 ... 2007/2008) entspricht, die in beiden Jahren als Bürofachkraft gemeldet wurden.

Aufgrund der starken Unterschiede bei den Beschäftigtenzahlen in den einzelnen Berufen sind die absoluten Übergangszahlen nicht aussagekräftig bzw. lassen sich diese nicht über Berufe hinweg vergleichen. Bei der Berechnung von relativen Übergängen gibt es zwei Möglichkeiten:

Zielberuf-Anteile Zielberuf-Anteile, im Folgenden auch Zielanteile genannt, werden berechnet, indem man die Übergangszahlen durch die Summe der Beschäftigten des Berufes teilt, aus dem heraus gewechselt wird. In Tabelle 5.2 auf der nächsten Seite sind Übergangszahlen für die gleichen Berufe wie in Tabelle 5.1 sowie die dafür berechneten Zielanteile angegeben.

Ursprungsberuf-Anteile Teilt man die Übergangszahlen durch die Summe der Beschäftigten eines Berufes, in den hineingewechselt wird, erhält man die Ursprungsberuf-Anteile, im Folgenden auch Ursprungsanteile genannt. In Tabelle 5.3 auf der nächsten Seite werden wieder die Übergangszahlen und nun die Ursprungsanteile aufgelistet. Man beachte, dass die Übergangszahlen dieselben wie in der Tabelle 5.2 sind (jedoch in anderer Sortierung).

³Diese Abbildung und alle weiteren, die in diesem Abschnitt enthalten sind, werden mit `berufstransitionen-analysieren.do` erstellt.

⁴Für ca. 40 % Berufskombinationen ist die Übergangszahl zwischen Eins und Zehn. Für ca. 32 % der Berufskombinationen haben in den betrachteten Jahren gar keine Wechsel stattgefunden.

⁵Summe der jährlichen Wechsel für den Zeitraum von 2004 bis 2008.

Tabelle 5.2.: Kumulierte Berufswechsel (Jahre: 2004–2008) – Zielanteile

source	destin (Zielberuf)	Personen (n)	Personen je source	Zielanteil
• (-1)	Missing (0)	2.570	13,9 Mio.	0,02
• (-1)	Landwirte (11)	23.462	13,9 Mio.	0,17
• (-1)	Weinbauern (12)	1.801	13,9 Mio.	0,01
• (-1)	Tierzüchter (21)	5.053	13,9 Mio.	0,04
⋮	⋮	⋮	⋮	⋮
• (-1)	Ausgleichsgeldbezieher (997)	1.552	13,9 Mio.	0,01
Missing (0)	• (-1)	4.116	17.290	23,81
Missing (0)	Missing (0)	8.976	17.290	51,91
Missing (0)	Landwirte (11)	< 10	17.290	0,02
Missing (0)	Weinbauern (12)	< 10	17.290	0
⋮	⋮	⋮	⋮	⋮
Missing (0)	Ausgleichsgeldbezieher (997)	< 10	17.290	0
Landwirte (11)	• (-1)	15.866	92.189	17,21
Landwirte (11)	Missing (0)	< 10	92.189	0
Landwirte (11)	Landwirte (11)	59.374	92.189	64,40
Landwirte (11)	Weinbauern (12)	60	92.189	0,07
⋮	⋮	⋮	⋮	⋮
Landwirte (11)	Ausgleichsgeldbezieher (997)	< 10	92.189	0,00
Weinbauern (12)	• (-1)	1.331	7.750	17,17
⋮	⋮	⋮	⋮	⋮

Tabelle 5.3.: Kumulierte Berufswechsel (Jahre: 2004–2008) – Ursprungsanteile

source (Ursprungsberuf)	destin	Personen (n)	Personen je destin	Ursprungsanteil
Missing (0)	• (-1)	4.116	13,1 Mio.	0,03
Landwirte (11)	• (-1)	15.866	13,1 Mio.	0,12
Weinbauern (12)	• (-1)	1.331	13,1 Mio.	0,01
Tierzüchter (21)	• (-1)	4.555	13,1 Mio.	0,03
⋮	⋮	⋮	⋮	⋮
• (-1)	Missing (0)	2.570	13.220	19,44
Missing (0)	Missing (0)	8.976	13.220	67,90
Landwirte (11)	Missing (0)	< 10	13.220	0
Weinbauern (12)	Missing (0)	< 10	13.220	0
⋮	⋮	⋮	⋮	⋮
• (-1)	Landwirte (11)	23.462	99.827	23,50
Missing (0)	Landwirte (11)	< 10	99.827	0,00
Landwirte (11)	Landwirte (11)	59.374	99.827	59,48
Weinbauern (12)	Landwirte (11)	65	99.827	0,07
⋮	⋮	⋮	⋮	⋮
• (-1)	Weinbauern (12)	1.801	8.366	21,53
⋮	⋮	⋮	⋮	⋮

5. Neue Berufsgruppierung

Welche Sichtweise? Je nachdem, ob Ziel- oder Ursprungsanteile berechnet werden, können sich zwei stark unterschiedliche Werte ergeben. Dies ist immer der Fall, wenn die Berufe in `source` und `destin` – für eine gegebene Anzahl an Transitionen – unterschiedlich stark besetzt sind.

Um festzustellen, ob sich zwei Berufe sehr ähnlich sind, müssen beide Wechselrichtungen betrachtet werden. Also nicht nur z. B. Maurer \rightarrow Landwirte, sondern auch die Gegenrichtung Maurer \leftarrow Landwirte. Finden Übergänge hauptsächlich in eine Richtung statt, könnte es sein, dass die Berufe zwar ähnlich sind, einer jedoch hierarchisch höher angesiedelt ist (z. B. Bäcker und Bäcker-Meister). Eine andere Erklärung könnte sein, dass der Beruf, aus dem heraus gewechselt wird, „ausstirbt“.

Einen Eindruck darüber, ob es viele Berufskombinationen mit einfach gerichteten Übergängen gibt, erhält man über Streudiagramme. In Abbildung 5.2 sind die absoluten Übergangszahlen für Berufswechsel (`source` \neq `destin`) abgetragen. Jeder Punkt steht für eine Berufskombination, z. B. Maurer - Landwirt; an der Abszisse ist dann die Anzahl an Wechsels von Maurern zu Landwirten abgetragen und an der Ordinate die Wechsel in Gegenrichtung. Das linke Streudiagramm enthält alle Daten. Das rechte Diagramm stellt nur den Ausschnitt mit Transitionen von maximal 8000 dar. Die hohe positive Korrelation (0,962 für alle Daten)

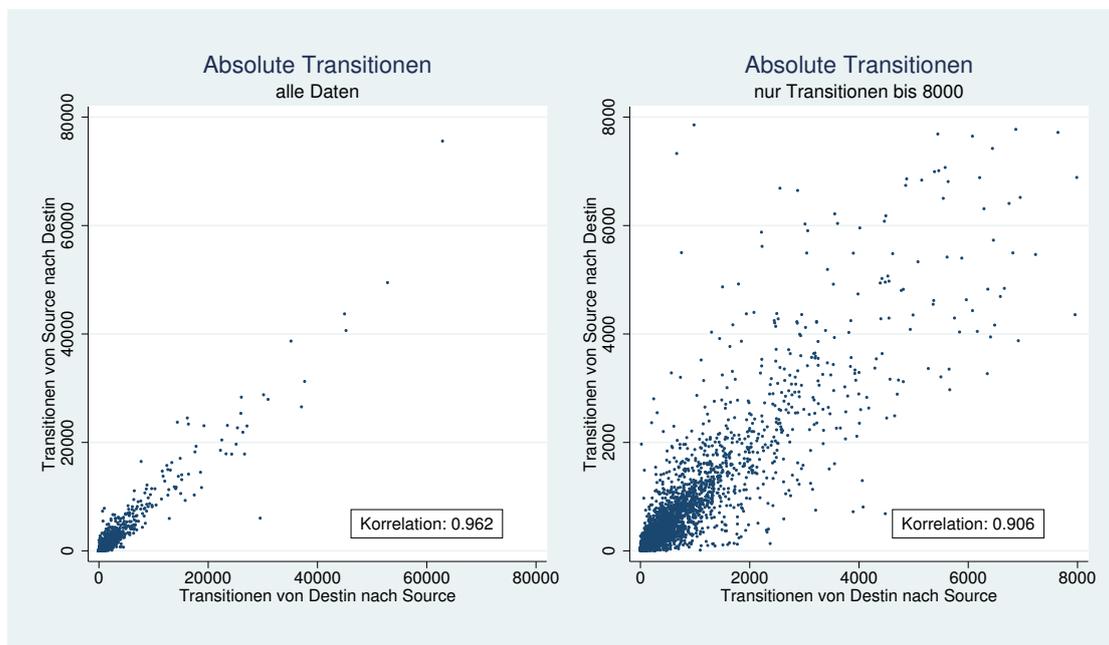


Abbildung 5.2.: Berufstransitionen - absolut

lässt vermuten, dass es eher wenige Berufskombinationen mit einfach gerichteten Wechslen gibt. Doch aufgrund der stark unterschiedlichen Beschäftigtenzahlen in den Berufen müssen relative Transitionen betrachtet werden. Hier herrscht das Bild von eher einfach gerichteten Übergängen vor. Die Korrelation beträgt nur 0,152 (alle Daten) und die Punktwolke liegt L-förmig an den Achsen, siehe Abbildung 5.3. Weiterhin ist festzuhalten, dass die relativen Transitionen vergleichsweise niedrig sind. Der größte Wert liegt bei ca. 9,2% und für den Großteil der Berufskombinationen übersteigen die relativen Transitionen nicht die 2-%-Marke.

Als Nächstes werden für jeden Beruf die fünf Top-Zielberufe und ebenso die fünf Top-Ursprungsberufe bestimmt. Somit erhält man 340 Top-1-Zielanteile, 340 Top-2-Zielanteile etc. und dies ebenso für die Ursprungsanteile. In Abbildung A.81 auf Seite 251 sind die Boxplots der Ursprungsanteile und in Abbildung A.82 auf Seite 252 die der Zielanteile zu finden. Für Ziel- und Ursprungsanteile sinken das Maximum und der Median rapide ab, je niedriger der Top-Rang ist. Da die Anteile sehr schnell kleiner werden, macht es keinen Sinn, mehr als die fünf Top-Ursprungs- bzw. Zielberufe zu berücksichtigen (der größte Top-5-Anteil beträgt gerade einmal knapp 2% und übersteigt in der Regel nicht 1%).

In den Abbildungen A.83 auf Seite 253 und A.84 auf Seite 254 sind die verschie-

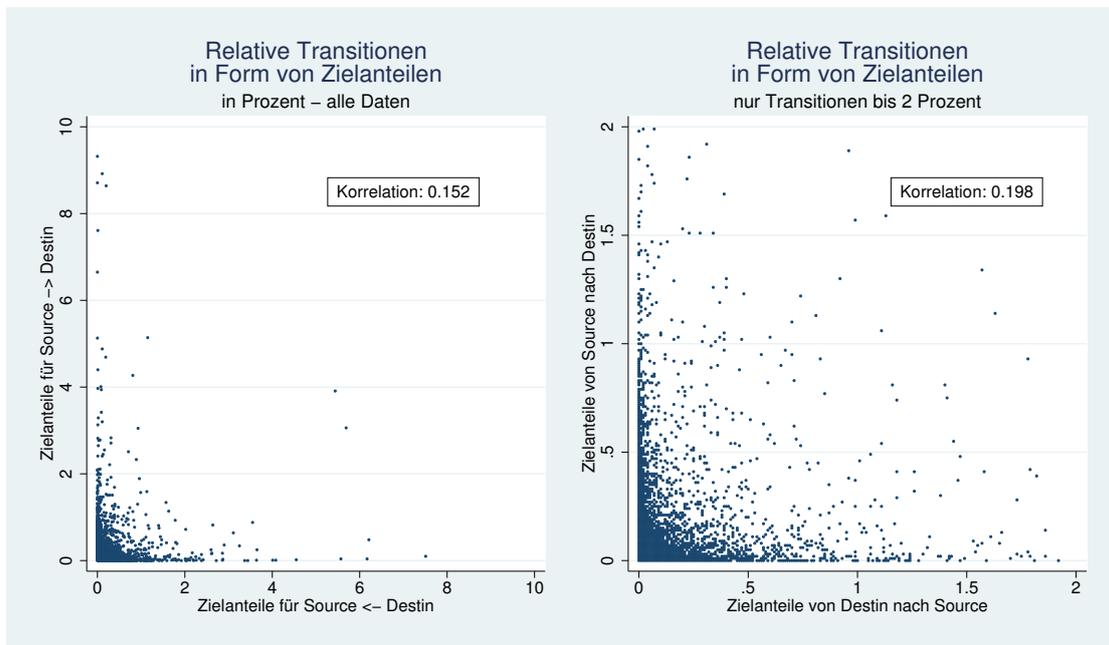


Abbildung 5.3.: Berufstransitionen - relativ

5. Neue Berufsgruppierung

denen Top-1-Ursprungs- bzw. Zielberufe samt der Häufigkeit, wie oft sie Top-1 sind, aufgelistet. Als Erstes fällt auf, dass beide Listen relativ kurz sind. Die Liste der Top-1-Ursprungsberufe umfasst 77 verschiedene Berufe und die der Top-1-Zielberufe nur 83. Es gibt 63 Überschneidungen zwischen den Listen. Doch sehr viel wichtiger ist die Tatsache, dass es drei Berufe bzw. Berufscodes gibt, die sehr häufig Top-1 sind: Bürofachkräfte (781), Hilfsarbeiter ohne Angabe (531) und Verkäufer (682). Werden disjunkte Gruppen gebildet, indem jeder Beruf mit seinem Top-1-Ursprungsberuf und seinem Top-1-Zielberuf zusammengelegt wird, erhält man nur sehr wenige Gruppen.

Eine andere Möglichkeit der Gruppierung besteht darin, Zweierpaare zu finden, bei denen beide Berufe jeweils das Top-1-Ziel des anderen sind. Auf diese Art ergeben sich nur 11 Zweierpaare, siehe Tabelle A.16 auf Seite 159. Wirklich zufriedenstellend ist dies auch nicht, da die Anzahl der Berufe nur von 342 auf 331 reduziert wird. Außerdem werden Bürofachkräfte und Verkäufer zusammengelegt. Dies sind beides jedoch so große Berufe, dass eher überprüft werden sollte, ob sie nach Bildungsabschlüssen aufgeteilt werden könnten.

Im Folgenden wird die Sichtweise der Zielberufe beibehalten. Da sich jedoch nur sehr wenige Berufspaare finden lassen, die gegenseitig Top-1-Zielberufe sind, wird der Ähnlichkeitsrang (ÄR) als Ähnlichkeitskriterium eingeführt:

$$\text{ÄR eines Berufspaares} = \text{Summe der Platzierungen unter den jeweiligen Top-Zielberufen minus eins}$$

Ein ÄR von 1 ergibt sich für ein Berufspaar, bei dem die beiden Berufe der Top-1-Zielberuf des jeweils anderen sind. Ist einer der beiden Berufe Top-1- und der andere Top-2-Zielberuf, ergibt sich für dieses Berufspaar ein ÄR von 2. Ab einem ÄR von 4 ist es möglich, dass ein Beruf denselben ÄR mit zwei verschiedenen Berufen erhält. In diesem Fall wird zusätzlich für beide Paare die Summe der relativen Wechselraten berechnet, um eine Rangfolge der Paare herzustellen.

5.3. Homogenität hinsichtlich der Bildungsabschlüsse

Im Hinblick auf die inhaltliche Aussagekraft der Projektionen sowie die Prognostizierbarkeit ist es wünschenswert, Berufe zu gruppieren, deren Beschäftigte möglichst alle denselben Bildungsabschluss haben. Für Berufe, in denen extrem viele

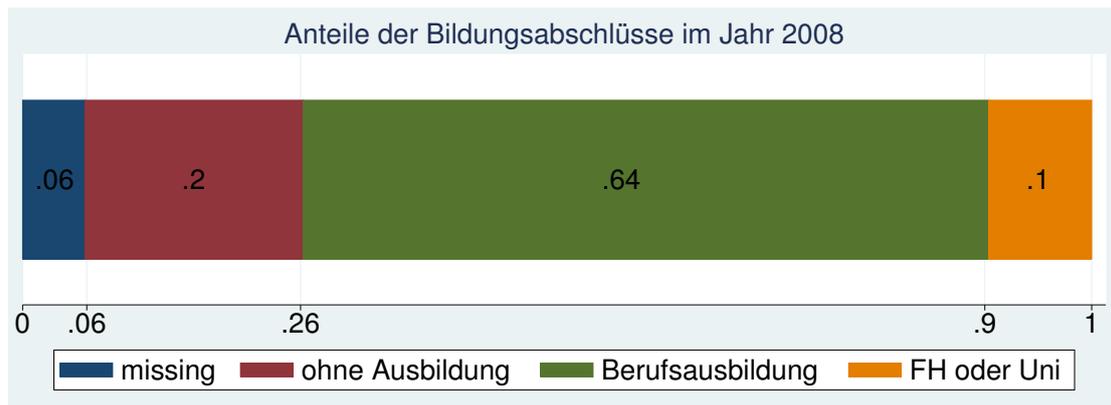


Abbildung 5.4.: Verteilung der Bildungsabschlüsse – insgesamt

Beschäftigte gemeldet sind, bedeutet dies, dass nach Bildungsabschlüssen aufgesplittet wird. Für Berufe mit nur wenigen Beschäftigten ist dies jedoch nicht möglich. Daraus folgend wird die Ähnlichkeitsprüfung jedoch um den Aspekt der Bildungsverteilung erweitert. Nur bei einer ähnlichen Verteilung der Bildungsabschlüsse innerhalb der zu aggregierenden Berufe werden diese zusammengefasst. Eine stark unterschiedliche Bildungsverteilung deutet auf stark unterschiedliche Qualifikationsanforderungen hin, was dazu führt, dass die Berufe nicht zusammengefasst werden.

Ein erster Blick gilt der globalen Verteilung des Merkmals Bildungsabschluss. In Abbildung 5.4 sind die jeweiligen Anteile der Bildungsabschlüsse für alle Beschäftigten aus dem Jahr 2008 dargestellt.⁶ Es werden nur drei Kategorien unterschieden: ohne Berufsausbildung (ca. 20 %), mit Berufsausbildung (ca. 64 %) und mit FH- oder Uni-Abschluss (ca. 10 %). Für ca. 6 % der Beschäftigten fehlt die Angabe zum Bildungsabschluss.

Innerhalb eines Berufes kann die Verteilung ganz anders aussehen. In Abbildung 5.5 auf der nächsten Seite ist dies exemplarisch für fünf Berufe dargestellt. Zum Beispiel sollten alle Ärzte und die meisten Hochschullehrer einen Uni-Abschluss haben. Aufgrund von Fehlmeldungen⁷ liegt der Anteil jedoch nur bei ca. 95 % bzw. 47 %. Bei typischen Ausbildungsberufen wird hingegen ein sehr großer Anteil an Beschäftigten mit eben einer solchen Ausbildung erwartet, bei

⁶Diese Abbildung und alle weiteren in diesem Abschnitt enthaltenen Abbildungen sind mit bildungsverteilung-analysieren.do erstellt worden.

⁷Es sind verschiedene Ansätze entwickelt worden, um diese Fehlmeldungen zu identifizieren und/oder zu korrigieren, vgl. Drews (2006). Die Bildungsvariable, die uns vorliegt, ist am IAB imputiert worden; fehlende Angaben sind rekursiv durch die Werte aus den Nachbarjahren ersetzt.

5. Neue Berufsgruppierung

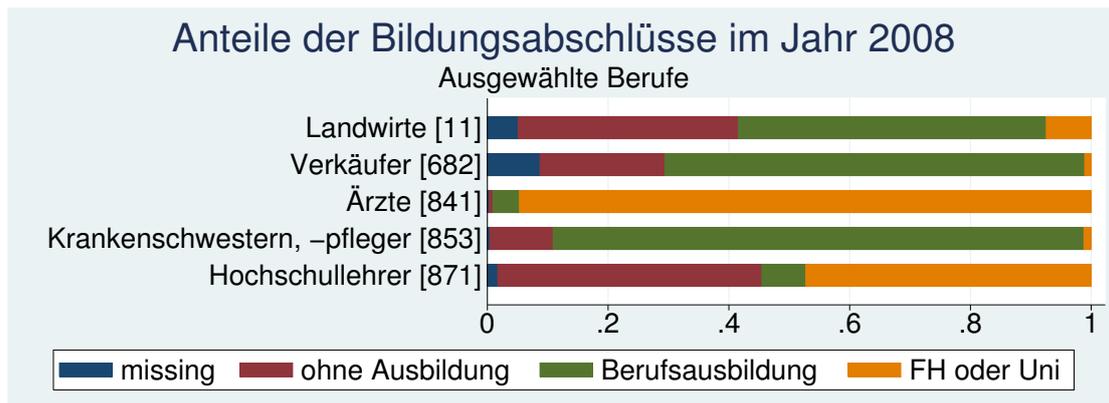


Abbildung 5.5.: Verteilung der Bildungsabschlüsse – 5 Berufe

z. B. KrankenpflegerInnen ist dieser Anteil ca. 88 %.

Um einen Eindruck davon zu gewinnen, wie stark die Anteile der drei Bildungsniveaus über die Berufe hinweg schwanken, sind diese, und auch die Kategorie der fehlenden Angaben zu diesem Merkmal, in Abbildung A.85 auf Seite 255 in Boxplots dargestellt. Für alle drei Bildungsabschlüsse ist die Bandbreite der Anteile sehr groß. Betrachtet man z. B. die Verteilung für die Anteile der FH- und Uni-Abschlüsse, erkennt man, dass es sehr viele Berufe gibt, in denen diese kaum vertreten sind. Jedoch gibt es einige Berufe, in denen diese sogar mehrheitlich vorhanden sind.

Der erste Eindruck ist also, dass es nur wenige Berufe gibt, in denen die Beschäftigten sehr homogen bezüglich des Bildungsabschlusses sind. Noch einmal zur Erinnerung: Ein Beruf ist homogen, wenn alle Beschäftigten denselben Bildungsabschluss haben. Um dies weiter zu überprüfen, werden die Daten für alle 341 Berufe wie in Tabelle 5.4 angeordnet. In Abbildung A.86 auf Seite 255 sind Boxplots der 4 Spalten Top-1 bis Top-4 zu finden. An der Verteilung der Top-1-Anteile ist zu erkennen, dass für ca. drei Viertel der Berufe der Anteil des häufigsten

Tabelle 5.4.: Datenanordnung für Abbildung A.86

Beruf	Anteil des Bildungsabschlusses in Prozent (%)			
	Top-1	Top-2	Top-3	Top-4
Landwirte	51 % mit Ausb.	36 % ohne Ausb.	8 % FH/Uni	5 % miss
Verkäufer	69 % mit Ausb.	21 % ohne Ausb.	9 % miss	1 % FH/Uni
Ärzte	95 % FH/Uni	4 % mit Ausb.	1 % ohne Ausb.	0 % miss
⋮	⋮	⋮	⋮	⋮

Bildungsabschlusses unter ca. 76 % liegt. Abschließend ist festzuhalten, dass viele Berufe hinsichtlich der Bildungsabschlüsse der Beschäftigten sehr heterogen sind.

Es geht jedoch nicht vorrangig darum, die Berufe auf ihre innere Homogenität zu untersuchen, sondern vielmehr darum, die Bildungsverteilung von zwei verschiedenen Berufen miteinander zu vergleichen. Ziel ist es, nur Berufe mit ähnlichen Bildungsverteilungen zu aggregieren. An dieser Stelle wird als Kriterium ausschließlich der Top-1-Bildungsabschluss betrachtet.

5.4. Aggregation der Berufsklassifikation

Aus den bisherigen Überlegungen ist ersichtlich, dass die Aggregation der 3-Steller sowohl über das Kriterium der Ähnlichkeit als auch über das Kriterium der Homogenität erfolgen sollte. Weiterhin ist offensichtlich, dass die Aggregation maßgeblich von der Reihenfolge des Vorgehens abhängen kann. In diesem Sinne ist es nicht möglich, ein objektiv unangreifbares und automatisiert implementierbares Vorgehen zu entwickeln.

Die Aggregation separat für jedes Bundesland durchzuführen, hat Konsequenzen für die anschließende Modellierung. Auf diese Weise werden Berufe gebildet, die nur in einem oder wenigen Bundesländern existieren. Wenn Prognosen auf verschiedenen regionalen Aggregationsniveaus verknüpft werden sollen, führt eine regionale Berufsklassifikation zu weiteren Komplikationen, insbesondere, da die Agenturbezirke nicht bundeslandscharf sind.

Als praktikabler Weg wird daher der folgende vierstufige Ablauf vorgeschlagen:

- In Stufe 1 werden extrem große Berufe nach Bildungsabschlüssen aufgesplittet. Ein Aufsplitten erfolgt jedoch nur, falls die resultierenden regionalen Zellenbesetzungen groß genug sind.
- In Stufe 2 werden Berufspaare aufgrund ihres Ähnlichkeitsranges (ÄR) gebildet, die als Aggregationskandidaten herangezogen werden. Bei nicht disjunkten Paaren desselben ÄR wird zusätzlich nach der jeweiligen Summe der relativen Wechselraten sortiert.
- In Stufe 3 wird die Validität der aus Stufe 2 resultierenden Paare mit dem Kriterium der Homogenität, d. h. in beiden Berufen identischer Top-1-Bildungsabschluss geprüft.⁸

⁸Basierend auf der jeweiligen Verteilung des Merkmals Bildungsabschluss der Berufe könnten

5. Neue Berufsgruppierung

- In Stufe 4 wird geprüft, ob ein homogenes Paar in den zurückliegenden Jahren einen ähnlichen – im Sinne positiver Korrelationen – Entwicklungspfad durchlaufen hat⁹. Ist dies der Fall, wird das Paar aggregiert.

Die Stufen 2, 3 und 4 werden so lange iteriert, bis eine ausreichend starke Aggregation der Berufe gewährleistet ist oder sich keine Aggregationskandidaten mehr finden.

5.5. Implementation und Ergebnisse

Stufe 1: Große Berufe splitten Zuerst werden die großen Berufe nach der Bildung aufgesplittet. In Tabelle 5.5 sind die 10 größten Berufe, gemessen an der Anzahl an Vollzeitbeschäftigten im Jahr 2008, aufgelistet. In der zweiten Spalte ist die Anzahl der Beschäftigten in den jeweiligen Berufen zu finden. In der dritten Spalte steht die Anzahl an Agenturbezirken mit weniger als 300 Beschäftigten des jeweiligen Berufes. In den letzten vier Spalten sind die Anteile der Bildungsniveaus innerhalb der Berufe aufgelistet.¹⁰ Da die Bürofachkräfte mit 2,8 Millionen Vollzeitbeschäftigten sehr zahlreich sind, kann vermutet werden, dass ein Aufsplitten nach allen drei Bildungsniveaus zu regionalen Zellenbesetzungen führt, die ausrei-

auch weniger restriktive Kriterien eingesetzt werden.

⁹Das bedeutet, die Aggregation erfolgt nicht, wenn die Korrelation über einen festgelegten Zeitraum einen bestimmten Schwellenwert unterschreitet.

¹⁰Die Anteile beziehen sich auf alle Beschäftigten, nicht nur Vollzeitbeschäftigte.

Tabelle 5.5.: Die 10 größten Berufe im Jahr 2008 – Vollzeit

Beruf (Berufscode)	Beschäftigte insgesamt (Vollzeit)	Anzahl Regionen mit weniger als 300 Beschäftigten	Anteile der Bildungs- abschlüsse (jede Arbeitszeit)			
			(0)	(1)	(2)	(3)
(781) Bürofachkräfte	2.858.940	0	3	11	76	9
(682) Verkäufer	806.795	0	8	20	69	1
(714) Kraftfahrzeugführer	748.856	0	4	22	71	0
(531) Hilfsarbeiter ohne Ang.	543.017	0	9	42	47	0
(774) Datenverarbeitungsfach.	468.912	11	3	11	47	36
(681) Groß- und Einzelhandel	453.164	1	2	16	72	8
(744) Lager-, Transportarbei.	436.572	1	14	36	48	0
(691) Bankfachleute	433.032	1	0	8	79	11
(311) Elektroinstallateure,	426.448	0	1	13	83	0
(853) Krankenschwestern, -pf.	419.756	0	0	10	87	1

chend groß sind. Für die Verkäufer ist zu vermuten, dass eine Unterscheidung nur nach „qualifiziert“ (2),(3) und „unqualifiziert“ (0),(1) möglich ist, da der Anteil an Beschäftigten mit Hochschulabschluss mit nur einem Prozent sehr gering ist. Ähnliches gilt für die Kraftfahrzeugführer und die Hilfsarbeiter ohne Angabe. Bei den Datenverarbeitungsfachleuten scheint aufgrund der Bildungsverteilung eine Unterscheidung zwischen allen drei Bildungsniveaus, oder zumindest eine Differenzierung zwischen hoch qualifiziert und andere Qualifikation, sinnvoll. Da jedoch in 11 Agenturbezirken die Anzahl der Beschäftigten unter 300 liegt, ist zu vermuten, dass die regionalen Zellenbesetzungen nach dem Aufsplitten zu gering sein werden.

Für die Berufe aus Tabelle 5.5 ist getrennt nach Bildungsniveau ausgezählt worden, in wie vielen Agenturbezirken weniger als 20 Beschäftigte im Jahr 2008 gemeldet waren. Die Ergebnisse sind in Tabelle 5.6 zu finden. Wie vermutet, lassen sich die Bürofachleute (781) nach allen drei Bildungsniveaus aufsplitten, ohne dass es zu Zellenbesetzungen mit weniger als 20 Beschäftigten kommt. Für Verkäufer (682), Kraftfahrzeugführer (714) und Hilfsarbeiter ohne Angabe (531) spricht, wie vermutet, nichts gegen eine Unterscheidung nach „unqualifiziert“ (0),(1) und „qualifiziert“ (2),(3). Bei den Datenverarbeitungsfachleuten (774) scheint eine Unterscheidung nach hoch qualifiziert (3) und übrige (0),(1),(2) möglich.

Aufgrund der Tatsache, dass die Projektionen auch für Teilzeitbeschäftigte erstellt werden und eine einheitliche Berufsgruppierung, d. h. dieselbe Berufsgruppierung für Vollzeit und Teilzeitbeschäftigte, angestrebt wird, muss überprüft wer-

Tabelle 5.6.: Regionen mit weniger als 20 Beschäftigten – Vollzeit – Die 10 größten Berufe

Beruf	Anzahl an Regionen mit weniger als 20 Beschäftigten getrennt nach Bildungsabschlüssen bzw. deren Kombinationen							
	NA (0)	ohne (1)	mit (2)	FH-Uni (3)	(0),(1),(2)	(0),(1)	(2),(3)	(0),(1),(3)
(781)	0	0	0	0	0	0	0	0
(682)	0	0	0	23	0	0	0	0
(714)	5	0	0	129	0	0	0	0
(531)	1	0	0	120	0	0	0	0
(774)	54	6	0	0	0	2	0	0
(681)	35	0	0	1	0	0	0	0
(744)	13	0	0	119	0	0	0	0
(691)	111	1	0	11	0	1	0	0
(311)	58	0	0	103	0	0	0	0
(853)	140	0	0	95	0	0	0	0

5. Neue Berufsgruppierung

den, ob die Zellenbesetzungen bei den Teilzeitbeschäftigten auch ausreichend groß sind.

Analog zu Tabelle 5.6 sind in Tabelle A.17 auf Seite 160 die Anzahlen der Regionen mit weniger als 20 Beschäftigten für die 24 größten Berufe¹¹, gemessen an Teilzeitbeschäftigten, angegeben. Es werden nur Bürofachkräfte und Verkäufer wie vorgeschlagen gesplittet, da für die anderen Berufe die regionalen Zellenbesetzungen bei den Teilzeitbeschäftigten zu schwach sind.

Stufen 2–4: Algorithmus, um Berufe zu aggregieren Der Aggregationsalgorithmus besteht aus den Stufen 2, 3 und 4:

Stufe 2: Berufspaare aufgrund der Berufswechsel bestimmen und in eine Reihenfolge bringen (ÄR und Summe der relativen Wechselraten)
⇒ Kandidatenpaare

Stufe 3: Kandidatenpaare hinsichtlich des Bildungsniveaus prüfen

Stufe 4: Verbleibende Kandidatenpaare der Korrelationsprüfung unterziehen

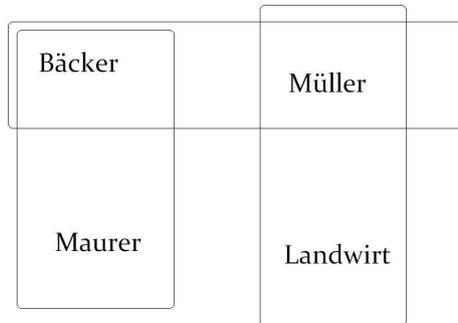
Im Folgenden wird die Implementation im Detail erklärt und begründet. Ein Problem, das sich ergibt, wenn Paare durch die Verwendung des Ähnlichkeitsranges bestimmt werden, ist, dass es zu nicht disjunkten Paaren mit demselben ÄR kommt, sobald ein ÄR von 2 oder schlechter zugelassen wird. Illustriert wird dies anhand zwei fiktiver Beispiele mit je vier Berufen: Bäcker, Müller, Landwirte und Maurer.

Eine mögliche Situation ist die Bildung von Kettenclustern. In Tabelle 5.7 auf der nächsten Seite sind die fiktiven Top-Zielpositionen und die entsprechenden Ähnlichkeitsränge für die Berufspaare eingetragen. Die erste Zeile der Tabelle besagt, dass der Beruf Bäcker der Top-3-Zielberuf für die Müller ist und dass der Beruf Müller der Top-1-Zielberuf für die Bäcker ist. Bäcker & Müller werden also zusammengefasst. Ebenso werden Bäcker & Maurer und Müller & Landwirte zusammengefasst. Die Abbildung unter der Tabelle zeigt das resultierende Kettencluster. Bei der Bildung solcher Kettencluster werden Berufe zusammengelegt, ohne Information darüber, wie ähnlich sich diese sind. Hier im Beispiel sind das die Berufe Maurer und Landwirt.

¹¹Die Datenverarbeitungsfachleute (774) sind erst an 24-ter Stelle bei den Teilzeitbeschäftigten.

Tabelle 5.7.: Nicht disjunkte Paare - Kettencluster

Beruf	Beruf	Top-Ziel-Positionen	Ähnlichkeits-rang
Bäcker	Müller	3,1	3
Bäcker	Maurer	2,2	3
Landwirt	Müller	1,3	3

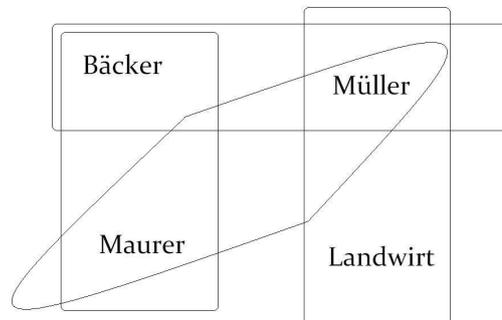


Anstatt Kettencluster können sich auch Dreieckscluster bilden, siehe Tabelle 5.8 und die dazugehörige Abbildung. Im Gegensatz zu dem Beispiel in Tabelle 5.7 ist hier zusätzlich angenommen worden, dass Maurer & Müller einen ÄR von 3 haben und somit auch zusammengefasst werden. Die Berufe Maurer, Bäcker und Müller bilden hier ein Dreieckscluster.

Es sind verschiedene Möglichkeiten denkbar, wie mit solchen Clustern umge-

Tabelle 5.8.: Nicht disjunkte Paare - Dreieckscluster

Beruf	Beruf	Top-Ziel-Positionen	Ähnlichkeits-rang
Bäcker	Müller	3,1	3
Bäcker	Maurer	2,2	3
Landwirt	Müller	1,3	3
Maurer	Müller	2,2	3



5. Neue Berufsgruppierung

gangen wird. Bei Kettenclustern ist eine Prüfung der Ähnlichkeit zwischen den einzelnen Berufen innerhalb einer solchen Kette notwendig, bevor die Berufe des Clusters aggregiert werden können. Bei Dreiecksclustern mag es recht einleuchtend sein, dass alle drei Berufe zusammenpassen. Kritisch ist jedoch, dass die Müller in ein Cluster mit Bäckern und Maurern gesteckt werden, obwohl ihr Top-1-Zielberuf die Landwirte sind.

Es sind verschiedene Kriterien zum Umgang mit Clustern denkbar. Aufgrund der Tatsache, dass die Clustergröße und -zusammensetzung stark variieren kann, müsste eine entsprechende Prüfung sehr flexibel und umfassend sein. Diese Komplexität schlägt sich natürlich auch auf die Implementation nieder. Daher wird festgelegt, solche Cluster nicht bestehen zu lassen, sondern letztendlich nur ein Paar zu aggregieren. Das bedeutet, dass zunächst ignoriert wird, dass die Kandidatenpaare nicht disjunkt sind. Erst nach dem Ende eines Durchlaufes der Stufen 2, 3 und 4 wird das Paar mit der größten Summe an gegenseitigen relativen Wechselraten aggregiert. Nach jeder erfolgreichen Aggregation von zwei Berufen wird die Liste der verbleibenden Kandidatenpaare darauf geprüft, ob einer der eben aggregierten Berufe enthalten ist. Ist dies der Fall, wird das Kandidatenpaar verworfen und nicht aggregiert.

Die Prüfung hinsichtlich der Bildung auf Stufe 2 gestaltet sich als sehr einfach. Für jedes Kandidatenpaar wird das Top-1-Bildungsniveau abgefragt und bei unterschiedlichem Ergebnis wird das Kandidatenpaar verworfen, d. h. von der Liste gestrichen.

Auf Stufe 3 wird für die verbleibenden Kandidaten die Korrelation für den Zeitraum von 2000 bis 2008 berechnet. Es wird nicht die gesamte Zeitreihe verwendet, da bei der Projektion aktuelle Entwicklungen von größerer Bedeutung sind. Erst wenn die Korrelation größer gleich 0,1 ist, wird das Kandidatenpaar zur Aggregation freigegeben.

Die zur Aggregation freigegebenen Kandidatenpaare werden nun wieder nach dem ÄR und der Summe der relativen Wechselraten sortiert und dann schrittweise aggregiert. Begonnen wird mit dem stärksten ÄR und der größten Summe.

Nachdem einmal die Stufen 2 bis 4 durchgelaufen sind und einige 3-Steller aggregiert wurden, startet ein neuer Durchlauf mit Stufe 2. Hierbei werden die aggregierten Berufe mit berücksichtigt. Dies bedeutet, dass die Tabelle der Berufswechsel, der Bildungsverteilung und die korrespondierenden Zeitreihen angepasst

werden müssen.¹² Drei Gründe dafür, die aggregierten Paare wieder mit in die Ähnlichkeitsprüfung aufzunehmen, sind:

- Die Information der Cluster wird auf diese Art indirekt mitgenutzt.
- Würden die aggregierten Paare herausgenommen und die Top-Ziele neu berechnet, würden Ähnlichkeiten erzeugt, die nicht dem tatsächlichen ÄR entsprechen.
- Würden die aggregierten Paare herausgenommen, würden wahrscheinlich nur wenige Berufe aggregiert.

Ergebnisse Als Erstes werden die beiden beschäftigungsstärksten Berufe gesplittet. Die Bürofachkräfte (781) werden nach Bildungsabschluss in drei Gruppen aufgeteilt, die Verkäufer (682) in zwei Gruppen, siehe Tabelle A.18 auf Seite 161. Die übrigen 339 3-Steller werden darauf geprüft, welche von ihnen aggregiert werden können. Nach Ausführen des Algorithmus mit verschiedenen Ähnlichkeitsrängen ist als Grenze ein ÄR von 5 gesetzt worden. Nach 13 Durchläufen werden keine Kandidatenpaare mehr gefunden, die aggregiert werden können. Insgesamt werden 130 Berufe (3-Steller) zu 36 Gruppen aggregiert. Die Zuordnung von 3-Stellern zu den neuen Berufsgruppen ist in Tabelle A.19 auf Seite 161 zu finden. Die übrigen 209 Berufe lassen sich nicht aggregieren und behalten ihren 3-Steller-Code. Ein Problem ist die Bildung einer Berufsgruppe, die aus 35 3-Steller-Berufen besteht (neuer Berufscode (1097)). Es besteht die Möglichkeit, dass nicht alle dieser 35 3-Steller ähnlich genug sind, um aus inhaltlicher Sicht aggregiert zu werden.

Diese große Berufsgruppe ist aufgrund der Berufsbezeichnungen und Wechselraten der enthaltenen 3-Steller manuell aufgesplittet worden.¹³ In Tabelle A.20 auf Seite 161 sind die 9 resultierenden kleineren Berufsgruppen aufgelistet. Insgesamt kommt man somit auf 44 neue Berufsgruppen, 5 neue aufgesplittete Berufe und 211 3-Steller in dem neuen Aggregationsschema.

Möchte man die Anzahl an Berufen insgesamt weiter reduzieren, bleiben zwei Möglichkeiten. Entweder wird das Ähnlichkeitskriterium abgeschwächt oder es werden kleine 3-Steller-Berufe aus der Betrachtung herausgenommen. Wird ein ÄR von 6 zugelassen, so ergeben sich 239 Berufe, davon 203 3-Steller. Je weiter

¹²Dabei wird auch eine .do-Datei erstellt bzw. angepasst, in welcher das Label für die neue Berufsklassifikation gespeichert ist. Die Datei heißt `define-label-b2a.do` und ist in dem Ordner `prog/labels` gespeichert.

¹³Siehe `riesen-Berufscluster-splitten.do`.

5. Neue Berufsgruppierung

jedoch der ÄR abgeschwächt wird, desto weiter verstärkt sich auch das Problem mit der Gruppe, die aus vielen 3-Stellern besteht. Beim ÄR von 6 sind es schon 38 3-Steller, die in eine Gruppe kommen. Bei einem ÄR von 7 erhält man 198 Berufe (davon 173 3-Steller) und eine Gruppe, bestehend aus 84 3-Stellern. Es zeigt sich, dass ein Abschwächen des Ähnlichkeitskriteriums nur sinnvoll ist, wenn gleichzeitig der Algorithmus so angepasst wird, dass die Bildung einer Gruppe, bestehend aus sehr vielen 3-Stellern, verhindert wird. Für die Zwecke des Forschungsprojekts ist in Absprache mit dem Projektbetreuer am IAB vereinbart worden, das eben präsentierte Schema für einen ÄR von 5 zu verwenden. Im Weiteren wird dieses Berufsschema mit Jones-Berufe bezeichnet.

Die andere Alternative, die Gesamtzahl der Berufe zu verringern, besteht darin, einige Berufe mit extrem geringen Beschäftigtenzahlen aus der Betrachtung herauszulassen. Nimmt man ein Prozent der Beschäftigten aus dem Projektionsmodell heraus, lässt sich die Anzahl der Berufe um 90 verringern. Bei zwei Prozent sind es 123 Berufe weniger und bei drei Prozent 144 weniger.¹⁴ Die zwei Hauptgründe für das Aggregieren sind zum einen, stabilere Zeitreihen zu erhalten, und zum anderen, schwach besetzte Zellen auf regionaler Ebene zu vermeiden. Ein Löschen der kleinen Berufe kann mit der Vermutung begründet werden, dass die Zeitreihen auf regionaler Ebene in den Zähldatenbereich gehen, d. h., dass sich die Beschäftigtenzahlen im einstelligen oder niedrigen zweistelligen Bereich bewegen. Für jede Zeitreihe auf Ebene der Jones-Berufe und Arbeitsagenturen ist die minimale Beschäftigtenzahl für den Zeitraum von 1993 bis 2008 bestimmt worden. An der Abbildung 5.6 auf der nächsten Seite ist zu erkennen, dass nur für 52,2 % der $176 \times 260 = 45.760$ Berufe-Regionen-Kombinationen die Anzahl der Vollzeitbeschäftigten konstant über 30 liegen.¹⁵ Löscht man die 144 kleinen Berufe (gemeinsamer Anteil an der Gesamtbeschäftigung kleiner 3 %), reduziert sich der Anteil an Zeitreihen im Zähldatenbereich lediglich auf 16 % (Summe aus 2,5 % in Kategorie 0, 4,7 % in Kategorie 1–10 und 8,8 % in Kategorie 11–30), siehe Abbildung 5.6. Bei den Beschäftigten in Großer Teilzeit ist der Anteil an Zeitreihen mit kleinem Wertebereich noch viel größer. Anstatt kleine Berufe im Ganzen aus dem Projektionsmodell auszuschließen, werden kleine Zeitreihen separat auf Grundlage des Random-Walk-Modells fortgeschrieben. Mehr Details zu diesem Modell und den anderen verwendeten Methoden und Modellen folgen im nächsten Kapitel.

¹⁴Berechnung anhand der Beschäftigtenzahlen des Jahres 2008 auf Ebene der 3-Steller, siehe [anteil-der-kleinen-3-Steller-2008.do](#).

¹⁵Abbildung erstellt mit [anz-kleine-zellen-b2a.do](#)

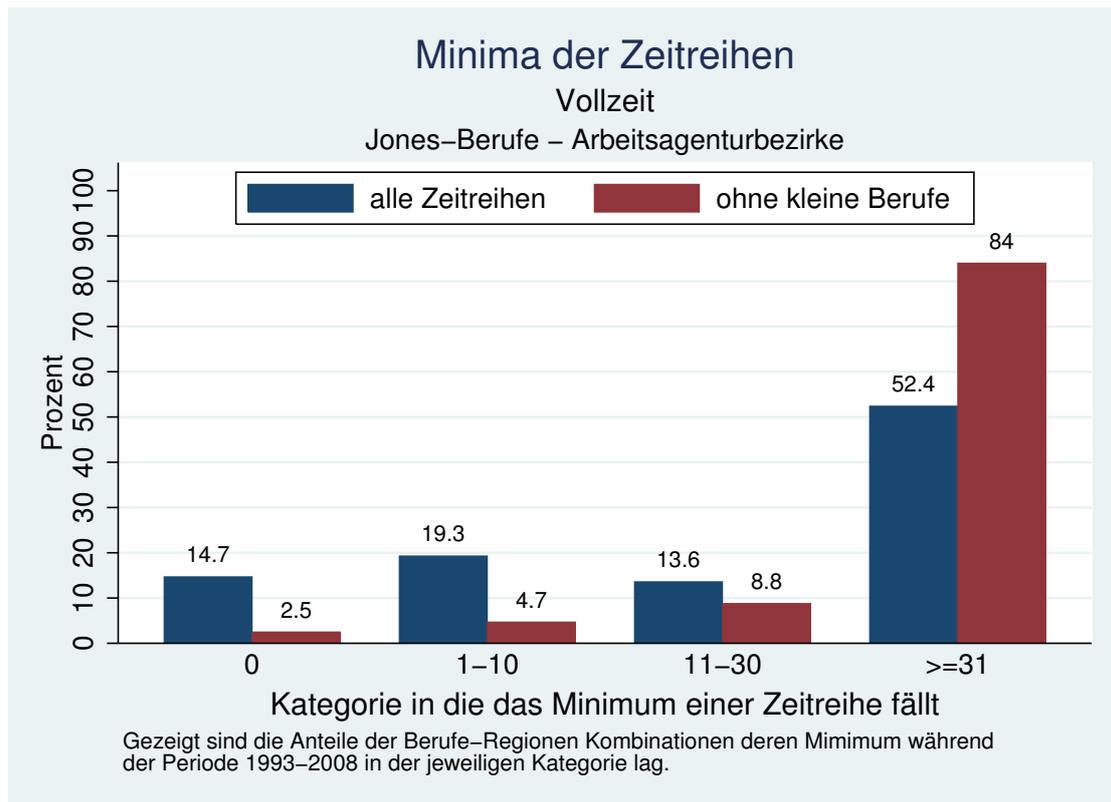


Abbildung 5.6.: Minima der Zeitreihen auf Ebene der Jones-Berufe und Arbeitsagenturbezirke

6. Methoden und Modelle

6.1. Literatur zu Arbeitsmarktprognosen¹

Seit mindestens einem halben Jahrhundert werden nach Berufen differenzierte Beschäftigtenprognosen erstellt bzw. sind diese Gegenstand der Forschung. Der in den 1960er-Jahren entwickelte Arbeitskräfte-Bedarf-Ansatz beinhaltet unter anderem die Prognosen der Beschäftigtenzahlen differenziert nach Berufen, vgl. Parnes (1962). Dort wird als Haupteinflussfaktor des Beschäftigungswachstums der Berufe das unterschiedliche Wachstum der einzelnen Industrien gewählt. Diese Sichtweise findet sich heutzutage z. B. bei den für Arbeitsmarktprognosen zuständigen Ämtern in den USA, Kanada und den Niederlanden wieder, vgl. Bureau of Labor Statistics (1997), Smith (2002) und Cörvers et al. (2002). In allen drei Ländern beruhen die Beschäftigtenprognosen auf Makro-Modellen der gesamten Wirtschaft.

In den USA und Kanada wird zuerst die Schätzung des BIP-Wachstums nach Industrien disaggregiert, um daraus die zukünftige Beschäftigung innerhalb der Industrien zu ermitteln. Am *Bureau of Labor Statistics* in den USA werden Beschäftigtenprognosen für 250 Industriezweige erstellt. Um das Vorgehen zu veranschaulichen, werden 2 Industriezweige mit 1000 und 1600 Beschäftigten unterschieden und in dem Zeilenvektor \mathbf{I} notiert: $\mathbf{I} = \begin{pmatrix} 1000 & 1600 \end{pmatrix}$. Diese werden dann mittels einer Industrie-Berufe-Matrix \mathbf{V} für einen festen Zeitpunkt nach folgendem Schema auf die Berufe B_1 , B_2 und B_3 verteilt:

$$\underbrace{\begin{pmatrix} I_1 & I_2 \\ 1000 & 1600 \end{pmatrix}}_{\mathbf{I}} \times \underbrace{\begin{matrix} B_1 & B_2 & B_3 \\ I_1 \begin{pmatrix} 0,1 & 0,4 & 0,5 \\ I_2 \begin{pmatrix} 0,6 & 0 & 0,4 \end{pmatrix} \end{matrix} \\ \mathbf{V} \end{matrix}}_{\mathbf{V}} = \underbrace{\begin{pmatrix} B_1 & B_2 & B_3 \\ 1060 & 400 & 1040 \end{pmatrix}}_{\mathbf{B}} \quad (6.1)$$

¹Dieser Abschnitt beruht auf Kapitel 2 meiner Diplomarbeit „Beschäftigtenprognosen differenziert nach Berufen und Regionen“, vorgelegt an der Fakultät für Wirtschaftswissenschaften an der Universität Bielefeld.

Jede Zeile der Industrie-Berufe-Matrix \mathbf{V} enthält die erwartete Verteilung der Berufe innerhalb der jeweiligen Industrie. Die Zeilensummen von \mathbf{V} müssen immer 1 ergeben. Somit sind in dem Vektor \mathbf{B} die erwarteten Beschäftigtenzahlen der einzelnen Berufe aufgeführt. Bei der Konstruktion der Industrie-Berufe-Matrix \mathbf{V} werden Trends für die Verschiebung der Berufe-Verteilungen berücksichtigt und durch Analysen der zugrunde liegenden Faktoren und Expertenwissen korrigiert². Das Vorgehen in Kanada ist ähnlich, vgl. Smith (2002). Dort werden die Einträge der Industrie-Berufe-Matrix \mathbf{V} mit Hilfe eines einfachen Regressionsmodells prognostiziert. Anstatt wie im Beispiel nur zwischen 3 Berufen, wird zwischen mehreren hundert Berufen unterschieden.

Einem ähnlichen Ansatz folgend, wird in den Niederlanden³ jedoch methodisch anders gearbeitet. Wie von Parnes (1962) vorgeschlagen, ist auch dort die Prognose der Beschäftigtenzahlen je Industrie Ausgangspunkt für die Schätzungen der Beschäftigtenzahlen pro Beruf. Dabei wird jedoch die Wachstumsrate für jeden Beruf je Industrie mit einem *Random-Coefficients*-Modell geschätzt. Cörvers et al. (2002) spezifizieren folgendes Modell:

$$\dot{a}_t^{bi} = \dot{a}_t^i + \mathbf{X}_t^i \boldsymbol{\beta}^{bi} + \epsilon_t^{bi} \quad (6.2)$$

mit \dot{a}_t^{bi} als Wachstumsrate von Beruf b in Industrie i zur Periode t , \dot{a}_t^i als Wachstumsrate der Gesamtbeschäftigung in Industrie i , \mathbf{X}_t^i als erklärende Variablen, unter denen auch ein Trendfaktor ist und ϵ_t^{bi} als Störterm⁴. Wie an (6.2) erkennbar, wird angenommen, dass die Parameter $\boldsymbol{\beta}^{bi}$ für jeden Beruf und jede Industrie verschieden sind, sich aber im Laufe der Zeit nicht ändern. Ohne weitere Annahmen würde für jeden Beruf in jeder Industrie ein eigener Parametervektor $\boldsymbol{\beta}^{bi}$ geschätzt werden, d. h., je mehr Berufe man unterscheidet, desto mehr Freiheitsgrade gehen verloren. In Anlehnung an Swamy (1970) wird dieses Problem durch die Annahme umgangen, dass die Parametervektoren zufällig um einen gemeinsamen Mittelwert verteilt liegen. Damit die Prognosen konsistent mit der Prognose für die Gesamtbeschäftigung sind, wird zusätzlich die Annahme getroffen, dass dieser Mittelwert gleich Null ist, vgl. Borghans und Heijke (1994). Somit werden

²Es ist anzumerken, dass Selbstständige bei diesen Berechnungen nicht mit einbezogen, sondern separate Schätzungen für diese Gruppe erstellt werden.

³Damit ist die Arbeit am Research Center for Education and the Labour Market (ROA) gemeint.

⁴Im Unterschied zu ihrer Notation ist in (6.2) der Zeitindex t hinzugefügt.

die Parameter, als stochastisch einer Normalverteilung folgend modelliert:

$$\beta^{bi} \sim N(\mathbf{0}, \Sigma^i), \quad (6.3)$$

mit Σ^i als Varianz-Kovarianz-Matrix. Eine ausführliche Beschreibung des Modells ist in Borghans und Heijke (1994) zu finden.

Einer der Hauptgründe für die Erstellung solcher Prognosen ist die Informationsbereitstellung. Die Nutzer solcher Informationen sind EntscheidungsträgerInnen in der Politik und in den Personalabteilungen von Unternehmen, SchülerInnen, die vor der Berufswahl stehen, aber auch z. B. Arbeitssuchende, die sich für eine Umschulung entscheiden, um ihre Berufschancen zu verbessern. Besonders für diese individuellen Entscheidungen sind räumlich disaggregierte Informationen sehr viel hilfreicher als die Angabe aggregierter Trends, denn „Was nutzt eine global gute Konjunktur, wenn jemand in einer Ecke der Republik festgehalten ist, die gerade eine Krise durchläuft?“, Blien et al. (2002, S. 293). In der deutschen Arbeitsmarktpolitik werden auch den regionalen Agenturbezirken zunehmend Entscheidungsbe-fugnisse übertragen. Daher ist das Ziel dieses Projektes nicht nur berufsspezifische Beschäftigtenprognosen zu liefern, sondern diese für relativ kleinräumige Regionen zu erstellen. In dieser Hinsicht sind die eben genannten Methoden nicht direkt anwendbar.

Eine etwas weiter zurückliegende Übersicht von Modellen zur regionalen Arbeitsmarktprognose gibt van der Laan (1996). Er betrachtet quantitative sowie qualitative Methoden, welche Prognosen für mehrere Regionen gleichzeitig liefern. Dabei liegt der Fokus auf „supply and demand models as such“ (S. 2105), die aber keine Interaktionen zwischen Angebot und Nachfrage betrachten. Van der Laan merkt jedoch an, dass sich die Methoden stark ähneln. Er unterscheidet fünf Klassen von Modellen, wobei verschiedene Methoden in mehreren Klassen zur Anwendung kommen.

1. Arbeitgeber-Umfragen:

Hierzu zählt er die klassische Befragung, welche die subjektiven Zukunftsaussichten der Arbeitgeber ermitteln sowie Input-Output-Modelle, die auf Umfragen basieren. Des Weiteren nennt er in dieser Kategorie die Methode der Frimographie, in der die Idee des Lebenszyklus aufgegriffen und auf Firmen angewandt wird. Dabei wird ein Zusammenhang zwischen Arbeits-

kräftenachfrage und den verschiedenen Phasen des Lebenszyklus hergestellt, um somit Rückschlüsse auf die künftige Entwicklung der Beschäftigung zu ziehen.

2. Modelle der evolutionären Entwicklung:

Die wirtschaftliche Entwicklung einer Region wird dabei als ein evolutionärer Prozess gesehen. Durch den Vergleich von zwei Regionen auf verschiedenen Entwicklungsstufen wird eine Prognose für die Entwicklung der Region auf der niedrigeren Stufe erstellt. Eine solche Methode ist schon bei Parnes (1962, S. 34) zu finden, um den zukünftigen Berufe-Mix innerhalb von Industrien zu schätzen. Die zugrunde liegende Annahme dieser Methode ist, dass wirtschaftliche Entwicklungen nach bestimmten Mustern verlaufen, so wie die biologische Evolution zwar zufällige Sprünge nehmen kann, aber innerhalb von Grenzen verläuft, die durch die Naturgesetze gegeben sind.

3. Mechanische Modelle:

Als mechanisch versteht van der Laan Modelle, welche Prognosen liefern, ohne eine Erklärung für diese zu geben, und teilt sie ein in „Trendanalyse“ und „Autoregressive Modelle“. Zu ersterer zählt er die *Shift-Share-Analyse* und die univariate Regression. Zu autoregressiven Modellen zählt er Modelle, die Prognosen ausschließlich auf Basis vergangener Daten der zu prognostizierenden Variable erstellen. Um solche Modelle anzuwenden, ist es wichtig, dass die Regionen möglichst homogen und nicht zu klein sind. Des Weiteren sollte die Zeitreihe nicht zu kurz sein. Jedoch wird nicht spezifiziert, was genau darunter zu verstehen ist.

Seitz (1996) erstellt regionale Beschäftigungsprognosen für die neuen Bundesländer. Die Zeitreihen umfassen nur 10 Beobachtungen und werden von ihm als zu kurz angesehen, um Methoden der Zeitreihenökonomie anzuwenden. Jedoch ist es sehr schwer, Faustregeln zu finden, ab wann eine Zeitreihe zu kurz ist.

4. Ökonometrische Modelle:

Ökonometrie ist eine Kombination von ökonomischer Theorie und statistischer Analyse, vgl. Allen und Fildes (2003, S. 304). Demnach wird bei der Spezifikation der ökonometrischen Modelle die Theorie zu Rate gezogen. Genau dieses macht nach van der Laan die Attraktivität dieser Modelle aus, da

die Ergebnisse den Eindruck vermitteln, als wären sie ökonomische Fakten. Gleichzeitig kritisiert er jedoch, dass die erklärenden Variablen schwer vorherzusagen sind und dass die Beziehungen meist statisch modelliert werden.

Allen und Fildes (2003) entwickeln einen Leitfaden für die Erstellung von Prognosen mithilfe von ökonometrischen Regressionsmodellen. Auf die beiden vorhin genannten Kritikpunkte wird insofern eingegangen, als die Auswahl der erklärenden Variablen zwar aus theoretischen Überlegungen erfolgt, jedoch die Wahl, welche Lags⁵ aufgenommen werden sollten, durch Ausprobieren festgelegt wird.

5. Kohorten-Modelle:

Bei der Kohorten-Analyse wird typischerweise eine Kohorte zu verschiedenen Zeitpunkten untersucht. Veränderungen werden dabei auf Faktoren, die nur in der Kohorte auftreten (Kohorten-Effekt), den Alterungsprozess (Alters-Effekt) und die Umstände bzw. besonderen Ereignisse zu dem Zeitpunkt der Untersuchung (Perioden-Effekt) zurückgeführt.

Einen aktuelleren Literaturüberblick geben Hampel et al. (2007). Sie betrachten ausschließlich quantitative Methoden und teilen die Ansätze zur regionalen Arbeitsmarktprognose in zwei grundsätzliche Klassen ein. Zum einen sind das Modelle/Methoden, die auf ökonomischer Theorie beruhen und zum anderen Modelle/Methoden, die in erster Linie mathematisch-statistische Werkzeuge nutzen. Als Beispiele für erstere nennen sie das nachfrageorientierte *Economic Base Concept*, die angebotsorientierte *Shift-Share-Analyse* sowie die Konzepte der *Labour Market Accounts* und der regionalen *Input-Output-Analyse*, welche Nachfrage- und Angebotsaspekte berücksichtigen. Zu den mathematisch-statistischen Methoden zählen sie die Regressions- und die Zeitreihenanalyse, den Ansatz neuronaler Netzwerke und die Methode der linearen Programmierung.

Eine andere Möglichkeit, Modelle zu klassifizieren, ist, zu unterscheiden, ob die regionalen Prognosen durch Disaggregation von nationalen Prognosen oder direkt erstellt werden. Mit direkt ist gemeint, ohne den „Umweg“ über die nationalen Prognosen. Dieser direkte Weg wird auch *Bottom-up* genannt und der Weg über die Disaggregation als *Top-down* bezeichnet. Die Bezeichnungen Bottom-up und

⁵Ein Lag bezeichnet den zeitlichen Abstand, mit welchem eine Variable in die Modellspezifikation aufgenommen wird. Wird z. B. angenommen, dass y von x und dem ersten Lag von x abhängt, könnte die Notation eines linearen Modells folgende sein: $y_t = \beta_1 x_t + \beta_2 x_{t-1} + \epsilon_t$.

Top-down sind dabei nicht beschränkt auf Modelle der regionalen Beschäftigungsprognosen, sondern werden auch in anderen Zusammenhängen gebraucht. Beide Ansätze haben ihre Vor- und Nachteile.

Ein Vorzug von Top-down liegt darin, dass nationale Prognosen der Gesamtbeschäftigung nicht so anfällig für zufällige Schwankungen sind wie Prognosen für sehr kleine Regionen, vgl. Cörvers und Hensen (2007, S. 6). Folgendes Beispiel veranschaulicht dies. Betrachtet wird eine sehr kleine Region, in der es zwei Lebensmittelgeschäfte gibt. Führt ein zufälliges Ereignis zur Schließung eines der Geschäfte, bedeutet dies einen Strukturbruch für die Region. Das Schließen dieses einen Geschäfts hat jedoch so gut wie keine messbaren Auswirkungen auf die nationale Handelslandschaft und stellt damit keinen Strukturbruch auf nationaler Ebene dar. Des Weiteren ist es möglich, dass ebenso zufällig in einer anderen Region ein Lebensmittelgeschäft eröffnet. Das Beispiel verdeutlicht, dass sich regionale zufällige Fluktuationen beim Aggregieren ausgleichen können. Ein weiterer praktischer Vorteil kann sein, dass eine Prognose der Gesamtbeschäftigung in vielen Ländern routinemäßig erstellt wird und somit einfach übernommen werden kann.

Der Nachteil dieser Herangehensweise liegt darin, dass regionale Informationen nicht genutzt werden. Genau hier setzt die Bottom-up-Methode an. Verschiedene Arbeiten verknüpfen beide Methoden, um die jeweiligen Stärken zu nutzen. Dangerfield und Morris (1992) geben zu Beginn ihres Artikels einige Literaturhinweise bezüglich der Diskussion zu den Vor- und Nachteilen der beiden Ansätze.

Im Folgenden werden Beispiele von Arbeiten gegeben, welche entweder dem Top-down, dem Bottom-up oder beiden Prinzipien folgen.

Top-down Die u. a. von Dunn (1960) entwickelte Shift-Share-Analyse wird häufig in der Regionalforschung angewandt und zählt zu den Top-down-Methoden, vgl. Tassinopoulos (1996). Sie erklärt die regionale Beschäftigungsentwicklung durch den Industrie-Mix der Region und nicht erfasste regional-spezifische Faktoren, wie z. B. einer guten Infrastruktur und dem damit verbundenen Wettbewerbsvorteil gegenüber anderen Regionen. Dunn nennt den Effekt des Industrie-Mixes *proportionality effect*. Hat nämlich eine Region überproportional viele „Boom“-Industrien, so wird auch ihre Beschäftigung, im Vergleich mit der Nation, überproportional wachsen. Die regional-spezifischen Faktoren, die Dunn als *differential effect* bezeichnet, werden in anderer Fachliteratur auch *competitive effect* genannt,

vgl. Tassinopoulos (2000, S. 50). Wolf (2002) nennt diese beiden Effekte Strukturkomponente und Standortkomponente und kritisiert, dass sämtliche Beschäftigungsänderung, die nicht durch die Strukturkomponente erklärt wird, dem Standort zugeschrieben wird. Zwei weitere Kritikpunkte, die sie aufnimmt, sind, dass keine weiteren erklärenden Variablen aufgenommen werden können und keine Signifikanztests durchführbar sind.

In Tassinopoulos (2000) wird die Shift-Share-Analyse angewandt, um Beschäftigungsprognosen für 327 Kreise in Westdeutschland zu erstellen. Es wird folgendes Modell mit leicht veränderter Notation spezifiziert (S. 52):

$$\underbrace{\frac{b_{r,t+1}}{b_{r,t}} \cdot \frac{B_{t+1}}{B_t}}_{\text{Regionalfaktor}} = \underbrace{\left(\frac{\tilde{b}_{r,t+1}}{b_{rt}} \cdot \frac{B_{t+1}}{B_t} \right)}_{\text{Strukturkomponente}} \cdot \underbrace{\left(\frac{b_{r,t+1}}{\tilde{b}_{r,t+1}} \right)}_{\text{Standortkomponente}} \quad (6.4)$$

$$\text{mit} \quad \tilde{b}_{r,t+1} = \sum_{i=1}^{11} b_{r,i,t} \cdot \frac{B_{i,t+1}}{B_{i,t}} \quad (6.5)$$

als erwartete Beschäftigung in Kreis r für den Zeitpunkt $t + 1$. Der Erwartungsbildung liegt die Annahme zugrunde, dass die Beschäftigung der in dem Kreis ansässigen Industrien (i) das gleiche Wachstum aufweisen wie in Westdeutschland insgesamt. Mit B wird die Gesamtbeschäftigtenzahl in Westdeutschland notiert, während b die Beschäftigtenzahl für einen Kreis bezeichnet. Der Regionalfaktor (RF) ist ein Index, der angibt, ob sich die Beschäftigung eines Kreises besser ($\text{RF} > 1$) oder schlechter ($\text{RF} < 1$) als die Gesamtbeschäftigung entwickelte. Eine ähnliche Information gibt die Strukturkomponente (SK). Wird aufgrund des Industrie-Mixes ein überdurchschnittliches Wachstum erwartet, ist die $\text{SK} > 1$. Sind in einem Kreis hingegen viele schrumpfende Industrien angesiedelt, dann wird auch mit einem unterdurchschnittlichen Wachstum gerechnet ($\text{SK} < 1$). Die Standortkomponente ist damit so etwas wie ein ausgleichender Faktor zwischen tatsächlicher und erwarteter Entwicklung.

Betrachtet werden Jahresdaten aus der Beschäftigtenstatistik der Bundesanstalt für Arbeit für die Jahre 1987 bis 1997. Aus den 11 vorliegenden Beobachtungspunkten erhält man durch die Shift-Share-Analyse jeweils 10 Werte für die einzelnen Komponenten je Kreis.

Die Prognose der SK gestaltet sich, bei Vorliegen von Prognosen der Gesamtbeschäftigung der einzelnen Industrien, als überaus einfach. Davon ausgehend,

dass die letzten Werte in t beobachtet werden und sich die Prognose auf $t + 1$ bezieht, ist an (6.4) und (6.5) zu erkennen, dass durch Einsetzen der Prognosen für die Gesamtbeschäftigung direkt eine Prognose für die SK vorliegt. Diese wird als ein Vorteil des Top-down Prinzips angesehen. Zu dem Zeitpunkt der Arbeit von Tassinopoulos (2000) lagen jedoch keine geeigneten Prognosen dieser Art vor, sodass diese erst von Tassinopoulos in Zusammenarbeit mit IAB-Experten erstellt werden mussten.

Die Prognose der Standortkomponente (SO) wird mithilfe der Schätzung folgenden Modells erstellt⁶:

$$SO_{r,t} = \alpha_r + \beta_r \cdot SO_{r,t-1} + \epsilon_{r,t} \quad \text{mit } \epsilon_{r,t} \text{ als Störterm,} \quad (6.6)$$

wobei in Abweichung zu der Notation in Tassinopoulos (2000) den Parametern α und β jeweils der Index r für den Kreis beige stellt ist. Eine Prognose für $t + 1$ ergibt sich demnach durch

$$\widehat{SO}_{r,t+1} = \widehat{\alpha}_r + \widehat{\beta}_r \cdot SO_{r,t}. \quad (6.7)$$

Die regionale Beschäftigungsprognose ist somit durch bloßes Umstellen der Formel für die Standortkomponente erstellt:

$$b_{r,t+1} = \frac{\widehat{SO}_{r,t+1}}{\widetilde{b}_{r,t+1}} \quad (6.8)$$

Problematisch hierbei ist, dass sich die Werte der SO für einen Teil der Kreise im Zeitablauf sprunghaft ändern und somit „eine sehr unzuverlässige Datenbasis für eine Projektion dar[stellt]“, Tassinopoulos (2000, S. 154)). Insgesamt bewertet Tassinopoulos die Shift-Share-Analyse zum Zwecke der Prognose als eher problematisch.

Verschiedene andere Arbeiten folgen auch dem Top-down-Prinzip. Ein Beispiel hierfür ist die Arbeit von Cörvers und Hensen (2007). Sie beschreiben das Vorgehen des Forschungsinstitutes ROA bei der Erstellung von regionalen Arbeitsmarktprognosen differenziert nach Berufen und Bildung. Die zwei Hauptziele der Prognosen sind, Informationen für die Politik-Beratung bereitzustellen sowie den Arbeitsmarkt transparenter zu machen. Insbesondere werden die generellen Zu-

⁶Anmerkung: In der zitierten Arbeit Tassinopoulos (2000, S. 101) wird die Variable SO inkonsistent einmal als „Beschäftigung“ und einmal als „Standortkomponente“ bezeichnet.

kunftsansichten der einzelnen Berufe auf einer Skala von „gut“ bis „schlecht“ bewertet und sollen SchülerInnen und AbsolventenInnen bei der Berufswahl bzw. der Studienwahl unterstützen. Im Rahmen ihres Ansatzes wird zwischen dem Arbeitskräftebedarf aufgrund von Wachstum (*expansion demand*) und dem Bedarf an Arbeitskräften als Ersatz, z. B. für MitarbeiterInnen, die in Rente gehen (*replacement demand*), unterschieden. Der regionale *expansion demand* wird dabei aus nationalen Prognosen abgeleitet. Für die Prognose des regionalen *replacement demand* werden nationale Flussgrößen einer Kohorten-Analyse der einzelnen Berufe verwendet und auf die regionale Beschäftigungsstruktur angewandt.

Bottom-up Eine Arbeit, welche dem Bottom-up-Ansatz folgt, ist Longhi und Nijkamp (2007). Sie erstellen für 326 Kreise in Westdeutschland Beschäftigungsprognosen. Dabei verwenden sie verschiedene Methoden und vergleichen diese anhand der Prognosefehler. Ihr Ziel ist es, herauszufinden, ob die Berücksichtigung von räumlichen Abhängigkeiten bei der Modellspezifikation zu Verbesserungen der regionalen Prognosen führt. Die Vergleiche werden anhand von 1-Schritt-Prognosen durchgeführt.

Als Referenz verwenden sie das naive *no-change* Modell, dessen 1-Schritt-Prognose genau der aktuellen Beschäftigtenzahl entspricht. Die Projektionen der verschiedenen Methoden werden nicht direkt miteinander verglichen, sondern über ihr relatives Abschneiden gegenüber dem Referenz-Modell.

Longhi und Nijkamp ziehen aus ihrer Untersuchung das Fazit, dass regionale Beschäftigtenprognosen, welche sich nicht auf gut abgegrenzte lokale Arbeitsmärkte beziehen, verbessert werden, wenn räumliche Abhängigkeiten berücksichtigt werden. Als einen einfachen Ansatz, um diese räumlichen Wechselwirkungen zu erfassen, schlagen sie vor, die Entfernung zwischen den Kreisen mit in die Modelle aufzunehmen. Gleichzeitig merken sie jedoch an, dass ihre Ergebnisse nicht ohne Weiteres verallgemeinert werden können. Um den Nutzen der Modellierung von räumlichen Wechselwirkungen für verschiedene Rahmenbedingungen zu testen, schlagen sie für zukünftige Forschung Simulationsstudien vor.

Die Prognosemodelle, welche in Hampel et al. (2007) verwendet werden, folgen auch dem Bottom-up-Prinzip. Wie in Longhi und Nijkamp (2007) werden Beschäftigtendaten des deutschen Arbeitsmarktes verwendet. Ebenso ist das Ziel von Hampel et al. der Vergleich eines Modelltyps, welcher räumliche Wechselwirkun-

gen berücksichtigt, mit Modellen, die diese Wechselwirkungen nicht beachten. Im Gegensatz zu Longhi und Nijkamp (2007) werden jedoch Agenturbezirke betrachtet. Ein Agenturbezirk bezeichnet das Zuständigkeitsgebiet einer Arbeitsagentur und umfasst in der Regel mehrere Kreise.

Es werden insgesamt fünf verschiedene Modelltypen verglichen. Allen Modelltypen ist der Verzicht auf exogene Variablen gemein. Die einzige Information, die zur Prognose genutzt wird, ist die Zeit sowie vergangene Werte der Zeitreihen selbst. Im Fall des Modelltyps, welcher räumliche Abhängigkeiten bei der Beschäftigtenentwicklung berücksichtigt, werden anstatt der vergangenen Werte der eigenen Zeitreihe die vergangenen Werte der angrenzenden Agenturbezirke verwendet. Die Entscheidung, auf exogene Variablen bei der Modellspezifikation zu verzichten, wird anhand von drei Argumenten begründet:

- Probleme bei der Datenverfügbarkeit auf regionaler Ebene.
- Der Umstand, dass exogene Variablen zum Zweck einer Prognose selbst erst vorhergesagt werden müssen.
- Die Auffassung, dass die vergangene Entwicklung einer Variable sämtliche Information enthält, um diese möglichst gut vorherzusagen zu können.

Der erste Modelltyp folgt dem Ansatz der exponentiellen Glättung. Eine Prognose ist dabei prinzipiell ein gewichtetes Mittel der vergangenen Zeitreihenwerte. Die Gewichte nehmen ab, je länger die Werte in der Vergangenheit liegen. Ein Argument für diese Modelle ist, „daß sie nicht selten beim Vergleich mit den Resultaten wesentlich komplizierterer Prognoseverfahren gut abschneiden.“, Stier (2001, S. 24).

Als zweite Art von Modellen werden ARMA- bzw. ARIMA-Modelle für jeden Agenturbezirk spezifiziert. Der Name ARMA ist eine Abkürzung für *autoregressive moving average* und beschreibt damit den Charakter der Zeitreihe bzw. die Annahmen über den stochastischen Prozess, welche der Zeitreihe zugrunde liegen. Das autoregressive Element wird über die ersten p Lags der endogenen Variable modelliert und der moving average durch die ersten q Lags des Störterms abgebildet. Formal beschreibt folgende Gleichung ein ARMA(p,q)-Modell:

$$y_t = \sum_{i=1}^p y_{t-i}\varphi_i + u_t + \sum_{i=1}^q u_{t-i}\theta_i, \quad (6.9)$$

mit u_t als Störterm.

Voraussetzung für die Anwendung von ARMA-Modellen ist die Stationarität der Zeitreihe. Um zu überprüfen, ob die Zeitreihen stationär sind, verwenden Hampel et al. den erweiterten Dickey-Fuller-Test. Deutet der Test auf Nicht-Stationarität einer Zeitreihe hin, wird die erste Differenz gebildet und der Test für die transformierte Zeitreihe wiederholt. Dieses Vorgehen wird so oft wiederholt, bis die Stationarität mit hinreichender Sicherheit gewährleistet ist. Stochastische Prozesse, die nach d Differenzenbildungen stationär sind, werden als integriert vom Grade d bezeichnet. Ist die Zeitreihe y_t z. B. integriert vom Grade eins, dann ist das ARIMA($p, d = 1, q$)-Modell für y_t folgendes:

$$y_t^* = \sum_{i=1}^p \varphi_i y_{t-i}^* + u_t + \sum_{i=1}^q \theta_i u_{t-i}, \quad (6.10)$$

mit $y_t^* = y_t - y_{t-1}$ und u_t als Störterm.

Die Wahl von p und q wird anhand der Autokorrelations- und partiellen Autokorrelationsfunktion getroffen. Um möglichst wenige Freiheitsgrade durch die Schätzung der Parameter zu verlieren, wird anhand des korrigierten Akaike-Informationskriteriums (AICC) überprüft, ob durch Weglassen einiger Lags Verbesserungen erzielt werden⁷. Eine Verbesserung bedeutet in diesem Zusammenhang eine Verringerung des AICC. Dabei wird, wie Hampel et al. schreiben, der „simple-to-general“ Ansatz befolgt, d. h., es wird mit der sparsamsten Parametrisierung begonnen (Modell mit nur einem Lag) und schrittweise geprüft, ob die Hinzunahme eines weiteren Lags zu Verbesserungen des Informationskriteriums führt.

Die Modelltypen drei, vier und fünf zählen alle zur Klasse der strukturellen Komponentenmodelle.

Für Modell drei nehmen Hampel et al. folgende Komponenten auf, um die Zeitreihen zu erklären: Niveau- und Trendkomponente μ_t , Saisonkomponente γ_t , Konjunkturzykluskomponente ψ_t und ϵ_t als Restkomponente bzw. Störterm. Das Niveau und der Trend werden als lineare Funktion der Zeit modelliert. Die Komponenten γ_t und ψ_t werden mit Hilfe von Sinus- und Kosinusfunktionen abgebildet.

Das Modell vier stellt eine einfache Erweiterung des Modells drei dar. Die Spezifikation von Modell drei wird übernommen, zusätzlich werden jedoch Lags der endogenen Variable aufgenommen. Wie bei der Spezifikationsbestimmung der

⁷Die Formel zur Berechnung des AICC ist: $\ln \hat{\sigma}^2 + \frac{T+k}{T-k-2}$ mit T als Länge der Zeitreihe, k als Anzahl zu schätzender Parameter und $\hat{\sigma}^2$ als geschätzte Standardabweichung.

ARIMA-Modelle wird die partielle Autokorrelationsfunktion genutzt, um je Agenturbezirk ausschließlich die optimalen Lags aufzunehmen. Als Entscheidungskriterium, ob ein Lag beibehalten wird, dient auch hier wieder das AICC.

Das Modell fünf ergibt sich auch durch eine Erweiterung von Modell drei. Anstatt jedoch Lags der endogenen Variable, werden Lags der geografisch angrenzenden Agenturbezirke aufgenommen. Ein weiterer Unterschied ergibt sich bei der Parameterschätzung. In den vorherigen Modellen werden für jeden Agenturbezirk separate Schätzungen durchgeführt. Modell fünf hingegen wird in der Art konstruiert, dass sämtliche Parameter simultan geschätzt werden. Dazu konstruieren Hampel et al. ein sogenanntes Modell scheinbar unverbundener Regressionen.

Die eben vorgestellten fünf Modelltypen werden anhand von artifiziellen Out-of-Sample-Prognosen verglichen. Das Ergebnis dieser Vergleiche ist, dass Prognosen mit Hilfe exponentieller Glättung für ca. 50 % der Regionen die genauesten Vorhersagen liefern, die ARIMA-Modelle für ca. 25 % der Regionen am genauesten sind, und die strukturellen Komponentenmodelle mit räumlichen Abhängigkeiten (Modell fünf) bei ca. 20 % der Regionen am genauesten sind. Für die übrigen 5 % der Agenturbezirke liefern entweder Modelltyp drei oder vier die genauesten Vorhersagen. Das Fazit, das Hampel et al. daraus ziehen, ist, dass für jeden Agenturbezirk individuell geprüft werden muss, welcher Modelltyp anzuwenden ist. Des Weiteren stellen sie fest, dass auch die konkreten Modellspezifikationen innerhalb eines Modelltyps sehr unterschiedlich für die verschiedenen Agenturbezirke ausfallen.

Verknüpfung von Top-down und Bottom-up Dangerfield und Morris (1992) vergleichen artifizielle Out-of-Sample-Prognosen die nach Top-down und Bottom-up berechnet wurden. Sie verwenden 178 Zeitreihen der M-Competition-Daten⁸. Für ca. 3/4 der Zeitreihen werden die Prognosen der Bottom-up-Methode bevorzugt. Ihre Untersuchung beschränkt sich jedoch auf Zeitreihen mit Monatsdaten und Aggregaten, bestehend aus zwei Zeitreihen. Daher ist eine Verallgemeinerung ihrer Ergebnisse nicht unmittelbar möglich.

Wie eingangs erwähnt, haben beide Ansätze ihre Vor- und Nachteile. Nationale Prognosen, welche beim Top-down-Prinzip genutzt werden, sind weniger sensitiv für zufällige Schwankungen als regionale Prognosen, vernachlässigen jedoch de-

⁸Die M-Competition bezieht sich auf einen von Spyros Makridakis organisierten Prognose-Wettbewerb. Die verwendeten Zeitreihen werden auch als M-Competition-Daten bezeichnet. Die Ergebnisse des Wettbewerbs sind in Makridakis et al. (1982) gegeben (vgl. Armstrong und Lusk, 1983).

taillierte Informationen der Regionalebene. Diese Vor- und Nachteile kehren sich für den Bottom-up-Ansatz um. Eine allgemein gültige Empfehlung für einen der beiden Ansätze lässt sich nicht geben. Das Verknüpfen der beiden Ansätze stellt einen Versuch dar, jeweils nur die positiven Eigenschaften zu nutzen und die negativen auszugleichen.

Ein Prognoseverfahren, welches explizit Top-down- mit Bottom-up-Elementen verbindet, ist in Blien und Tassinopoulos (2001) beschrieben. Unter Verwendung der sogenannten ENTROP-Methode werden Beschäftigtenprognosen für sämtliche Kreise in Westdeutschland erstellt. Die ENTROP-Methode stellt eine verallgemeinerte Form von RAS-Techniken⁹ dar. Das Vorgehen von Blien und Tassinopoulos kann grob in drei Schritte gegliedert werden.

Als erstes werden für das Zieljahr der Prognose die Beschäftigtenzahlen differenziert nach Kreisen und Industrien geschätzt. Dies geschieht durch eine einfache Trend-Extrapolation mittels folgender Gleichung:

$$y_{jk}^{99} = y_{jk}^{97} + \underbrace{y_{jk}^{97} \left(0,5 \ln \left(\frac{y_{jk}^{97}}{y_{jk}^{93}} \right) \right)}_{\text{Trend-Wachstum}} \quad j = 1, \dots, 327 \quad k = 1, \dots, 11 \quad (6.11)$$

mit y als Beschäftigtenzahl in Kreis j und Industrie k . Die hochgestellten Indizes geben die Jahreszahl an¹⁰. Die Ergebnisse dieser Extrapolationen werden in einer 327×11 Matrix festgehalten, welche als Basis-Matrix bezeichnet wird.

In einem zweiten Schritt werden Aggregatsprognosen entweder erstellt, oder soweit möglich, aus anderen Quellen übernommen. Zur Definition der Aggregate werden drei verschiedene Kriterien herangezogen. Das erste Aggregationskriterium ist die Zugehörigkeit eines Beschäftigten zu einer Industrie. Das zweite Kriterium bilden die Bundesländer. Als letztes Kriterium wird der Typ eines Kreises gewählt. Die Typisierung bezieht sich auf den Urbanisierungsgrad des Kreises und dessen Umland.

Der dritte Schritt besteht darin, die Ergebnisse der Trend-Extrapolation in Einklang mit den Aggregatsprognosen zu bringen. Hierbei kommt die ENTROP-Methode zum Einsatz. Ziel ist es, die Einträge der Basis-Matrix möglichst ge-

⁹RAS-Techniken werden z. B. eingesetzt, um fehlende Werte in einer Matrix künstlich zu erzeugen und dabei verschiedene Restriktionen (Spalten oder Zeilensummen) nicht zu verletzen.

¹⁰Bei der Notation in Blien und Tassinopoulos (2001) wird für die prognostizierte Beschäftigtenzahl ein anderer Buchstabe als für die beobachteten Werte verwendet.

ringfügig zu verändern, gleichzeitig jedoch die Restriktionen, gegeben durch die Aggregatsprognosen, einzuhalten. Im Fall der Prognosen für die Industrien beziehen sich die Restriktionen auf die Spaltensummen.

An dieser Stelle sei auf ein kritisches Element der ENTROP-Methode hingewiesen. Die Basis-Matrix, welche die Trend-Extrapolationen enthält, wird einer subjektiven Prüfung unterzogen, bevor sie weiter verwendet wird. Ziel dieser Prüfung ist es, extreme Trends zu identifizieren und gegebenenfalls nach unten oder oben zu korrigieren. Dabei kommt es, wie Blien und Tassinopoulos einräumen, auf die Erfahrung und das Expertenwissen der Personen an, welche die Prognosen erstellen. Im Falle von sehr exaktem Expertenwissen und einem hohen Maß an Erfahrung kann dies zu einer signifikanten Verbesserung der Prognosen führen. Gleichzeitig stellt dieses Vorgehen jedoch einen Schwachpunkt dar, weil somit die Nachvollziehbarkeit und Objektivität der Prognosen nicht mehr gewährleistet sind.

Um die Güte der ENTROP-Methode einzuschätzen, werden artifizielle Out-of-Sample-Prognosen erstellt und der gewichtete *mean squared error* (MSE) berechnet. Als Gewicht wird die tatsächlich beobachtete Beschäftigtenzahl des Zieljahres der Prognose verwendet. Als Referenz werden die einfachen Trend-Extrapolationen aus Schritt eins herangezogen. Dieser Vergleich fällt eindeutig zugunsten der ENTROP-Methode aus. Der gewichtete MSE ist nur ca. halb so groß wie der für die Trend-Extrapolation.

Abschließend sei darauf hingewiesen, dass die eben vorgestellten Arbeiten nur einen kleinen Ausschnitt der Literatur zu dem Thema regionaler Beschäftigtenprognosen darstellen. Speziell die zuletzt genannten Arbeiten sind deshalb ausgewählt worden, weil sich deren Prognosen auf den deutschen Arbeitsmarkt beziehen. Für einen Überblick der Forschungsansätze und Methoden, welche am IAB verfolgt bzw. angewandt werden, bietet sich Blien et al. (2001) an.

Im Hinblick auf das anstehende Prognosevorhaben muss festgestellt werden, dass viele Methoden und Modelle aus zwei Gründen ausscheiden: Erstens, die Anzahl an zu erstellenden Prognosen ist so groß, dass nur Modelle, die zum größten Teil automatisiert ablaufen, in Frage kommen. Zweitens, Methoden, welche Expertenwissen bezüglich der Entwicklungen in bestimmten Regionen oder Berufsfeldern benötigen, werden auch ausgeschlossen, da solche Prognosen nicht replizierbar und nicht anhand von artifiziellen Out-of-Sample-Prognosen evaluierbar sind.

Die Bedingung, eine Prognose mit einer künstlich reduzierten Informationsmenge zu erstellen, ist nicht erfüllbar, da das Wissen eines Experten über vergangene Entwicklungen nicht gelöscht werden kann.

Ein Gebiet auf dem die Anzahl der verlangten Prognosen typischerweise auch sehr groß ist, ist die Vorhersage von Lagerbeständen. Ende der 1950er-Jahre begann man in diesem Umfeld Methoden der exponentiellen Zeitreihenglättung zur Prognose zu verwenden. Einen kompakten Überblick zur Entwicklung von Projektionsmethoden auf Basis der exponentiellen Glättung geben De Gooijer und Hyndman (2006). Eine viel zitierte Arbeit, welche einen Überblick über die gängigsten Modelle der exponentiellen Glättung gibt, ist Gardner (1985). Exponentielle Glättungsmethoden lassen sich für verschiedene Arten von Zeitreihen nutzen. Die Abbildung A.87 auf Seite 256 zeigt schematisch 12 unterschiedliche Situationen bezüglich des Trends einer Zeitreihe und ihrer saisonalen Schwankungen. Jede Situation erfordert eine spezielle Glättungsmethode bzw. Parameterspezifikation.

Auch heute noch werden exponentielle Glättungsmethoden zur Prognose genutzt. Chatfield et al. (2001) bemerken in ihrer Einleitung, dass Projektionen in der Industrie und im Handel oft mit Hilfe von exponentieller Glättung erstellt werden. Besonders häufig werden Methoden der exponentiellen Glättung in Situationen angewandt, in denen die Anzahl und Frequenz der zu erstellenden Projektionen sehr groß ist oder die zur Verfügung stehenden Zeitreihen sehr kurz sind, vgl. Diebold (2007, S. 313). Oft ist festgestellt worden, dass Projektionen von sehr viel komplexeren Methoden in der Praxis keine oder nur geringe Verbesserungen liefern, vgl. z. B. Allen und Fildes (2003, S. 305), Armstrong (1984) oder Stock (2003). Auch Makridakis und Hibon (2000) fassen die Resultate verschiedener empirischer Studien mit der Bemerkung zusammen, dass komplexere Methoden nicht zwangsläufig genauere Projektionen liefern als einfache Methoden.

Die exponentielle Glättung wurde früher dafür kritisiert, keine theoretische Fundierung in Form eines statistischen Modells zu besitzen, siehe De Gooijer und Hyndman (2006). Mittlerweile ist gezeigt worden, dass die exponentielle Glättung die MSE-optimale Projektionsvorschrift für verschiedene Modelle ist, siehe Chatfield et al. (2001). Nach Gardner und McKenzie (1985) liefert beispielsweise exponentielles Glätten mit gedämpften additivem Trend (Holt-D) je nach Parameterspezifikation die MSE-optimale Projektion für sechs verschiedene ARIMA-Modelle. Die p -Schritt-Projektion berechnet sich dabei aus dem aktuell geglätteten

6. Methoden und Modelle

Wert S_t und dem aktuellen Trend T_t der Zeitreihe y_t :

$$\hat{y}_{t+p|t} = S_t + \sum_{i=1}^p \phi^i T_t \quad (6.12)$$

mit

$$S_t = \alpha y_t + (1 - \alpha)(S_{t-1} + \phi T_{t-1}) \quad (6.13)$$

$$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1} \quad (6.14)$$

und ϕ als Dämpfungs- und α und γ als Glättungsparameter. Die Methode nutzt keine berufs- oder regionsspezifischen Informationen, daher wird der Index i weggelassen. Unter Verwendung der M-Competition-Daten¹¹ vergleichen sie die Prognosegenauigkeit zwischen Holt-D und Holt-Winters linearer Glättung ($\phi = 1$). Ihre Ergebnisse zeigen, dass erst mit wachsendem Prognosehorizont ein Unterschied sichtbar wird. Ab einem Prognosehorizont von 4 Jahren liefert Holt-D die kleinsten durchschnittlichen absoluten Prognosefehler. Betrachtet man den Median derselben Fehler, ist erst ab Projektionen für 7 oder mehr Jahre ein Unterschied zu sehen.

Da in der vorliegenden Arbeit nur Jahresdaten verwendet werden, wäre es interessant, die Ergebnisse separat nach Frequenz der Daten (Jahres-, Quartals- und Monatsdaten) zu sehen. Dies geschieht leider nur für einen Teil der Zeitreihen (111 von den 1001 Zeitreihen). Dabei unterscheiden sich für die jährlichen Reihen die über alle Horizonte gemittelten APEs kaum (ca. 13% zu 13,2%). Gardner und McKenzie erklären dies durch die große Häufigkeit, mit der $\phi = 1$ gewählt wird und somit Holt-D gleich Holt-Winters linearem Glätten ist.

In den folgenden Abschnitten werden die Methoden und Modelle vorgestellt, welche zur Prognose verwendet werden.

¹¹Siehe Fußnote 8.

6.2. Modellierungsstrategien und ihre Annahmen¹²

Ein sehr allgemeiner Ausgangspunkt für ein mögliches Modell zur Schätzung (und Prognose) sind die strukturellen Bestimmungsgleichungen

$$g_1(y_{it}) = g_2(z_{it}, \xi_{it}), \quad i = 1, \dots, N, t = 1, \dots, T, \quad (6.15)$$

wobei $g_1(\cdot)$ und $g_2(\cdot)$ parametrische oder nichtparametrische Funktionen sind, die z_{it} beobachtbare (nicht notwendigerweise vorherbestimmte) Prädiktoren und die ξ_{it} nichtbeobachtbare Prädiktoren umfassen. Im Folgenden befassen wir uns mit einer Klasse von Ansätzen in reduzierter Form, die sich durch Umformung aus den strukturellen Gleichungen (6.15) gewinnen lassen und die folgende additive Struktur aufweisen:

$$y_{it} = g(x_{it}) + v_{it}, \quad i = 1, \dots, N, t = 1, \dots, T, \quad (6.16)$$

wobei $g(\cdot)$ eine parametrische oder nichtparametrische Funktion ist, x_{it} beobachtbare, vorherbestimmte Prädiktoren (exogene und/oder verzögerte endogene) und v_{it} nichtbeobachtbare Prädiktoren enthält. Zentral für die Spezifikation dieses Regressionsmodells ist der stochastische Zusammenhang zwischen den Prozessen $\{g(x_{it})\}$ und $\{v_{it}\}$. In einer idealen Welt würde sich jeder interessierende Aspekt der konditionalen Verteilung von y_{it} gegeben x_{it} vollständig durch Funktionen der x_{it} , wie z. B. $g(x_{it})$, beschreiben lassen, und in diesem Sinne alle berufs-, regionen- und zeitspezifischen Einflüsse auf y erfassen. Da in der Praxis derartige Funktionen im Allgemeinen nicht zur Verfügung stehen bzw. aus rechentechnischen Gründen bis vor Kurzem nicht geschätzt werden konnten, müssen Annahmen getroffen werden, wie sich aus (6.16) ein Ansatz gewinnen lässt, der die o. a. ideale Situation in einem statistischen Sinne möglichst gut approximiert.

Ein sehr populärer Ansatz besteht darin, eine Fehlerkomponentenannahme für v_{it} zu setzen. An dieser Stelle wird die Verwendung der expliziten Doppelindizierung mit Beruf b und Region r nötig. Die Notation der Beschäftigtenzahl in Berufe-Regionen-Kombination i ist jetzt y_{brt} . Analog gilt dies auch für die ande-

¹²Dieser und die übrigen Abschnitte dieses Kapitels stammen aus Jones et al. (2013).

ren Variablen. Das resultierende Modell besteht aus den beiden Gleichungen

$$y_{brt} = \gamma_0 + x'_{brt}\gamma_1 + v_{brt}, \quad b = 1, \dots, B, r = 1, \dots, R, t = 1, \dots, T, \quad (6.17)$$

$$v_{brt} = \kappa_b + \eta_r + \lambda_t + u_{brt}, \quad (6.18)$$

wobei in (6.17) der Einfachheit halber die zusätzliche Annahme einer linearen, parametrischen Regressionsfunktion getroffen wurde. In (6.18) sind die jeweils nichtbeobachtbaren Effekte für die Berufe κ_b , für die Regionen η_r und die Zeiteffekte λ_t sowie die Restgröße u_{brt} enthalten. Ein Argument, das für diese Modellierung spricht, ergibt sich aus der zentralen Frage, ob die Effekte v_{brt} mit den x_{brt} korreliert sind oder nicht. Im vorliegenden Fall der Analyse der Beschäftigung auf disaggregiertem Berufe-Regionen-Niveau sind Korrelationen zwischen nichtbeobachtbaren Eigenschaften der Regionen und den Prädiktoren wahrscheinlich. Aus diesem Grund werden die berufe- und regionenspezifische Parameter κ_b und η_r geschätzt. Die zeitspezifischen Effekte basieren auf einer Variable, die das Jahr angibt (explizite Berücksichtigung in den nichtparametrischen Spezifikationen). In den parametrischen Regressionsfunktionen wird diese Variable mithilfe von $T - 1$ Zeitdummies abgebildet. Gründe dafür sind die starke (politische) Regulierung des Arbeitsmarktes und nicht zuletzt die einfache Extrapolierbarkeit eines übergeordneten Trendmusters. Die genauen Spezifikationen der Paneldatenmodelle sind in Abschnitt 6.3 zu finden. In Abschnitt 6.4 werden die nichtparametrischen Schätzmethoden beschrieben.

Zusätzliche Informationen: Entwicklungen für Berufe, Regionen und die Beschäftigung insgesamt

Die Beschäftigtenzahlen auf Ebene der Berufe-Regionen-Kombinationen y_{brt} lassen sich nach Berufen und/oder Regionen aggregieren. Wird beispielsweise der Agenturbezirk Bielefeld betrachtet und werden für diesen die Beschäftigtenzahlen über alle Berufe summiert, so ergibt sich die Gesamtbeschäftigtenzahl für den Agenturbezirk Bielefeld. Dies wird auch als ein regionales Aggregat bezeichnet. Analog dazu lässt sich ein berufliches Aggregat bilden. Summiert man beispielsweise die Beschäftigtenzahlen aller Landwirte, die in den verschiedenen Regionen arbeiten, erhält man die Gesamtbeschäftigung der Landwirte in Deutschland. Auf diese Art lassen sich Zeitreihen der Aggregate bilden.

- Die Summation über Berufe liefert die Zeitreihen der regionalen Aggregate:

$$y_{\bullet rt} = \sum_{b=1}^B y_{brt}$$

- Die Summation über Regionen liefert die Zeitreihen der beruflichen Aggregate: $y_{b\bullet t} = \sum_{r=1}^R y_{brt}$
- Die Summation über Berufe und Regionen liefert die Zeitreihe des Aggregats der Gesamtbeschäftigung: $y_{\bullet\bullet t} = \sum_{b=1}^B \sum_{r=1}^R y_{brt}$

Die Extrapolationen der Beschäftigten auf Ebene der Berufe-Regionen-Kombinationen y_{br} für zukünftige Perioden $T + p$, $p \geq 1$, kann insofern problematisch sein, als dass die zukünftigen Entwicklungen der Aggregate nicht expliziter Bestandteil des jeweiligen Prognoseansatzes sind. Eine Folge ist, dass die aus den disaggregierten Prognosen \hat{y}_{brT+p} resultierenden Aggregate eventuell erheblich von den Prognosen der Aggregate abweichen können, z. B. für eine Region r

$$\hat{y}_{\bullet r T+p} \neq \sum_{b=1}^B \hat{y}_{brT+p}.$$

Im Folgenden wird erläutert, wie diese Problematik entschärft und durch die Berücksichtigung von zusätzlichen Informationen die Prognosegenauigkeit (im Sinne der Reduktion der p -Schritt-Prognosefehlervarianz) möglicherweise erhöht werden kann.

Dazu betrachten wir die Zeitreihen der Aggregate $y_{\bullet rt}$, $y_{b\bullet t}$ und $y_{\bullet\bullet t}$, im Folgenden auch Randsummen genannt. Die zeitlichen Verläufe der Randsummen für verschiedene Gliederungstiefen geben einen ersten Aufschluss darüber, wie schnell sich Änderungen eventueller Trend- bzw. Niveauverläufe historisch ergeben haben. Darauf aufbauend stellt sich die Frage nach geeigneten Methoden der Extrapolation dieser Aggregate für $t = T + p$, $p \geq 1$. Die Modellierung kann beispielsweise mit Verfahren der multiplen Zeitreihenanalyse erfolgen, wobei die nur kurze zeitliche Dimension der Daten kritisch zu sehen ist. Alternativ können auch ökonometrische Modelle in Analogie zu den o. a. Ansätzen zum Einsatz kommen. Hier gibt es im Prinzip mehrere Optionen.

Eine Option ist die Modellierung der Aggregatsbeobachtungen als zusätzliche Beobachtung des disaggregierten Ansatzes im Sinne einer stochastischen Nebenbedingung, siehe z. B. Haupt und Oberhofer (2005). Alternativ kann die Modellierung der Randsummen als übergeordnete hierarchische Stufe (und dementsprechend die Gesamtsumme als höchste hierarchische Stufe) erfolgen. D. h., dass Prädiktoren zum Einsatz kommen, die nur auf der jeweiligen hierarchischen Ebene – also Berufs- oder/und Regionenebene – relevant sind (und nicht zwangsläufig auf

der untergeordneten hierarchischen Ebene der Berufe-Regionen-Kombinationen). Durch die Summationsbedingungen, die auf den jeweiligen hierarchischen Ebenen gelten, kann die Methode von Athanasopoulos et al. (2009) und Hyndman et al. (2011) eingesetzt werden, die es erlaubt, hierarchische Punktprognosen beliebigen Ursprungs miteinander zu verbinden, um Prognosen für alle Aggregationsebenen einer hierarchischen Struktur zu erhalten.

In Analogie zu den obigen Ausführungen ist für die extrapolierten Werte der Randsummen $\hat{y}_{b\bullet T+p}$ und $\hat{y}_{\bullet r T+p}$ darauf zu achten, dass ihre jeweiligen Aggregate ebenfalls nicht nur erheblich voneinander, sondern auch von der entsprechenden tatsächlichen gesamten Beschäftigtenanzahl $y_{\bullet\bullet T+p}$ abweichen können. Generell kann (und sollte) die Extrapolation dieser Aggregate zu Zwecken der Plausibilitätsprüfung der aus dem disaggregierten Modell prognostizierten Beschäftigtenzahlen nach Berufen, Regionen bzw. beidem verwendet werden.

Zu beachten ist auch eine Asymmetrie in der Natur der Randsummen: Während auf Ebene der Agenturbezirke (d. h. Aggregation über die jeweiligen Berufe) typischerweise eine Reihe möglicher Prädiktoren (aus der amtlichen Statistik) zur Verfügung stehen, ist dies auf Ebene der Jones-Berufe (d. h. Aggregation über die jeweilige Regionenstruktur) nicht der Fall. Zudem sollen für die Fortschreibung der Randsummen (und auch der Prädiktoren) reine Zeitreihenverfahren eingesetzt werden, um zum einen nicht die gleichen Quellen der Variation wie im Schätz- und Prognoseansatz für die disaggregierte Beschäftigung zu verwenden, und zum anderen voll automatisierbare Verfahren zu ermöglichen. Insbesondere letzteres Argument hat Gewicht, wenn man bedenkt, dass Hunderte einzelne Ansätze zu spezifizieren und zu schätzen sind. Die Methode von Athanasopoulos et al. (2009) wird in Abschnitt 6.6 vorgestellt.

6.3. Parametrische Modellierung

Die Zeitreihen der Berufe-Regionen-Kombinationen werden als ein Paneldatensatz betrachtet. So lassen sich berufs-, regionen- und zeitspezifische Effekte schätzen. Ideal wäre es, wenn zusätzlich weitere über i und t variierende Prädiktoren x_{it} aufgenommen würden. Für die Prognose müssen diese, genau wie die zeitspezifischen Effekte, für die Prognoseperioden fortgeschrieben werden.

Die Entwicklung von Prognosemethoden für Paneldatenregressionsansätze ist, trotz des großen theoretischen und empirischen Interesses an der Spezifikation,

Schätzung und Inferenz von Panelmethoden, ein erstaunlich unterentwickeltes Gebiet, wie auch ein aktueller Überblicksartikel von Baltagi (2008) betont. Dieser Artikel legt seinen Fokus aber, ebenso wie Baltagi (2010) und Kouassi et al. (2011) für das (one- bzw. two-way) Fehlerkomponentenmodell, sowie Frees und Miller (2004) für das gemischte lineare Modell, auf die Diskussion des BLUP (*best linear unbiased predictor*).

Die sture Anwendung von Paneldatenkonzepten auf das vorliegende Prognoseproblem bringt jedoch größere Probleme mit sich. Es lässt sich beobachten, dass die existierenden Arbeiten vornehmlich auf längere Zeithorizonte und höhere Beobachtungsfrequenzen zurückgreifen können und in der Regel nicht an Langfristprognosen interessiert sind. Wenige Ausnahmen wie Schmalensee et al. (1998) können auf einen einzelnen, sehr guten Prädiktor zurückgreifen, für dessen langfristige Fortschreibung Expertenszenarien zur Verfügung stehen.

Ein noch wichtigerer Punkt ist der Folgende: Unabhängig davon, wie Berufe und Regionen letztlich klassifiziert werden, ist es nicht möglich, die komplexe, zeitlich und räumlich dynamische Struktur der ökonomischen und soziodemographischen Zusammenhänge der Beschäftigung zu erfassen. Die Prädiktoren x_{it} sind schwerer zu identifizieren. Zudem sind sie nur eingeschränkt beobachtbar bzw. stehen sie auf Ebene der Berufe und Regionen nur in zweifelhafter Qualität zur Verfügung. Aus dieser Fehlklassifikation folgt, dass auf Ebene der Berufe-Regionen-Kombinationen jedes Modell fehlspezifiziert sein wird. Daher ist der BLUP nur von eingeschränkter Praktikabilität, insbesondere hinsichtlich der Schätzung einer (auch für die Prognose) geeigneten Kovarianzstruktur. Es kann keine generelle Aussage zur Anwendbarkeit des BLUP im vorliegenden Kontext geben, da die zugrunde liegenden Annahmen (bezüglich der Fehlerkomponenten und beobachtbaren Prädiktoren) von der betrachteten Berufsklassifikation bzw. regionalen Aggregationsstufe abhängen. Zielführender scheint es daher, die Modellspezifikation (d. h. die Auswahl der Prädiktoren) anhand der resultierenden Prognosequalität zu bestimmen.

Entsprechend den Überlegungen zur Modellierung in Abschnitt 6.2 wird folgendes Modell aufgestellt:

$$\log(y_{brt}) = \sum_{j=2}^B \kappa_j D_{b,j} + \sum_{k=2}^R \eta_k D_{r,k} + \sum_{l=2}^T \lambda_l D_{t,l} + \gamma x'_{brt} + u_{brt}, \quad (6.19)$$

mit $D_{b,j}$, $D_{r,k}$ und $D_{t,l}$ als Dummy-Variablen für Beruf, Region und Jahr, x'_{brt} als transponierter Zeilenvektor der Prädiktoren, γ als Parametervektor und u_{brt}

als unbeobachtbare Restkomponente. Aufgrund der extremen Größenunterschiede zwischen den Beschäftigtenzahlen der verschiedenen Berufe-Regionen-Kombinationen und ihrer stark rechtsschiefen Verteilung, werden diese vor der Schätzung logarithmiert. Ein weiterer Vorteil der Logarithmierung ergibt sich bei der Rücktransformation der Prognosen durch die Exponentialfunktion

$$\hat{y}_{brT+p} = \exp(\hat{\sigma}_u^2/2) \exp(\widehat{\log(y_{brT+p})}), \quad (6.20)$$

wobei $\hat{\sigma}_u^2$ die geschätzte Varianz von u ist. Die \hat{y}_{brT+p} sind strikt positiv. Ausgehend vom Fehlerkomponentenmodell in den Gleichungen (6.17) und (6.18) wird eine sogenannte Fixed-Effects Annahme gestellt. Als sparsamste Spezifikation wird ein autoregressiver Ansatz gewählt, d. h. mit $x_{brt} = (1 \quad \log(y_{brt-1}))$. Unter Verwendung aller aus der BeH generierten Prädiktoren (siehe Abschnitt 3.5) ergibt sich

$$x_{brt} = (1 \quad \log(y_{brt-1}) \quad \text{old.num}_{brt} \quad \text{young.num}_{brt} \quad \text{fem.share}_{brt} \quad \text{smaco.share}_{brt} \quad \text{dwage.med}_{brt}).$$

Die Parameterschätzung für (6.19) geschieht typischerweise mit der Methode der kleinsten Quadrate. Diese Methode ist jedoch anfällig für Ausreißer. Wird bei der Parameterschätzung darauf abgezielt, die absoluten Abweichungen anstatt der quadrierten Abweichung zu minimieren, wird diese Anfälligkeit vermindert.¹³

6.4. Nichtparametrische Methoden

Entsprechend der Überlegungen zur Schätzung des Paneldatenmodells im vorherigen Abschnitt, bildet der Ansatz

$$y_{it} = \alpha_i + \lambda_t + h(x_{it}) + u_{it}, \quad i = 1, \dots, N, t = 1, \dots, T, \quad (6.21)$$

mit $\alpha_i = \kappa_b + \eta_r$, den Startpunkt für die Überlegungen zur nichtparametrischen Schätzung. Dabei ist $h(\cdot)$ eine nicht notwendigerweise bekannte nichtparametrische Funktion.

Während die Schätzung von Ansatz (6.21) auch für flexible nichtparametrische

¹³In diesem Fall wird die Prognose, bei der ja auf den Median abgezielt wird, nicht mit $\exp(\hat{\sigma}_u^2/2)$ multipliziert, da die Exponentialfunktion eine monotone Transformation bewirkt.

Funktionen $h(\cdot)$ (z. B. Henderson et al. (2008)) unproblematisch ist, gestaltet sich die Prognose deutlich schwieriger. Akzeptiert man die Annahme, dass die α_i auch kurz- bis mittelfristig konstant in der Zeit sind, wird für eine Prognose von y für den Zeitpunkt $T + p$, $p \geq 1$, sowohl λ_{T+p} benötigt als auch x_{iT+p} . Schmalensee et al. (1998) diskutieren Strategien einer datengesteuerten Bestimmung von $h(\cdot)$ und zur Fortschreibung der Zeiteffekte für die Prognoseperioden. Ein mögliches Problem bei der Verwendung von (6.21) für die vorliegende Fragestellung liegt darin, dass die additive Natur des Modells einen gemeinsamen Trendprozess $\{\lambda_t\}$ für alle Berufe-Regionen-Kombinationen unterstellt. Individuelle Trends können nur über eine entsprechende Modellierung des Prozesses $\{u_{it}\}$ erfolgen. Letzteres ist angesichts der kurzen Zeitdimension der zur Verfügung stehenden Daten aber als problematisch anzusehen.

Eine alternative Modellierung, die dieses Problem umgeht und zudem einen in der Schätzung inkludierten Test auf Poolability¹⁴ sowie einen Test auf parametrische Fehlspezifikation (siehe Hsiao et al. (2007)) liefert, wird in Racine (2008) vorgeschlagen. Der zentrale Unterschied zu Ansatz (6.16) liegt darin, dass angenommen wird, dass alle nur von i bzw. t abhängigen Effekte durch die Berücksichtigung kategorialer Variablen in dem Vektor z_{it} , erfasst werden können. Der resultierende Ansatz

$$y_{it} = g(z_{it}) + u_{it}, \quad i = 1, \dots, N, t = 1, \dots, T, \quad (6.22)$$

ermöglicht eine prinzipiell beliebige Interaktion aller Effekte und Prädiktoren. Letztere kann man sich als eine Art polynomiale Approximation vorstellen, deren Grad aus den Daten heraus bestimmt wird, siehe Haupt et al. (2011). Da die Schätzung aber nichtparametrisch mit Glättungsverfahren (d. h. Kernschätzung, siehe Li und Racine (2007)) erfolgt, kann man die für die Kernschätzung relevanten Glättungsgewichte (Bandweiten) als Analogie zum Grad eines parametrischen Polynoms betrachten.

Für die durchzuführenden Schätzungen, Prognosen und deren jeweiligen statistischen Evaluationen wird der Ansatz (6.22) herangezogen. Im Rahmen einer gemischten (d. h. mit kategorialen und stetigen Kovariablen) Kernregression wird

¹⁴Im Vergleich zu traditionellen parametrischen Ansätzen und Tests auf Poolability ist diese Vorgehensweise zwar annahmefrei, aber unter Umständen deutlich rechenintensiver.

folgende Gleichung geschätzt:

$$\log(y_{it}) = g(b, r, t, \log(y_{it-1})) + u_{it}, \quad i = 1, \dots, N, t = 1, \dots, T \quad (6.23)$$

Die kategorialen Prädiktoren sind die Berufsklasse b , die Region r und die Zeit t , wobei letztere als geordnet kategoriale Variable berücksichtigt wird.

Der vorhergesagte Wert $\widehat{\log(y_{jT+p})}$ für Beschäftigte in Großer Teilzeit ergibt sich aus folgendem Minimierungskalkül:

$$\min_{\log(y_{jT+p}), \hat{\alpha}} \sum_{i,t} \left[\log(y_{it}) - \widehat{\log(y_{jT+p})} - \hat{\alpha} \cdot (\log(y_{iT+p-1}) - \log(y_{jT+p-1})) \right]^2 \cdot W(\boldsymbol{\delta}, \mathbf{h}) \quad (6.24)$$

In diesem Zusammenhang spricht man von lokal linearer Kernregression. Für Vollzeitbeschäftigte wird – da hier kein über alle Berufe/Regionen persistentes Trendmuster ersichtlich ist – ein lokal konstanter Ansatz gewählt, zu welchem sich obiges Kalkül durch $\hat{\alpha} = 0$ vereinfacht. In beiden Ansätzen wird das Gewicht der (i, t) -ten Beobachtung durch die Gewichtungsfunktion $W(\cdot)$, dem sogenannten verallgemeinerten Produktkern, bestimmt. Das Gewicht einer Beobachtung bestimmt sich dabei aus der Ähnlichkeit der Kovariablenwerte zwischen Beobachtungspunkt und vorhergesagtem Punkt, enthalten im Vektor $\boldsymbol{\delta} = (\delta_b, \delta_r, \delta_t, \delta_{\log(y_{jT+p-1})})'$. Um eine Kernregression schätzen zu können, benötigt man sogenannte Bandweiten. Der Vektor $\mathbf{h} = (h_b, h_r, h_t, h_{\log(y_{jT+p-1})})'$ gibt die Bandweiten an, welche das Ausmaß der Glättung über die jeweilige Kovariable bestimmen. Diese Glättungsparameter sind vor der eigentlichen Regressions-Schätzung zu ermitteln. Für den Fall von gemischten Kovariablen gibt es lediglich zwei Bandweitenwahlverfahren: Die Kleinst-Quadrate-Kreuz-Validierung (vgl. Kapitel 4 in Li und Racine (2007)) sowie einen Ansatz über ein modifiziertes AIC (vgl. Hurvich et al. (1998)).

6.5. Semiparametrische Modellierung

Aus der Klasse der univariaten Zeitreihenanalyse werden Innovation-State-Space-Modelle gewählt. Diese erfüllen die Anforderungen der Automatisierbarkeit und decken zudem einen Teil der Ansätze ab, die durch ARIMA (Autoregressive Integrated Moving Average) Strukturen generiert werden können. Weiterhin erlauben sie im Gegensatz zu ARIMA-Modellen, auf einfache Weise Nichtlinearität zu be-

rücksichtigen und benötigen vor allem keine lange zeitliche Historie der Daten.¹⁵ Ein weiteres Argument für die Verwendung von Innovation-State-Space-Modellen ist, dass deren Punktprognosen bei bestimmten Konfigurationen identisch mit denen verschiedener exponentieller Glättungsmethoden sind, siehe Hyndman et al. (2002). Seit ihrer Entwicklung Ende der 1950er- und Anfang der 1960er-Jahre werden exponentielle Glättungsmethoden sehr häufig in der Praxis zu Prognosezwecken eingesetzt und schnitten in verschiedenen Prognosewettbewerben gut ab. Die State-Space-Modelle bieten eine theoretische Fundierung und erlauben, im Gegensatz zu exponentiellen Glättungsmethoden, auch die Berechnung von Prognoseintervallen.

Exemplarisch ergibt sich für die Beschäftigung in Berufe-Regionen-Kombination i in der Notation von Ord et al. (1997)

$$y_{it} = h(\mathbf{x}_{it-1}, \boldsymbol{\theta}) + k(\mathbf{x}_{it-1}, \boldsymbol{\theta})\varepsilon_{it}, \quad (6.25)$$

$$\mathbf{x}_{it} = \mathbf{f}(\mathbf{x}_{it-1}, \boldsymbol{\theta}) + \mathbf{g}(\mathbf{x}_{it-1}, \boldsymbol{\theta})\varepsilon_{it}, \quad (6.26)$$

mit Beobachtungsgleichung (6.25) für die Anzahl der Beschäftigten y_{it} zum Zeitpunkt t , der Zustandsgleichung (6.26), dem nichtbeobachtbaren Vektor der Zustandsvariablen \mathbf{x}_{it} , den unbekanntem Parametern $\boldsymbol{\theta}$ und dem Innovationsprozess $\{\varepsilon_{it}\}$ (siehe auch Hyndman et al. (2002) und Hyndman und Khandakar (2008)). Hyndman et al. (2002) zeigen, dass die Punktprognosen dieser State-Space-Modelle bei bestimmten Konfigurationen identisch mit denen verschiedener exponentieller Glättungsmethoden sind. Der nichtbeobachtete Zustandsvektor besteht dabei aus dem Level l und dem Trend w der Zeitreihe zum Zeitpunkt t , also $\mathbf{x}_{it} = (l_{it}, w_{it})'$. Für verschiedene Spezifikationen der Funktionen $h(\cdot)$, $k(\cdot)$, $\mathbf{f}(\cdot)$ und $\mathbf{g}(\cdot)$, die zu zwölf Konfigurationen führen, werden automatisch Prognosen erstellt. Anhand des AIC wird automatisch eine Konfiguration ausgewählt, mit der dann die Out-of-Sample-Prognosen erstellt werden. In Tabelle 6.1 auf der nächsten Seite sind die Konfigurationen für additive Fehler aufgeführt (hier gilt $k(\mathbf{x}_{it-1}, \boldsymbol{\theta}) = 1$). Für multiplikative Fehler wird $k(\mathbf{x}_{it-1}, \boldsymbol{\theta}) := h(\mathbf{x}_{it-1}, \boldsymbol{\theta})$ definiert.

¹⁵Die vorliegenden State-Space-Modelle gehen von einer nichtstationären Welt aus. Dementsprechend werden keine Einschwingphasen der Momente wie bei stationären Prozessen benötigt.

Tabelle 6.1.: Spezifikationen der State-Space-Modelle

Trendkomponente	State-Space-Spezifikation
ohne	$y_{it} = l_{it-1} + \varepsilon_{it}$ $\begin{pmatrix} l_{it} \\ w_{it} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} l_{it-1} \\ w_{it-1} \end{pmatrix} + \begin{pmatrix} \alpha \\ 0 \end{pmatrix} \varepsilon_{it}$
additiv	$y_{it} = l_{it-1} + w_{it-1} + \varepsilon_{it}$ $\begin{pmatrix} l_{it} \\ w_{it} \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} l_{it-1} \\ w_{it-1} \end{pmatrix} + \begin{pmatrix} \alpha \\ \alpha\beta \end{pmatrix} \varepsilon_{it}$
multiplikativ	$y_{it} = l_{it-1}w_{it-1} + \varepsilon_{it}$ $\begin{pmatrix} l_{it} \\ w_{it} \end{pmatrix} = \begin{pmatrix} l_{it-1}w_{it-1} + \alpha\varepsilon_{it} \\ w_{it-1} + \alpha\beta\varepsilon_{it}/l_{it-1} \end{pmatrix}$
gedämpft	$y_{it} = l_{it-1} + w_{it-1} + \varepsilon_{it}$ $\begin{pmatrix} l_{it} \\ w_{it} \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ 0 & \phi \end{pmatrix} \begin{pmatrix} l_{it-1} \\ w_{it-1} \end{pmatrix} + \begin{pmatrix} \alpha \\ \alpha\beta \end{pmatrix} \varepsilon_{it}$

6.6. Hierarchische Aggregation von Prognosen

Als ein weiterer wichtiger Baustein für das vorliegende Prognoseproblem mit einer Vielzahl möglicher Ansätze auf unterschiedlichen Aggregationsebenen kann das Gebiet „Forecast combination“ genannt werden. In erster Linie geht es dabei um die Kombination von Daten und Modellierungsansätzen gleicher oder unterschiedlicher zeitlicher Frequenz, siehe z. B. Clemen (1989), Diebold und Pauly (1990), Aiolfi et al. (2011) und Hendry und Hubrich (2011).

Die Idee der Top-down-Prognose liegt darin, zuerst eine Prognose des Aggregats zu erstellen – in unserem Fall die Beschäftigung insgesamt in Deutschland – und dieses Aggregat zu disaggregieren, d. h. auf die Berufe-Regionen-Kombinationen aufzuteilen. Das Aufteilen der Aggregatsprognose kann dabei auf verschiedene Arten bzw. nach verschiedenen Kennzahlen erfolgen. Der Argumentation von Athanasopoulos et al. (2009) folgend, verwenden wir dazu die prognostizierten Anteile der einzelnen Berufe-Regionen-Kombinationen. Diese Anteile werden in einem vorbereitenden Arbeitsschritt berechnet, bei dem Prognosen auf disaggregiertem Niveau erstellt werden. Durch die Verwendung von prognostizierten anstatt historischen Anteilen wird die in den Zeitreihen der Berufe-Regionen-Kombinationen enthaltene Information, z. B. über Auf- oder Abwärtstrends, direkt mitgenutzt. Weiterhin erlaubt diese Methode auf sehr einfache Weise, disaggregierte Prognose

sen für verschiedene Szenarien der aggregierten Beschäftigungsentwicklung zu erstellen. Ebenso lässt sich etwaiges Expertenwissen in Form von Korrekturen der Prognosen im ersten Arbeitsschritt berücksichtigen.

Aus statistischer Sicht bietet ein Top-down-Ansatz zudem den Vorteil, dass die Aggregatsprognose tendenziell genauer ist als die Prognosen auf disaggregiertem Niveau, da sich zufällige Schwankungen auf Ebene der Berufe-Regionen-Kombinationen durch die Aggregation ausgleichen. Im Jargon der Zeitreihenanalyse sagt man, dass die Zeitreihe des Aggregats somit „glatter“ ist. Grundlegende Annahme hierbei ist, dass alle Zeitreihen einem ähnlichen Muster folgen. Bei der vorliegenden Thematik der zeitlichen Entwicklung der Beschäftigtenzahlen ist genau dies aus sachlogischer Sicht sehr plausibel. Zeitreihenplots der Beschäftigtenzahlen zeigen persistente Muster für verschiedene Stufen der Disaggregation.

Ausgehend von den verschiedenen Aggregationsebenen für die Berufe und Regionen, lassen sich verschiedene hierarchische Strukturen kreieren. Eine mögliche Hierarchie für die Jones-Berufe und Agenturbezirke ist in Abbildung 6.1 dargestellt. Jeder Kreis stellt eine Zeitreihe dar. An der Spitze steht die Gesamtbeschäftigung in Deutschland, $y_{\bullet,\bullet}$. Auf Level 1 dieser Hierarchie wird nach Agenturbezirken differenziert und auf Level 2 wird zusätzlich nach Jones-Berufen unterschieden.

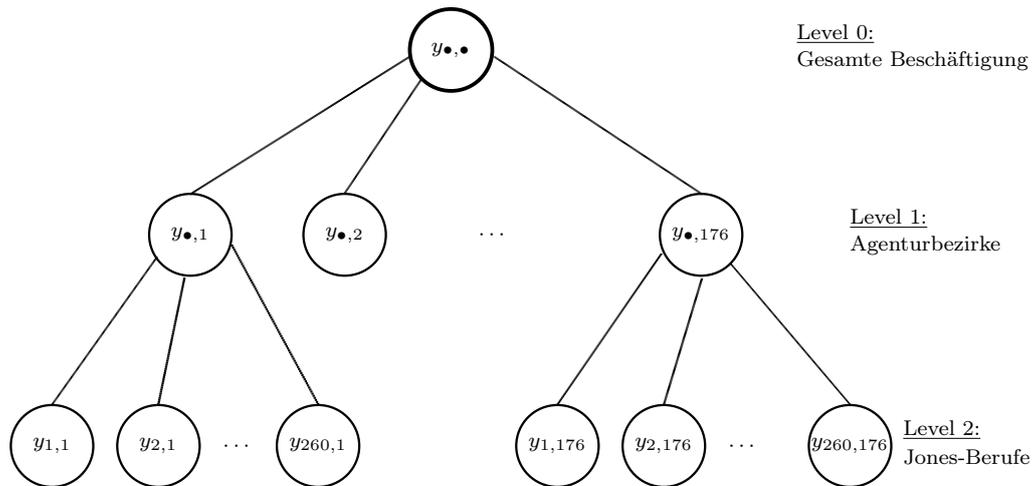


Abbildung 6.1.: Hierarchiebaum für die Jones-Berufe und Agenturbezirke

Im ersten Arbeitsschritt werden für alle Zeitreihen (auf dem jeweiligen Aggregationsniveau) – in diesem Beispiel $1 + 176 + 176 \cdot 260 = 45.937$ Prognosen – erstellt. Dabei können die unterschiedlichsten Methoden angewandt werden. Wie bereits erwähnt wurde, könnte beispielsweise auch Expertenwissen genutzt werden, um einzelne Prognosen anzupassen, z. B. indem etwa die Beschäftigtenzahlen

in bestimmten Berufe-Regionen-Kombinationen nach oben oder unten korrigiert werden. Zudem können auch (vorläufige) IST-Daten, die eventuell auf stark aggregierter Ebene mit größerer Aktualität verfügbar sind, in das Modell integriert werden. Derartige Techniken werden sehr erfolgreich auf dem Gebiet der MIDAS (*mixed data sampling*) Ansätze eingesetzt, siehe u. a. Ghysels et al. (2007) und die dort angegebene Literatur.

Im zweiten Arbeitsschritt werden die Anteile wie folgt berechnet: Bezugspunkt ist jeweils die nächsthöhere Aggregationsstufe, zu der die betrachtete Zeitreihe aggregiert wird. Beispielsweise berechnet sich der prognostizierte Anteil für Agenturbezirk $r = 1$ aus

$$\widehat{\text{Anteil}}(y_{\bullet,1}) = \frac{\widehat{y}_{\bullet,1}}{\sum_{r=1}^{176} \widehat{y}_{\bullet,r}}. \quad (6.27)$$

Bei der Berechnung der Anteile auf dem Level 2, also für die Berufe-Regionen-Kombinationen, stellen die 176 Agenturbezirke jeweils die Bezugspunkte dar. Somit berechnet sich der prognostizierte Anteil für Beruf $b = 1$ in Region $r = 1$ durch

$$\widehat{\text{Anteil}}(y_{1,1}) = \frac{\widehat{y}_{1,1}}{\sum_{b=1}^{260} \widehat{y}_{b,1}}. \quad (6.28)$$

Mit Level 1 beginnend, wird im dritten und letzten Arbeitsschritt die Prognose der Gesamtbeschäftigung $\widehat{y}_{\bullet,\bullet}$, den Aggregationsstufen des Hierarchiebaums hinabfolgend, aufgeteilt. Die endgültige Prognose für Region $r = 1$ ergibt sich demnach als

$$\widetilde{y}_{\bullet,1} = \widehat{y}_{\bullet,\bullet} \cdot \widehat{\text{Anteil}}(y_{\bullet,1}) \quad (6.29)$$

und die endgültige Prognose für Beruf $b = 1$ in Region $r = 1$ ergibt sich durch

$$\widetilde{y}_{1,1} = \widetilde{y}_{\bullet,1} \cdot \widehat{\text{Anteil}}(y_{1,1}). \quad (6.30)$$

Getrennt nach Arbeitszeit, wird die eben beschriebene Methode des Top-down nach prognostizierten Anteilen auf Ebene der Agenturbezirke und Jones-Berufe angewandt. Der zu erwartende Genauigkeitsgewinn hängt von der zusätzlichen Genauigkeit auf den höheren Aggregationsstufen ab. Im Rahmen dieses Projektes werden die Prognosen auf den höheren Aggregationsstufen durch einen Bottom-up-Ansatz gewonnen, d. h. Prognosen auf dem untersten Level werden sukzessive aggregiert. Die Aggregatsprognose $\widehat{y}_{\bullet,\bullet}$ auf der rechten Seite von Gleichung (6.29)

wird also gemäß

$$\hat{y}_{\bullet,\bullet} = \sum_{b=1}^B \sum_{r=1}^{R_b} \hat{y}_{b,r}$$

erstellt, mit B als Anzahl der Berufe und R_b als Anzahl der Regionen, in denen Beschäftigte des Berufs b arbeiten. Würde auf jedem Level des Hierarchiebaums dasselbe Modell ausgewählt, würden sich die Top-down-Prognosen nicht von den ursprünglichen Prognosen unterscheiden. Der Grund dafür ist, dass die Nenner bei der Berechnung der Anteile – als Folge der Konstruktion des Bottom-up-Ansatzes – gleich der Prognose des darüberliegenden Aggregats sind¹⁶.

Die hier beschriebene Struktur des Hierarchiebaums lässt sich auch variieren. So ist z. B. denkbar, auf Level 1 die Aggregation über Berufe anstatt über Regionen zu betrachten. Eine weitere Möglichkeit bestünde darin, den Baum um ein weiteres Aggregationslevel mit den Bundesländern¹⁷ zu erweitern. Im Prinzip ließe sich diese Methode für jeden Prognosehorizont individuell gestalten. Dabei könnten sich die Hierarchiebäume und/oder die Prognosemethoden bzw. -modelle auf den einzelnen Levels von Horizont zu Horizont unterscheiden.

¹⁶Essentiell ist, dass sich die Aggregatsprognosen auf den höheren Levels numerisch von der Summe der darunterliegenden Einzelprognosen unterscheiden.

¹⁷Die Bundesländer Bremen und Niedersachsen müssen jedoch zusammengelegt werden, da sich ein Agenturbezirk über die Ländergrenze hinweg erstreckt.

7. Konzeption der empirischen Analyse

In diesem Kapitel werden Fragen beantwortet, die für die Erstellung, Interpretation und Zuverlässigkeit der empirischen Ergebnisse von zentraler Bedeutung sind. Es wird diskutiert, welche Prädiktoren vorliegen und wie sich diese für Prognosezwecke fortschreiben lassen, siehe Abschnitt 7.1. Im Anschluss werden in Abschnitt 7.2 die Kriterien vorgestellt, anhand derer die Methoden verglichen werden.

7.1. Auswahl der Prädiktoren und deren Fortschreibung

In Abschnitt 3.5 wurde erläutert, welche weiteren Variablen neben den Beschäftigtenzahlen aus der BeH generiert werden:

`fem.share`, `young.num`, `old.num`, `smaco.share` und `dwage.med`

Diese werden als Prädiktoren für das parametrische Paneldatenmodell

$$\log(y_{brt}) = \sum_{j=2}^B \kappa_j D_{b,j} + \sum_{k=2}^R \eta_k D_{r,k} + \sum_{l=2}^T \lambda_l D_{t,l} + \gamma x'_{brt} + u_{brt},$$

verwendet, siehe Abschnitt 6.3.

Zur Berechnung der Punktprognose $\log(\widehat{y_{brT+p}})$ werden die zukünftigen Werte der Prädiktoren x_{brT+p} und der Wert des Parameters λ_{T+p} benötigt. Für die unabhängigen Prädiktoren und den geschätzten Parametervektor $\hat{\lambda} = (\hat{\lambda}_1 \ \hat{\lambda}_2 \ \cdots \ \hat{\lambda}_T)$ werden State-Space-Modelle (siehe Abschnitt 6.5) geschätzt und deren Prognosen verwendet.

Für die verzögerte Beschäftigung wird ab einem Prognosehorizont $p > 1$ ebenfalls eine Prognose benötigt. Entweder kann die Plug-in-Methode zum Einsatz

7. Konzeption der empirischen Analyse

kommen, bei der schrittweise die Prognose des jeweiligen Paneldatenmodells verwendet wird, oder die Beschäftigtenzahlen werden in einem ersten Schritt separat außerhalb des Modells fortgeschrieben und diese Prognosen gehen dann als Prädiktoren in das Paneldatenmodell ein.

Die Verwendung zeitlich verzögerter Werte der y_{brt} als Prädiktoren ist nicht unproblematisch. Plug-in-Methoden, die beginnend mit $p = 2$ die prognostizierten Werte der Beschäftigung schrittweise als beobachtet annehmen, sind im Allgemeinen verzerrt, siehe z. B. Elliott und Timmermann (2008). Direkte p -Schritt-Prognosen mit verzögerten Werten der zu prognostizierenden Variable benötigen typischerweise einen großen Wert für T und leiden im Allgemeinen unter Ineffizienz. Dennoch wird in der vorliegenden Arbeit die im Kontext der linearen Prozesse übliche Plug-in-Methode verwendet, vgl. z. B. Schanne et al. (2010), die zur Prognose der regionalen Arbeitslosigkeit eine (räumliche) vektorautoregressive Modellierung nutzen. Ein Vergleich der resultierenden Out-of-Sample-Prognosen zeigt zudem, dass die Plug-in-Methode gegenüber der Verwendung von State-Space-Prognosen der verzögerten Beschäftigtenzahlen vorzuziehen ist. Da sich die Verteilung der Punktprognosen von State-Space-Modelle (sowohl analytisch als auch mit Bootstrap) berechnen lässt, könnten jedoch bei Bedarf Quantile dieser Verteilung als Szenarien verwendet werden.

Die Analyse zur Auswahl der Prädiktoren geschieht auf Ebene der Blossfeld-Berufe und Bundesländer. Begründet wird dies mit den hohen Rechenzeiten zur Generierung der Prädiktoren (im Speziellen `dwage.med`) und den Rechenzeiten für die Prognosen.

7.2. Vergleich von Prognosen

Der Vergleich verschiedener Modelle/Methoden in der Anwendung ist nur auf den ersten Blick einfach: Man erstellt Prognosen und vergleicht diese mit den zukünftigen Realisationen. Problematisch wird es bei der Festlegung „Was“ und „Wie“ man vergleichen will.

Die zentralen Begriffe in diesem Zusammenhang sind:

- Spezifikation der Verlustfunktion \Leftrightarrow Auswahl des Genauigkeitsmaßes
- Beurteilung der Prognosegüte, In-Sample versus Out-of-Sample
- Prognosehorizont

- Vergleich über mehrere Zeitreihen
- Signifikanz der Unterschiede
- Vergleich von mehr als zwei Methoden: Benchmarking

Verlustfunktion Ohne die Spezifikation einer Verlustfunktion ist es nicht möglich, die Qualität einer Prognose zu beurteilen. Folgendes Beispiel verdeutlicht dies auf einfache Art und Weise.

Beispiel: In einer Urne befinden sich 101 identische Kugeln mit den Zahlen 0 bis 100. Die Prognoseaufgabe besteht darin, zu erraten, welche Zahl gezogen wird. Da alle Zahlen mit derselben Wahrscheinlichkeit gezogen werden können, scheint jeder Tipp gleich gut zu sein. Ob man seine Lieblingszahl tippt, den Geburtstag der Mutter wählt oder den Erwartungswert berechnet, sollte also egal sein. Dieser Argumentation liegt die Annahme zugrunde, dass es keinen Unterschied macht, ob der Tipp kleiner oder größer als die gezogene Zahl ist. Ebenso scheint es irrelevant, ob man um 17 oder um 87 danebentippt hat. Folgende Verlustfunktion L würde zu dieser Situation passen:

$$L(\text{richtig geraten?}) = \begin{cases} 0 & , \text{ falls richtig geraten} \\ X & , \text{ falls nicht.} \end{cases} \quad (7.1)$$

Die Höhe des Verlusts X ist unabhängig davon, wie weit der Tipp und gezogene Zahl auseinanderliegen. Erhält man aber zu Beginn 100 Euro und verliert davon die absolute Differenz zwischen Tipp und gezogener Zahl, ändert sich die Verluststruktur und kann folgendermaßen modelliert werden:

$$L(|\text{Differenz}|) = 100 \text{ Euro} - |\text{Differenz}| \quad (7.2)$$

Minimiert man den erwarteten Verlust, ist nun der beste Tipp die Zahl 50.

Generell hängt die Verlustfunktion L von der Prognose $\hat{y}_{t+p|t}$ und der Realisation y_{t+p} ab. Der Doppelindex $t+p|t$ gibt an, für welchen Zeitpunkt die Prognose erstellt wird ($t+p$) und welche Informationsmenge dazu genutzt wird (die zum Zeitpunkt t zur Verfügung stand). Um die Notation einfach zu halten, wird der Index für die Berufe-Regionen-Kombination erst verwendet, wenn es nötig ist.

Das Standardbeispiel in vielen Lehrbüchern ist die quadratische Verlustfunktion

$$L(y_{t+p}, \hat{y}_{t+p|t}) = (y_{t+p} - \hat{y}_{t+p|t})^2 = e_{t+p|t}^2. \quad (7.3)$$

7. Konzeption der empirischen Analyse

Die quadratische Verlustfunktion ist dann geeignet, wenn der Verlust überproportional mit der Größe des Fehlers $e_{t+p|t}$ zunimmt und dessen Vorzeichen keine Rolle spielt. Zwei andere intuitiv verständliche symmetrische Verlustfunktionen verwenden den absoluten Fehler

$$L(y_{t+p}, \hat{y}_{t+p|t}) = |e_{t+p|t}| \quad (7.4)$$

bzw. den absoluten prozentualen Fehler

$$L(y_{t+p}, \hat{y}_{t+p|t}) = \frac{|e_{t+p|t}|}{y_{t+p}} 100. \quad (7.5)$$

Laut Diebold (2007, S. 37) wird die quadratische Verlustfunktion oft verwendet, weil mit ihr die echten Verluste häufig gut approximiert werden und weil man einfach mit ihr rechnen kann. Das einfache Rechnen ist dabei wahrscheinlich von größerer Bedeutung, denn Diebold und Mariano (1995) schreiben in ihrer Einleitung, dass realistische ökonomische Verlustfunktionen regelmäßig nicht quadratisch sind und dies angeblich weithin bekannt sei. Ganz verschwiegen wird dies aber auch in dem einführenden Lehrbuch Diebold (2007) nicht, auf S. 38 wird darauf hingewiesen, dass es durchaus Situationen gibt, in denen z. B. nur ein Unterschätzen negative Konsequenzen nach sich zieht.

Beurteilung der Prognosegüte, In-Sample versus Out-of-Sample Nachdem die Verlustfunktion spezifiziert ist, kann die Qualität einer Prognose quantifiziert werden. Angenommen, es stehen zwei Methoden, A und B, zur Verfügung, die beide numerisch unterschiedliche Prognosen ergeben haben, $\hat{y}_{t+p|t}^{(A)}$ und $\hat{y}_{t+p|t}^{(B)}$. Über den Vergleich

$$L\left(y_{t+p}, y_{t+p|t}^{(A)}\right) \stackrel{?}{\leq} L\left(y_{t+p}, y_{t+p|t}^{(B)}\right)$$

lässt sich eine Aussage darüber treffen, welcher der beiden Werte $y_{t+p|t}^{(A)}$ und $y_{t+p|t}^{(B)}$ zu einem kleinen Verlust geführt hat. Essentiell ist, dass lediglich entschieden wird, welcher der prognostizierten Werte für exakt die beobachtete Realisation als besser zu bewerten ist.

Um zu beurteilen, welche der beiden Methoden im Allgemeinen die besseren Prognosen liefert, reicht der Vergleich von nur einer Prognose nicht aus. Als Kriterium der Prognosegüte einer Methode kann z. B. der erwartete Verlust zum Einsatz kommen. Dieser kann unter Nutzung zwei verschiedener Arten von Pro-

gnosefehlern abgeschätzt werden: In-Sample-Prognosefehler und Out-of-Sample-Prognosefehler. Die beiden unterscheiden sich dadurch, welche Informationsmenge zur Erstellung der Prognose herangezogen wurde. Bei einer In-Sample-Prognose ist der zu prognostizierende Wert schon beobachtet. In der Notation mit der Angabe der verwendeten Informationsmenge lassen sich die In-Sample-Prognosen so aufschreiben: $\hat{y}_{t|T}$ mit $t = 1, 2, \dots, T$, wobei die Werte y_t alle beobachtet sind und somit zur Informationsmenge des Zeitpunkts T gehören. Treffender als In-Sample-Prognosefehler ist die Bezeichnung Anpassungsfehler.

Vergleicht man die Anpassungsfehler verschiedener Methoden miteinander, besteht die Gefahr des *Overfitting*. Damit ist gemeint, dass eine Methode gewählt wird, deren In-Sample-Prognosen relativ nah an den Beobachtungen liegen, aber die Out-of-Sample-Prognosen relativ schlecht sind, vgl. Tashman (2000) oder Franses (2000, S. 65). Daher sollten nach Möglichkeit immer Out-of-Sample-Prognosefehler genutzt werden, um die Prognosegüte einer Methode abzuschätzen, vgl. Stock (2003, S. 566). Problematisch wird dies, wenn die zeitlichen Abstände zwischen den Beobachtungen sehr groß sind. Handelt es sich um Jahresdaten, wird jedes Jahr nur ein Out-of-Sample-Fehler beobachtet. Um auch in solchen Situationen ausreichend Out-of-Sample-Fehler berechnen zu können, werden artifizielle Out-of-Sample-Projektionen erstellt. Diese Idee ist in Abbildung 7.1 dargestellt. Es liegen Beobachtungen für die Jahre von 1992 bis 2008 vor. Zur Berechnung der artifiziellen Out-of-Sample-Projektion wird die Zeitreihe in einen Schätzdatensatz

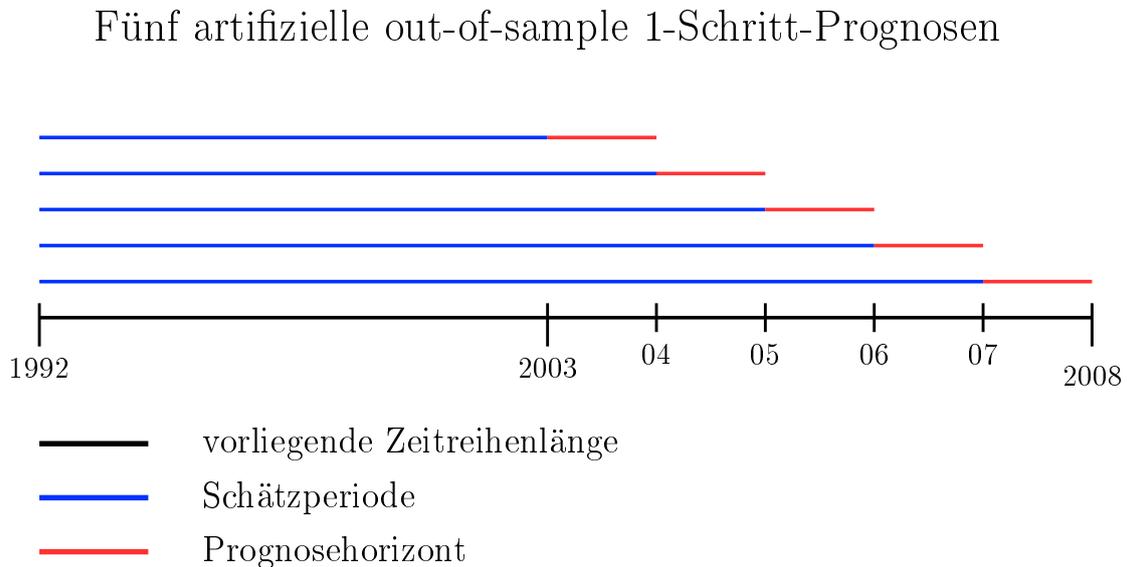


Abbildung 7.1.: Fünf artifizielle Out-of-Sample-1-Schritt-Prognosen

7. Konzeption der empirischen Analyse

(in Blau angedeutet) und einen Validierungsdatensatz (in Rot angedeutet) aufgeteilt. Für einen Prognosehorizont von $p = 1$ können auf diese Art fünf artifizielle Out-of-Sample-Prognosefehler berechnet werden. Die Bezeichnung artifizielle Out-of-Sample-Projektion ist bewusst gewählt, um zu verdeutlichen, dass ein solches Vorgehen nur für mathematische Methoden genutzt werden kann. Für Methoden, die Expertenwissen nutzen, ist es nicht möglich, artifizielle Out-of-Sample-Prognosen zu erstellen. Die Informationsmenge, also das Wissen des Experten, lässt sich nicht künstlich verringern.

Wird beispielsweise die quadratische Verlustfunktion unterstellt, lässt sich die Prognosegüte über den mittleren quadratischen Prognosefehler (engl. *mean squared error of prediction*¹)

$$MSEP = \frac{1}{(T - p + 1) - \mathcal{T}} \sum_{t=\mathcal{T}}^{T-p} e_{t+p|t}^2 \quad (7.6)$$

abschätzen, bei dem die Out-of-Sample-Prognosefehler verwendet werden. T ist die Länge der gesamten Zeitreihe und \mathcal{T} gibt die Anzahl der Beobachtungen an, welche mindestens zur Parameterschätzung bzw. zur Projektion verwendet werden. Anstatt die Bezeichnung artifiziell, könnte man auch von Out-of-*Estimation*-Sample-Fehlern sprechen, wobei das Estimation-Sample eine entsprechend gekürzte Version der ursprünglichen Zeitreihe ist.

Die Berechnung von artifiziellen Prognosefehlern erlaubt zwar das Abschätzen der Prognosegüte, ohne auf neue Beobachtungen warten zu müssen, aber falls die beobachteten Zeitreihen recht kurz sind, lässt sich nur eine kleine Zahl an Out-of-Sample-Fehlern berechnen. Dementsprechend unsicher ist die resultierende Schätzung der Prognosegüte.

Fildes (1992) schlägt vor, die Vergleiche separat für die In-Sample- und die Out-of-Sample-Fehler durchzuführen. Er führt aus, dass die In-Sample-Fehler genutzt werden sollten, um die Anzahl der zu vergleichenden Methoden einzugrenzen und die endgültige Entscheidung für eine Methode anhand der Out-of-Sample-Fehler geschehen sollte. Ähnliches ist bei Chatfield (2001) in Kapitel 6 zu lesen. Nach ihm werden die In-Sample-Fehler genutzt, falls nur eine Methode auf ihre Taug-

¹In der Literatur wird dieser auch *mean squared prediction error*, z. B. in Hubrich und West (2010), *mean squared forecast error*, z. B. Stock und Watson (2004) oder *prediction mean square error*, z. B. in (Chatfield, 2001, Kapitel 6), genannt. Wenn sich aus dem Kontext ergibt, ob Anpassungs- oder Prognosefehler gemeint sind, wird mitunter nur *mean squared error* verwendet, z. B. in Makridakis et al. (1982).

lichkeit geprüft wird und die Out-of-Sample-Fehler, um verschiedene Methoden in Relation zu setzen. Eine weitere Möglichkeit besteht darin, bei ähnlich guten Out-of-Sample-Projektionen die In-Sample-Fehler zu vergleichen. Auf diese Art verringert man das Risiko, eine Methode auszuwählen, welche nur rein zufällig gute Out-of-Sample-Projektionen geliefert hat.

Prognosehorizont Im Rahmen dieses Forschungsprojekts werden Beschäftigtenprognosen für bis zu fünf Jahre über das Ende des Beobachtungszeitraums hinaus verlangt. Makridakis et al. (1982) werten die Resultate eines Vorhersagewettbewerbs aus. Eines der Ergebnisse ist, dass sich einige Methoden anscheinend besonders gut für kurzfristige Projektionen eignen, aber schlechte Langfrist-Projektionen liefern, und für andere Methoden das Umgekehrte gilt.

Aus diesen Gründen werden in der vorliegenden Arbeit mit allen Methoden 1-Schritt- bis 5-Schritt-Projektionen erstellt und ausgewertet. Da die Zeitreihen relativ kurz sind (16 Beobachtungen), werden mindestens 10 Beobachtungen als Trainings-Daten verwendet.

Vergleich über mehrere Zeitreihen Eine Umfrage aus dem Jahr 1981 unter den 500 Besuchern des First International Symposium on Forecasting zeigte, dass das am häufigsten genannte Genauigkeitsmaß die Quadratwurzel des *MSEP* war, vgl. Carbone und Armstrong (1982). Armstrong und Collopy (1992) untersuchen mehrere Genauigkeitsmaße und kommen zu dem Schluss, dass die Quadratwurzel des *MSEP* nicht geeignet ist, wenn der Vergleich über mehrere Zeitreihen hinweg stattfindet. Der Grund dafür ist, dass sich der *MSEP* mit der Skalierung ändert und somit die Fehler von Zeitreihen mit sehr großen Zahlen den Vergleich dominieren können, vgl. Chatfield (1988) und Tashman (2000). Aus diesem Grund sollten nur Genauigkeitsmaße verwendet werden, welche unabhängig von der Skalierung sind. Ein Beispiel hierfür ist der mittlere absolute prozentuale Prognosefehler (engl. *mean absolut percentage error of prediction*)

$$MAPEP = \frac{1}{(T - p + 1) - \mathcal{T}} \sum_{t=\mathcal{T}}^{T-p} \frac{|e_{t+p|t}|}{y_{t+p}} 100. \quad (7.7)$$

Die mit diesem Maß verbundene Verlustfunktion in Gleichung (7.5) ist nicht symmetrisch. Ein Überschätzen wird stärker bestraft als ein Unterschätzen. Besonders gravierend fällt dies ins Gewicht, wenn die Realisationen sehr kleine Werte anneh-

7. Konzeption der empirischen Analyse

men. Im Extremfall eines Wertes von Null ist der $MAPEP$ nicht definiert.

Beim Vergleich von verschiedenen Projektionsmethoden über sehr viele Zeitreihen hinweg werden die $MAPEPs$ typischerweise über alle Zeitreihen gemittelt. Bei einer solchen Verdichtung an Informationen bleiben wichtige Ergebnisse unter Umständen verdeckt. Verdeutlicht wird dies anhand eines fiktiven Beispiels.

Um den $MAPEP$ einer einzelnen Zeitreihe von dem über alle Zeitreihen gemittelten $MAPEP$ zu unterscheiden, wird an dieser Stelle ein Überstrich verwendet:

$$\overline{MAPEP} = \frac{1}{N} \sum_{i=1}^R MAPEP_i, \quad (7.8)$$

dabei ist N die Anzahl der Zeitreihen und der Index i steht für die einzelnen Zeitreihen.

Es sollen zwei Methoden (A und B) anhand des \overline{MAPEP} miteinander verglichen werden. Der \overline{MAPEP} für Methode A sei 5% und der von Methode B 4%. Damit lässt sich argumentieren, dass Methode B besser als Methode A ist. In Abbildung 7.2 sind fiktive Boxplots der $MAPEPs$ aller Zeitreihen für die beiden Methoden dargestellt. Die roten Striche zeigen die \overline{MAPEPs} an. Es ist deutlich zu erkennen, dass die $MAPEPs$ der Methode B eine sehr viel größere Streuung aufweisen als die der Methode A. Außerdem ist zu erkennen, dass der Median von Methode A etwas kleiner ist als der von Methode B. Der Grund für den größeren \overline{MAPEP} von Methode A ist ein Ausreißer bei ca. 20%. Die scheinbar eindeutige Entscheidung zugunsten von Methode B ist nach Betrachtung der Boxplots nicht

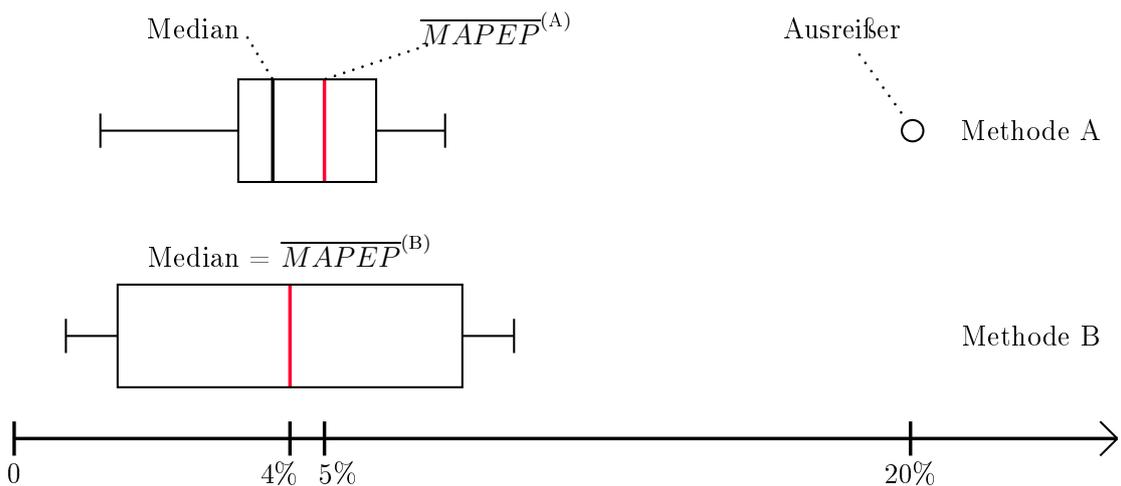


Abbildung 7.2.: Vergleich von zwei Methoden anhand der \overline{MAPEPs}

aufrechtzuerhalten. Der Vergleich ist nicht mehr eindeutig.

Um den Einfluss von Ausreißern zu verringern, schlägt Chatfield (2001, Kapitel 6.3) vor, anstatt des arithmetischen das geometrische Mittel der absoluten prozentualen Fehler zu berechnen. Auch Fildes (1992) und Armstrong und Collopy (1992) schlagen Genauigkeitsmaße auf Basis von geometrischen Mitteln vor. Ebenso könnten die Mediane der absoluten prozentualen Prognosefehler verglichen werden.

Da der Vergleich von solchen Kennzahlen ohnehin rein deskriptiv ist, erscheint es sinnvoll, Boxplots der absoluten prozentualen Prognosefehler zu erstellen und diese miteinander zu vergleichen. Anstatt hier eine vollständige Liste aller statistischen Genauigkeitsmaße mit ihren Vor- und Nachteilen zu erstellen, wird noch darauf hingewiesen, dass die Rangfolge verschiedener Methoden je nach verwendetem Genauigkeitsmaß variieren kann, vgl. Makridakis et al. (1982), Makridakis et al. (1993), Makridakis und Hibon (2000) oder Chatfield (2001, Kapitel 6.3). Dennoch messen sie im Prinzip alle das Gleiche, nämlich die Prognosegenauigkeit, vgl. Armstrong und Collopy (1992).

Um in der Lage zu sein, im Nachhinein noch andere Genauigkeitsmaße zu berechnen, werden für jede Methode nicht nur die Prognosefehler, sondern auch die Projektionen gespeichert. Diese Entscheidung mag nebensächlich wirken, da die Prognosen jederzeit erneut berechnet werden können. Aufgrund der immensen Datenmenge und der Vielzahl an Prognosen, die erstellt werden müssen, benötigen die Berechnungen jedoch mehrere Stunden oder auch Tage.

Signifikanz Ein weiterer wichtiger Punkt ist die Frage, ob die resultierenden Unterschiede, d. h. die Differenzen zwischen den Genauigkeitsmaßen verschiedener Methoden, signifikant sind. Diebold und Mariano (1995) merken an, dass fast alle Studien zur Prognosegenauigkeit verschiedener Methoden diesen Aspekt vernachlässigen und nur die Punktschätzer (eben die Genauigkeitsmaße) vergleichen, ohne dabei auf die Unsicherheit der Schätzung einzugehen. Sie stellen einen asymptotischen Test vor, welcher für verschiedenste Verlustfunktionen anwendbar ist.

Die Null-Hypothese ist, dass die Genauigkeit von zwei betrachteten Projektionsmethoden A und B gleich ist:

$$H_0 : \quad \mathbb{E} \left[L(y_{t+p}, \hat{y}_{t+p|t}^{(A)}) \right] = \mathbb{E} \left[L(y_{t+p}, \hat{y}_{t+p|t}^{(B)}) \right]. \quad (7.9)$$

Mithilfe der Verlustdifferenz

$$d_{t+p} = L(y_{t+p}, \hat{y}_{t+p|t}^{(A)}) - L(y_{t+p}, \hat{y}_{t+p|t}^{(B)}) \quad (7.10)$$

kann die H_0 umgeschrieben werden zu

$$H_0 : \quad E [d_{t+p}] = 0. \quad (7.11)$$

Unter der Annahme, dass der Prozess d_{t+p} ein kurzes Gedächtnis hat und kovarianzstationär ist, lässt sich für lange Zeitreihen eine Teststatistik aufstellen, mit der die Hypothese (7.11) getestet werden kann. Für unsere Situation ergeben sich daraus zwei Probleme. Erstens, wir haben nur wenige Out-of-Sample-Prognosefehler zur Verfügung, und zweitens beinhaltet die Teststatistik die Autokovarianz von d_{t+p} . Somit ist nicht klar, inwieweit sich dieser Test auch für den Vergleich über mehrere Zeitreihen hinweg anwenden lässt. Dieselben Einwände werden in Chatfield (2001, Kapitel 6.3.1) angeführt. Wird nur eine Zeitreihe untersucht und liegen wenige Out-of-Sample-Fehler vor, werden sämtliche Tests eine schwache Trennschärfe haben, d. h., die Fehler 2. Art werden sehr groß sein. Geschieht der Vergleich über mehrere Zeitreihen hinweg, ist es sehr wahrscheinlich, dass verschiedene Annahmen, die für die Tests benötigt werden, nicht erfüllt sind. Aus diesen Gründen verzichten wir darauf, Signifikanztests durchzuführen.

Benchmarking Die bisherige Diskussion konzentrierte sich auf den Vergleich von zwei Methoden. In dieser Arbeit kommen jedoch mehr als nur zwei Methoden zum Einsatz. Anstatt die Methoden bzw. ihre Projektionen paarweise zu vergleichen, kann eine Referenzmethode bestimmt werden, um das Abschneiden aller übrigen Methoden in Relation zu den Referenzprojektionen zu setzen. Dieses Vorgehen wird von Tashman (2000) vorgeschlagen, wenn die betrachteten Zeitreihen unterschiedlich stark schwanken. Auch Armstrong und Fildes (1995) kommen zu dem Schluss, dass relative Genauigkeitsmaße beim Vergleich über Zeitreihen hinweg angewandt werden sollten. Makridakis und Hibon (2000) benutzen in der M3-Competition die naive Status-quo-Projektion² und Dampend Trend Exponential Smoothing (siehe Gardner und McKenzie (1985)) als Referenzen. In der vorliegenden Arbeit wird auch die naive Status-quo-Projektion als Referenz gesetzt, da sie zwei Vorteile hat: Zum einen liefert sie ganzzahlige Projektionen und zum anderen

²Optimal für den Random-Walk und daher auch Random-Walk-Projektion genannt.

wird die Fortschreibung extremer Trends vermieden.

Ein Genauigkeitsmaß, das in diesem Rahmen oft verwendet wird, zählt aus, wie oft eine zu evaluierende Methode bessere Projektionen liefert als die naive Status-quo-Projektion. Anschließend wird diese Zahl ins Verhältnis zu der Gesamtzahl an Projektionen gesetzt. Dieses Maß wird *Percent Better* genannt. Es liegt zwischen Null und Eins, wobei größere Werte besser sind. Zwei Eigenschaften machen dieses Maß besonders attraktiv. Erstens ist es leicht zu berechnen und zu interpretieren, und damit gut zu kommunizieren. Und zweitens ist es robust gegenüber Ausreißern, da weder die Größe der Differenz der beiden Projektionen noch die Größe des Prognosefehlers in die Berechnung eingehen.

Anhand von relativen Genauigkeitsmaßen vergleichen Tashman und Kruk (1996) verschiedene Exponential Smoothing Methoden miteinander. Die Referenz bilden naive Status-quo-Projektionen. Ihre Fehler sollen dabei als Proxy für die Volatilität der einzelnen Zeitreihen dienen. In ihrer Argumentation schließen sie von hoher Volatilität auf schlechte Projizierbarkeit. Analog zur Begründung für die Verwendung von prozentualen Fehlern beim Vergleich über mehrere Zeitreihen unterschiedlicher Skalenniveaus, sollten beim Vergleich über mehrere Zeitreihen unterschiedlicher Projizierbarkeit relative Fehler verwendet werden. Ansonsten besteht die Gefahr, dass einige besonders schlecht zu projizierende Zeitreihen den Vergleich dominieren. Anstatt des recht simplen *Percent Better* berechnen sie zuerst für jede Zeitreihe den *MAPEP* für alle Methoden und teilen diese jeweils durch den *MAPEP* der Referenzmethode (hier die naive Status-quo-Projektion) und nennen dieses Maß *relative absolut error*. Diese werden dann entweder über alle Zeitreihen geometrisch gemittelt, oder es wird lediglich der Median angegeben.

Einen Kritikpunkt bei dieser Argumentation ist der Rückschluss von Volatilität auf Projizierbarkeit. Zeitreihen mit sehr starken, aber regelmäßigen saisonalen Schwankungen weisen eine hohe Volatilität auf, sind jedoch möglicherweise sehr einfach und genau zu projizieren. Ähnliches gilt für stark trendbehaftete Zeitreihen: Die naiven Status-quo-Prognosefehler werden typischerweise recht groß im Vergleich zu den Fehlern von Trend-Modellen sein. Daher ist es wichtig, bei solchen relativen Fehlern ein gutes Abschneiden einer Methode kritisch zu betrachten. Dennoch scheinen relative Fehler für den Vergleich mehrerer Methoden geeignet zu sein, die alle in Relation zu einer Referenzmethode gesetzt wurden.

Fazit Im Rahmen des IAB-Forschungsprojektes „Projektion berufsspezifischer Arbeitsnachfrage“ werden Projektionen für Zeiträume bis zu 5 Jahren verlangt. Aus diesem Grund scheint es sinnvoll, die Methoden anhand der 5-Schritt-Prognosefehler miteinander zu vergleichen. Frühere empirische Arbeiten haben gezeigt, dass Methoden, die gut in der langen Frist sind, nicht zwangsläufig gut in der kurzen Frist sind. Daher werden nicht nur die 5-Schritt-Projektionen verglichen, sondern auch alle kürzeren Horizonte.

Da der Vergleich über eine große Anzahl an Zeitreihen unterschiedlicher Skalierung geschieht, werden keine Genauigkeitsmaße, die von der Skalierung abhängen, verwendet.

Unterschiedliche Genauigkeitsmaße können zu unterschiedlichen Ergebnissen beim Vergleich zwischen Methoden führen, daher werden für jede Methode die Out-of-Sample-Projektionen gespeichert. Auf diese Art lassen sich im Nachhinein weitere Genauigkeitsmaße berechnen, ohne dass die mit großem zeitlichen Aufwand verbundenen Out-of-Sample-Prognosen erneut erstellt werden müssen. In dieser Arbeit werden vorrangig die absoluten prozentualen Prognosefehler (*APEPs*)

$$APEP = \begin{cases} \frac{|y_{t+p} - \hat{y}_{t+p|t}|}{y_{t+p}} 100 & \text{falls } y_{t+p} \neq 0 \\ 0 & \text{falls } y_{t+p} = 0 = \hat{y}_{t+p|t} \\ \text{missing / nicht definiert} & \text{falls } y_{t+p} = 0 \neq \hat{y}_{t+p|t} \end{cases} \quad (7.12)$$

verwendet. Im Gegensatz zur gängigen Praxis werden neben den Vergleichen der über alle Zeitreihen gemittelten *MAPEPs* (der Überstrich wird von hier an weggelassen) auch visuelle Vergleiche anhand von Boxplots der *APEPs* angestellt.

8. Resultate für die Prognosevergleiche¹

Abschließend wird nun die Güte der einzelnen Prognosevorschriften evaluiert und die Frage geklärt, ob sich aus der Verwendung verschiedener statistischer Kriterien zur Evaluation der p -Schritt-Prognosefähigkeit ein klares Bild ergibt. Die Analysen werden auf Ebene der Blossfeld-Berufe und Bundesländer begonnen. Nach der Wahl der besten parametrischen Modellspezifikation wird die Prognosegüte der parametrischen, nichtparametrischen und semiparametrischen Prognoseverfahren verglichen. In Abschnitt 8.2 werden die Analysen auf Ebene der Jones-Berufe und Agenturbezirke wiederholt und zusätzlich das Verfahren Top-down angewandt und ausgewertet. Begründet wird diese Vorgehensweise zum einen mit dem erheblich geringeren Rechenaufwand auf Ebene der Blossfeld-Berufe und Bundesländer und zum anderen lässt sich so einschätzen, inwieweit der Einfluss von zufälligen Störungen auf die Prognosegenauigkeit mit dem Grad an Disaggregation zunimmt.

8.1. Blossfeld-Berufe und Bundesländer

Begonnen wird die Analyse auf Ebene der 12 Blossfeld-Berufe und der 16 Bundesländer. Das bedeutet, es werden Prognosen für 192 Berufe-Regionen-Kombinationen erstellt. Die in diesem Arbeitspapier vorgestellten Analysen wurden Mitte 2010 gestartet. Zu dem Zeitpunkt standen nur Daten bis 2008 zur Verfügung. Die präsentierten Resultate beziehen sich auf Analysen der Daten bis 2008.²

8.1.1. Prädiktorenauswahl für das parametrische Modell

Als Erstes wird aus der Klasse an linearen Modellen, die zusätzliche Prädiktoren enthalten, eine Vorauswahl getroffen. Nur die Spezifikation mit der besten

¹Dieses Kapitel stammt aus Jones et al. (2013).

²Siehe R-Skripte: `Panel_Forecast_vz.R` und `Panel_Forecast_gtz.R`

8. Resultate für die Prognosevergleiche

Prognose-Performance wird mit den anderen Modellen verglichen. Die fünf zusätzlichen Prädiktoren (vgl. Abschnitt 3) erlauben 31 mögliche Kombinationen.

Vollzeit Tabelle A.22 auf Seite 163 enthält für alle Kombinationen die Informationskriterien *AIC* und *SIC*, welche die Anpassungsgüte des Modells anzeigen. Hierbei wurden alle vorliegenden Daten zur Schätzung herangezogen. Aus dieser Tabelle wird deutlich, dass die Spezifikationen, welche den Prädiktor `dwage.med` enthalten, eine überlegene Anpassungsgüte (kleinere Werte der Informationskriterien) aufweisen. In Gelb ist jeweils das Minimum und somit die beste Spezifikation markiert; der zweitkleinste Wert ist jeweils in Grün markiert. Gemäß *SIC* werden zudem Spezifikationen bevorzugt, die nur ein oder zwei Prädiktoren enthalten, was plausibel ist, da zusätzliche Kovariablen beim *SIC* stärker bestraft werden als beim *AIC*. Eine Modellspezifikation anhand der Anpassungsgüte auszuwählen, kann zum Problem des Overfitting führen. Typisch dabei ist, dass die vorhandenen Daten sehr gut beschrieben werden, die Out-of-Sample-Prognosen jedoch sehr schlecht sind.

Tabelle A.23 auf Seite 164 enthält die, anhand des *MAPEP* abgeschätzte, Prognosegüte für die fünf Prognosehorizonte $p \in \{1, \dots, 5\}$ sowie den Mittelwert über diese fünf Einträge. Aus Tabelle A.23 wird ersichtlich, dass gerade die Spezifikationen, die relativ gute Werte bei der Anpassungsgüte aufweisen, eine schlechte Prognosegüte aufweisen. Insbesondere alle Modelle, die den Median des Tageslohns (`dwage.med`) als Prädiktor enthalten, weisen eine schlechte Prognosegüte auf. Dies kann unter anderem damit begründet sein, dass der Prädiktor selbst schwierig fortzuschreiben ist. Tendenziell weisen die Modelle, die weniger zusätzliche Prädiktoren verwenden, eine bessere Prognosegüte auf. Für die weiteren Auswertungen verwenden wir nur das Modell `lm2-1`, welches lediglich den Anteil der weiblichen Beschäftigten (`fem.share`) als zusätzlichen Prädiktor enthält, da dieses Modell für alle fünf Prognosehorizonte jeweils den geringsten *MAPEP* aufweist.

Große Teilzeit Analog zu dem Vorgehen bei den Vollzeitbeschäftigten wird für die Beschäftigten in Großer Teilzeit verfahren. In Tabelle A.24 auf Seite 165 ist die Anpassungsgüte anhand der Informationskriterien für alle Prädiktor-Kombinationen zu finden. Hier haben Spezifikationen, welche als Prädiktor den Anteil an Beschäftigten in kleinen Unternehmen (`smaco.share`) enthalten, eine überlegene Anpassungsgüte. Auch hier sind die jeweils bevorzugten Spezifikationen gelb

markiert. Der Vergleich anhand des *MAPEP* zeigt jedoch, dass die genauesten Projektionen im Mittel durch das Modell mit der Anzahl an alten Beschäftigten (`old.num`) erzielt werden. Dieses Modell (`1m2-3`) wird bei den weiteren Vergleichen berücksichtigt.

8.1.2. Verschiedene Modellklassen versus Benchmark

Aus der Menge an möglichen Modellen, die sich aus den bisherigen Modellgleichungen ergeben können, werden folgende Modelle im Detail betrachtet:

- `1m1`: Ausgehend von Gleichung (6.19) enthält dieses lineare Paneldatenmodell eine Konstante sowie jeweils die Anzahl an Kategorien minus 1 Dummy-Variablen, um den Einfluss von Beruf, Region und Zeit abzubilden. Des Weiteren enthält das Modell eine verzögerte endogene Variable, deren zukünftige Werte sich für $p > 1$ durch sukzessives Einsetzen ergeben,

$$\log(y_{brt}) = \gamma_0 + \sum_{j=2}^B \kappa_j D_{b,j} + \sum_{k=2}^R \eta_k D_{r,k} + \sum_{l=2}^T \lambda_l D_{t,l} + \gamma_2 \log(y_{brt-1}) + u_{brt},$$

mit $D_{b,j}$, $D_{r,k}$ und $D_{t,l}$ als Dummy-Variablen, die Beruf, Region und Jahr anzeigen. Die geschätzten Parameter der Zeitdummies werden mittels eines automatisch gewählten State-Space-Modells fortgeschrieben, siehe Tabelle 6.1 auf Seite 82 und die Erläuterungen dazu.

- `1m2-1` bzw. `1m2-3`: Dieses Modell entspricht Modell `1m1`, lediglich erweitert um die kontemporäre Variable `fem.share` bei Betrachtung der Vollzeitbeschäftigten bzw. `old.num` für die Beschäftigten in Großer Teilzeit. Deren zukünftige Werte werden ebenfalls mittels eines automatisch gewählten State-Space-Modells fortgeschrieben, siehe Tabelle 6.1 auf Seite 82 und die Erläuterungen dazu.
- `ne1`: Bei diesem Modell wird der letzte beobachtete Wert der Beschäftigung als Vorhersage (für alle p) verwendet.
- `ne2`: Die Vorhersage ergibt sich aus einem automatisch gewählten State-Space-Modell der Beschäftigtenzahl ohne Berücksichtigung weiterer Variablen, siehe Tabelle 6.1 auf Seite 82 und die Erläuterungen dazu.

8. Resultate für die Prognosevergleiche

- **np1**: Bei diesem Ansatz wird das Modell aus Gleichung (6.23)

$$\log(y_{it}) = g(b, r, t, \log(y_{it-1})) + u_{it}, \quad i = 1, \dots, N, t = 1, \dots, T,$$

mittels nichtparametrischer Kernregression für gemischte (stetige und diskrete) Kovariablen geschätzt. Für Vollzeitbeschäftigte wird – da hier kein über alle Berufe/Regionen persistentes Trendmuster ersichtlich ist – ein lokal konstanter Ansatz gewählt. Für die Prognose der Beschäftigten in Großer Teilzeit wird ein lokal linearer Ansatz gewählt, da für diese positive Trends vorherrschen. Die Bandweiten werden vor der eigentlichen Regression und Extrapolation mittels des modifizierten AIC-Ansatzes von Hurvich et al. (1998) geschätzt.

- **np2**: Dieses Modell entspricht dem Modell **np1**, jedoch werden die Bandweiten nun mittels Kleinst-Quadrate-Kreuz-Validierung geschätzt, vgl. Kapitel 4 in Li und Racine (2007).

Vollzeit Tabelle A.26 auf Seite 167 enthält die *MAPEPs* für die ausgewählten Modelle. Die Zeile für Modell **1m2-1** entspricht der Zeile **1m2-1** in Tabelle A.23 auf Seite 164. Aus Tabelle A.26 zeigt sich, dass das Modell **np2** für alle Prognosehorizonte $p = 1, \dots, 5$ die besten Vorhersagen liefert (Minima mit Gelb hervorgehoben). Danach folgen die Modelle **1m2-1** und **ne1** (grün markiert). Für den Prognosehorizont $p = 1$ liefert die Status-quo-Prognose (**ne1**) den zweitkleinsten *MAPEP*. Für Prognosehorizonte $p > 2$ sind die Prognosen des Paneldatenmodells **1m2-1** zweitplaziert. Die Modelle **ne2** und **np1** liefern die schlechtesten Prognosen.

Neben dem *MAPEP* werden zwei weitere Kriterien zur Beurteilung der Prognosegüte herangezogen. Die Tabelle A.27 auf Seite 167 ist genauso wie Tabelle A.26 aufgebaut, zeigt jedoch die absolute Anzahl Beschäftigter, um die im Mittel über- oder unterschätzt wurde. Gemäß der englischen Bezeichnung *mean absolute error of prediction* wird das Kriterium mit *MAEP* abgekürzt. Beispielsweise besagt der Wert in der ersten Zeile in Spalte $p = 1$, dass die 1-Schritt-Vorhersage des Modells **1m1** im Mittel um 2.048 Beschäftigte zu hoch oder zu niedrig ist. Auch hier liefert wieder das Modell **np2** den niedrigsten *MAEP* und die Modelle **ne2** und **np1** die schlechtesten. Im Gegensatz zur Evaluation anhand des *MAPEP* ist hier die Status-quo-Prognose **ne1** nicht nur für die kurzfristigen Prognosen, sondern für alle p zweitplaziert. Als weiteres Kriterium wurden die quadrierten Prognose-

fehler berechnet, deren Mittelwerte in Tabelle A.28 auf Seite 167 präsentiert sind. Bis auf kleinere Abweichungen ist auch hier das gleiche Muster zu erkennen, d. h. die Spezifikation `np2` des nichtparametrischen Modells schneidet am besten ab.

Große Teilzeit Bei der Betrachtung der *MAPEPs* für die Beschäftigten in Großer Teilzeit fällt direkt ins Auge, dass die Fehler insgesamt größer sind, siehe Tabelle A.29 auf Seite 168. Die beiden Paneldatenmodelle schneiden am besten ab, wobei das autoregressive Modell (`lm1`) durchweg die kleinsten *MAPEPs* liefert. Wie auch für die Beschäftigten in Vollzeit sind die schlechtesten Prognosen die der Modelle `ne2` und `np1` (gemessen am *MAPEP*). Werden anstatt der prozentualen Fehler die absoluten Fehler betrachtet, gewinnt zwar auch wieder das Modell `lm1` den Vergleich, jedoch liefert hier das Modell `ne2` die zweitkleinsten mittleren *MAEPs*, siehe Tabelle A.30 auf Seite 168. Eine Erklärung für das gute Abschneiden der parametrischen Spezifikation `lm1` liegt darin, dass die Zeitreihen für Große Teilzeit einem klaren positiven Trend folgen, der gut vorherzusagen ist. Die Tatsache, dass sich die Platzierung des Modells `ne2` bei Verwendung des *MAEP* so stark verbessert, ist ein Indiz dafür, dass Berufe-Regionen-Kombinationen mit wenigen Beschäftigten nicht so gut durch das Modell `ne2` wie beschäftigungsstarke Kombinationen vorhergesagt werden können. Dies zeigt deutlich die unterschiedliche Gewichtung von beschäftigungsstarken und -schwachen Berufe-Regionen-Kombinationen, die mit der Verwendung der unterschiedlichen Kriterien verbunden sind. Werden die quadrierten Fehler betrachtet, verschiebt sich der Fokus nochmals weiter in Richtung der beschäftigungsstarken Berufe-Regionen-Kombinationen. Auch hier wird weiterhin das Modell `lm1` als erstes platziert, aber nun ist das Modell `ne2` für den Prognosehorizont von 5 Jahren auf dem zweiten Platz, siehe Tabelle A.31 auf Seite 168.

8.1.3. Systematisches Über- bzw. Unterschätzen

In den Tabellen A.32 (Vollzeit) und A.33 (Große Teilzeit) auf Seite 169 werden die Anzahlen und Prozentsätze der Fälle angegeben, bei denen der beobachtete Wert den vorhergesagten übersteigt, also eine Unterschätzung vorliegt. Die Darstellung als Bruch verdeutlicht die Datenstruktur, die für die verschiedenen Prognosehorizonte resultiert. Es liegen 16 Regionen und 12 Berufe vor, also 192 Berufe-Regionen-Kombinationen. Eine 3-Schritt-Vorhersage ist beispielsweise möglich, wenn man zur Schätzung die Daten entweder bis 2002, 2003, 2004

oder 2005 verwendet. Es gibt also 4 Schätzdatensätze, bei denen jeweils 3-Schritt-Vorhersagen für alle Berufe-Regionen-Kombinationen ermöglicht werden. Insofern gibt es $4 \times 192 = 768$ vorhergesagte Werte. Es zeigt sich, dass manche Modelle tendenziell zur Überschätzung oder Unterschätzung für alle Vorhersagehorizonte neigen. Besonders gravierend trifft dies für die nichtparametrischen Modelle (**np1** und **np2**) und die naive Prognose (**ne1**) bei den Beschäftigten in Großer Teilzeit zu. Der Grund dafür ist der ausgeprägte Trend in fast allen Zeitreihen.

8.2. Jones-Berufe und Agenturbezirke

Aufgrund der Tatsache, dass die Beschäftigtenzahlen durch die starke Ausdifferenzierung auf Ebene der Agenturbezirke und Jones-Berufe für viele Berufe-Regionen-Kombinationen im niedrigen zweistelligen Bereich liegen, kann es zu instabilen Prognosen kommen. Eine gesonderte Analyse und Prognose dieser „kleinen“ Zeitreihen würde entweder aufwendige Plausibilitätsprüfungen oder die Verwendung entsprechender Zeitreihenregressionsmodelle für Zähldaten erfordern. Im Rahmen dieser Arbeit wird eine auf die vorliegenden Daten zugeschnittene und einfach zu wartende Lösung verfolgt, bei der diese „kleinen“ Zeitreihen mittels einer naiven Prognose fortgeschrieben werden. Zum einen ist so die Nichtnegativitätsbedingung immer erfüllt und zum anderen sind die resultierenden Prognosen frei von Schätzfehlern.

Es bleibt zu klären, an welcher Stelle die Abgrenzung erfolgt und ab wann eine Zeitreihe als „klein“ angesehen wird. Prinzipiell liegt eine derartige Abgrenzung im Auge des Betrachters und ist abhängig von der jeweiligen Fragestellung.

Alle Zeitreihen mit konstant mindestens 30 Beschäftigten werden als ausreichend groß deklariert und mit den verschiedenen, bereits diskutierten Modellen bzw. Methoden fortgeschrieben. Auf diese Art werden nicht mehr als insgesamt 2 Prozent der Vollzeitbeschäftigten bzw. 10 Prozent der Teilzeitbeschäftigten durch die naive Prognose fortgeschrieben. In Tabelle A.34 auf Seite 170 sind die entsprechenden Auszählungen getrennt nach Arbeitszeit zu finden. Von den 45.408 Berufe-Regionen-Kombinationen sind bei den Vollzeitbeschäftigten 24.359 Kombinationen als ausreichend groß deklariert worden. Für das Jahr 2008 stellen die Beschäftigten in diesen großen Kombinationen ca. 98,3 Prozent der Beschäftigten in Vollzeit. Bei der Großen Teilzeit erfüllen lediglich 6.429 Kombinationen das Kriterium einer ausreichend groß besetzten Zeitreihe. Diese enthalten jedoch beinahe

90 Prozent der Beschäftigten in Großer Teilzeit.

8.2.1. Prädiktorenauswahl für das parametrische Modell

Bei der Analyse auf Ebene der Blossfeld-Berufe und der Bundesländer mit nur 192 Berufe-Regionen-Kombinationen ist für die linearen Paneldatenmodelle eine Modellselektion aus den 31 Kombinationen der zusätzlichen Prädiktoren durchgeführt worden. Da auf der Ebene der Jones-Berufe und Agenturbezirke für 24.359 Berufe-Regionen-Kombinationen Prognosen erstellt werden müssen, wurde die Anzahl der Spezifikationen, aus denen gewählt wird, auf fünf reduziert. Die Ergebnisse aus Abschnitt 8.1.2 zeigen, dass die Spezifikationen mit nur einem zusätzlichen Prädiktor zu wählen sind. Daher werden jeweils nur die fünf linearen Modellspezifikationen mit nur einem zusätzlichen Prädiktor berücksichtigt. Die Ergebnisse aus Abschnitt 8.1.2 zeigen auch, dass die Auswahl anhand von Kriterien zur Modellanpassung (AIC und SIC) nicht geeignet ist, um die Spezifikation zu finden, welche die besten Out-of-Sample-Prognosen liefert. Daher geschieht auf Ebene der Jones-Berufe und Agenturbezirke die Auswahl direkt anhand der artifiziellen Out-of-Sample-Prognosevergleiche. Die Ergebnisse sind in Tabelle A.35 und A.36 auf Seite 170 zu finden und werden im nächsten Abschnitt erläutert.

8.2.2. Verschiedene Modellklassen versus Benchmark

Für insgesamt sieben verschiedene Modelle bzw. Methoden sind Prognosevergleiche angestellt worden: fünf parametrische Paneldatenmodelle, eine Version der nichtparametrischen Regression und die Status-quo-Prognose als Benchmark.³ Da die State-Space-Modelle (`ne2`) auf der Ebene Blossfeld-Berufe und Bundesländer relativ schlecht abschneiden, werden diese nicht weiter betrachtet. Aufgrund der langen Rechenzeiten wird nur eine Variante zur Bandweitenwahl für die nichtparametrische Regression in den Vergleich aufgenommen. Auf Ebene der Blossfeld-Berufe und Bundesländer schneidet zwar die Variante mit der Kleinste-Quadrat-Kreuzvalidierung (`np2`) besser als die Bandweitenwahl über das modifizierte AIC (`np1`) ab, dennoch wird aus verschiedenen Gründen die Variante `np1` für den weiteren Vergleich herangezogen. So finden sich in der Literatur keine Hinweise, die eine Entscheidung für oder gegen eine der Varianten erzwingen. Gegen die

³Berechnungen sind mit `AAA-Master-4-relevant.do` und den darin aufgeführten R-Skripten durchgeführt worden.

8. Resultate für die Prognosevergleiche

Kleinste-Quadrate-Kreuzvalidierung sprechen die längeren Rechenzeiten und die möglichen Probleme im Paneldatenkontext auf disaggregierter Ebene. Auf Ebene der Blossfeld-Berufe und Bundesländer sind keine starken Austauschbeziehungen zwischen den Zeitreihen zu erwarten. Dafür ist der Grad an Aggregation zu hoch. Bei der starken Disaggregation, die auf Ebene der Jones-Berufe und Agenturbezirke gegeben ist, treten solche Wechselwirkungen, regional sowie beruflich, wahrscheinlich zutage. Eine Kreuzvalidierung, bei der einzelne Datenpunkte aus der Schätzung herausgelassen werden, berücksichtigt diese Wechselwirkungen nicht.

Nachfolgend werden die Ergebnisse des Prognosevergleichs auf Ebene der Berufe-Regionen-Kombinationen getrennt nach Voll- und Teilzeit besprochen. Als Kriterium der Prognosegüte wird nur der *MAPEP* verwendet, da die beiden anderen Kriterien (*MAEP* und *MSEP*) jeweils das beste Modell in Übereinstimmung mit dem *MAPEP* identifiziert haben. Zusätzlich werden jedoch Boxplots der absoluten prozentualen Prognosefehler erstellt und verglichen.

Vollzeit In Tabelle A.35 auf Seite 170 ist klar zu erkennen, dass alle parametrischen Paneldatenmodelle ähnlich gut abschneiden, wobei die Modelle *lm1* und *lm2-1* für sämtliche Prognosehorizonte im Mittel die kleinsten *MAPEPs* liefern. In Gelb wird der kleinste Wert und in Grün der zweitkleinste Wert angezeigt. Das Modell *lm2-1* enthält neben der verzögerten Beschäftigung und den fixen Effekten für Beruf, Region und Jahr noch zusätzlich den Anteil der weiblichen Beschäftigten in der jeweiligen Berufe-Regionen-Kombination. Die Unterschiede in den *MAPEPs* zwischen den beiden Modellen treten erst ab der dritten Nachkommastelle auf.⁴ Die Ergebnisse zeigen, dass keine Verbesserungen der Prognosen erzielt werden, wenn zusätzliche erklärende Variablen (außer der verzögerten Beschäftigung selbst) aufgenommen werden. Ein Grund dafür kann sein, dass die erklärenden Variablen selbst nur schlecht vorhergesagt werden können. In Abbildung A.88 auf Seite 257 sind die Boxplots der absoluten prozentualen Prognosefehler für $p = 1$ dargestellt. Die eigentlichen Boxen sind aufgrund der vielen extrem großen Werte gar nicht zu erkennen. Bei allen Methoden kommt es zu *APEPs* von bis zu ca. 1500 Prozent. In der Abbildung A.89 auf Seite 257 sind nur die Boxen ohne die extrem großen *APEPs* eingezeichnet. Jetzt ist deutlich erkennbar, dass nicht nur die Mediane der *APEPs* für alle parametrischen Modelle und die der

⁴Die Tatsache, dass das Modell *lm2-1* fast identische *MAPEPs* besitzt, kann dadurch erklärt werden, dass der geschätzte Einfluss des Anteils der weiblichen Beschäftigten (*fem.share*) nahe Null ist (p-value $\approx 0,7$).

Status-quo-Prognose fast identisch sind, sondern die Verteilungen insgesamt fast identisch sind. Der Median und das 25-%- und 75-%-Quartil der *APEPs* für die nichtparametrische Regression (**np1**) sind etwas größer, aber ihre Verteilung ähnelt stark den anderen Verteilungen und ist durch eine Rechtsschiefe gekennzeichnet. Bei den Prognosefehlern für die 5-Schritt-Prognosen sind die Mediane zwar alle größer, aber die Verteilungen sehen ähnlich wie bei $p = 1$ aus, siehe Abbildungen A.90 und A.91 auf Seite 258. Aufgrund des kleinsten *MAPEPs* wird somit das Modell **lm2-1** zur weiteren Analyse ausgewählt.

Große Teilzeit Für die Beschäftigten in Großer Teilzeit sind die *MAPEPs* alle etwas größer als bei den Vollzeitbeschäftigten, siehe Tabelle A.36 auf Seite 170. Überraschenderweise liefert die Status-quo-Prognose für $p = 1$ den kleinsten *MAPEP*. Den zweitkleinsten *MAPEP* liefert das autoregressive Modell (**lm1**). Die Boxplots der *APEPs* zeigen die gleichen Muster wie bei der Vollzeit, siehe Abbildungen A.92 und A.93 auf Seite 259 für $p = 1$ und A.94 und A.95 auf Seite 260 für $p = 5$. Für alle Prognosehorizonte größer als 1 liefert das Modell **lm1** den kleinsten *MAPEP* und wird daher zur weiteren Analyse gewählt.

8.2.3. Median-Prognose

Bei der Schätzung der parametrischen Paneldatenmodelle wurden bisher immer die quadrierten Abweichungen minimiert (Mittelwert-Regression). Es lassen sich jedoch auch die absoluten Abweichungen minimieren (Median-Regression). In Tabelle A.37 auf Seite 171 sind die Vergleiche zwischen Median- und Mittelwert-Prognosen für die Beschäftigten in Großer Teilzeit aufgeführt. Bei beiden Schätzmethoden führen dieselben Modelle zu den kleinsten *MAPEPs*. Aufgrund von numerischen Problemen bei der Schätzung für die Vollzeitbeschäftigten können dafür keine Vergleiche angestellt werden.

8.2.4. Hierarchische Aggregation von Prognosen

Die Vergleiche in den vorherigen Abschnitten sind für Prognosevorschriften durchgeführt worden, die ohne manuelle Eingriffe auskommen bzw. diese nicht erlauben. Vor dem Hintergrund der möglichen Verwendung der Prognosen durch Mitarbeiter der BA ist jedoch davon auszugehen, dass diese Expertenwissen besitzen. Die Akzeptanz einer Methode ist wahrscheinlich größer, wenn diese es erlaubt, solches

8. Resultate für die Prognosevergleiche

Wissen in den Prognoseprozess einzubeziehen. Die Methode Top-down-FP von Athanasopoulos et al. (2009) erlaubt es, Expertenwissen über die Beschäftigungsentwicklungen bestimmter Berufe oder in bestimmten Regionen zu nutzen, siehe Abschnitt 6.6.

Anstatt Expertenwissen können aber auch einfach weniger disaggregierte Prognosen der Beschäftigtenzahlen verwendet werden, d. h. Prognosen für die Berufe, für die Regionen oder die Gesamtzahl der Beschäftigten. Die Idee dahinter ist, dass diese Aggregatsprognosen im Mittel genauer sind als die Prognosen für die Berufe-Regionen-Kombinationen. Als Aggregatsprognosen verwenden wir einfach die entsprechenden Summen der Prognosen für die Berufe-Regionen-Kombinationen und bezeichnen diese als Bottom-up-Prognosen. Im Folgenden werden die Bottom-up-Prognosen der verschiedenen Modelle verglichen.

Vollzeit In Tabelle A.38 auf Seite 172 sind die *MAPEPs* für die Bottom-up-Prognosen für die Regionen ($y_{\bullet r}$), für die Berufe ($y_{b\bullet}$) und Gesamtzahl der Beschäftigten ($y_{\bullet\bullet}$) aufgelistet.

Ein Vergleich der *MAPEPs* für die Aggregate $y_{\bullet r}$ und $y_{b\bullet}$ zeigt, dass die Bottom-up-Prognosen für die Arbeitsagenturen (Aggregation über Berufe ($y_{\bullet r}$)) zu etwa halb so großen *MAPEPs* führen wie die bei den Bottom-up-Prognosen für die Berufe ($y_{b\bullet}$). Daher bieten sich die Agenturbezirke als nächsthöheres Aggregationslevel an. Die Wahl eines Modells ist hier weniger eindeutig als auf Ebene der Berufe-Regionen-Kombinationen. Die Prognosen nach nichtparametrischer Schätzung (**np1**) schneiden im Vergleich zu den linearen Paneldatenmodellen besonders gut für Prognosehorizonte $p \geq 3$ ab. Je nachdem, ob der Fokus auf den kurzfristigen oder mittelfristigen Prognosen liegt, wird also ein anderes Modell gewählt. Für Steuerungszwecke in der BA sind die mittelfristigen Prognosen von größerer Bedeutung. Daher wird das Modell **np1** gewählt.

Als nächstes Aggregationslevel im Hierarchiebaum könnten entweder Prognosen für die Bundesländer oder für Deutschland insgesamt verwendet werden. Im Rahmen dieses Projektes wird die zweite Variante implementiert und verwendet werden die Bottom-up-Prognosen des Modells **lm2-3**, da dieses sehr gut in der kurzen Frist abschneidet. Es ergibt sich somit ein Hierarchiebaum analog zu Abbildung 6.1.

Für die Beschäftigten in Vollzeit ist die gewählte Bottom-up-Aggregatsprognose für Deutschland (insgesamt) durchweg besser als die des gewählten Modells auf

dem untersten Level. Für Horizonte $p > 2$ sind dabei die Unterschiede mit mindestens zwei Prozentpunkten besonders groß (siehe hierzu Tabelle A.38 auf Seite 172, Aggregation „über Berufe und Regionen“, Modelle 1m2-3 versus 1m2-1). Anders als erwartet, verschlechtern sich die Prognosen jedoch durch die Verwendung der Methode des Top-down-FP. Für die 1-Schritt Prognosen steigt der *MAPEP* um 0,11 Prozentpunkte, für die 5-Schritt Prognosen beträgt der Anstieg 0,25 Prozentpunkte, siehe Tabelle A.39 auf Seite 172.

Eine andere Sichtweise auf die Methode des Top-down kann helfen, dieses Ergebnis zu erklären. Dazu kehren wir kurz zu den Überlegungen des Abschnitts 6.6 zurück und formen Gleichung (6.29) um zu

$$\begin{aligned}\tilde{y}_{\bullet,1} &= \hat{y}_{\bullet,\bullet} \cdot \widehat{\text{Anteil}}(y_{\bullet,1}) \\ &\stackrel{(6.27)}{=} \hat{y}_{\bullet,\bullet} \cdot \frac{\hat{y}_{\bullet,1}}{\sum_{r=1}^{176} \hat{y}_{\bullet,r}} \\ &= \underbrace{\frac{\hat{y}_{\bullet,\bullet}}{\sum_{r=1}^{176} \hat{y}_{\bullet,r}}}_{C_{\text{Level 1}}} \cdot \hat{y}_{\bullet,1},\end{aligned}$$

wobei $C_{\text{Level 1}}$ ein konstanter Faktor ist, mit dem alle Prognosen auf Level 1 modifiziert werden. Diese Modifikation führt offensichtlich dazu, dass die Summe der Top-down-Prognosen exakt der Aggregatsprognose entsprechen muss, d. h.

$$\sum \tilde{y}_{\bullet,1} = \hat{y}_{\bullet,\bullet}$$

und sich somit keine Veränderungen ergeben, wenn auf allen Levels das gleiche Modell gewählt wird. Die beobachtete Verschlechterung durch das Top-down könnte darauf zurückzuführen sein, dass das Modell 1m2-1 (für das unterste Level) vergleichsweise schlechte Prognosen bei den beschäftigungsstarken Berufe-Regionen-Kombinationen liefert, aber im Mittel über alle Kombinationen vergleichsweise akkurat ist. Top-down-FP verbessert möglicherweise die Prognosen für die beschäftigungsstarken Kombinationen, führt aber für die Mehrzahl der Berufe-Regionen-Kombinationen zu einer Verschlechterung der Prognosegüte.

Große Teilzeit Analog zur Vorgehensweise für die Beschäftigten in Vollzeit wird auch für die Zeitreihen der Großen Teilzeit ein Hierarchiebaum gemäß Abbildung 6.1 gewählt. Aus Tabelle A.40 auf Seite 173 ist ersichtlich, dass auch hier die mittleren *MAPEPs* für die Agenturbezirke wesentlich kleiner sind als für die

8. Resultate für die Prognosevergleiche

Jones-Berufe. Auf dem untersten Aggregationslevel wird das Modell **1m1** gewählt. Die Bottom-up-Prognosen des Modells **1m2-4** werden für die Agenturbezirke verwendet, für Deutschland insgesamt wieder die des Modells **1m1**.

Im Gegensatz zu den Vollzeitbeschäftigten sind hier minimale Verbesserungen durch Anwendung von Top-down-FP über alle Prognosehorizonte zu beobachten. Da diese im Mittel gerade einmal ein Hundertstel Prozentpunkt betragen, siehe Tabelle A.41 auf Seite 173, wird die Methode Top-down-FP nicht für die finalen Prognosen verwendet.

Anmerkung: Prognosen für die Berufe Für Vollzeit und Große Teilzeit bringt das Aggregieren über Regionen – d. h. die Verwendung einer Bottom-up-Prognose für die Berufe – kaum Genauigkeitsgewinne. Daraus lässt sich schließen, dass die Berufe konstant in allen Agenturbezirken entweder über- oder unterschätzt werden. Dies kann als ein mögliches Indiz dafür angesehen werden, dass es berufsspezifische, regionale Austauschbeziehungen gibt, die durch das Modell nicht erklärt werden. Dieser Frage ließe sich beispielsweise über die Aufnahme einer räumlichen Komponente in die parametrische Modellspezifikation nachgehen. Einen Überblick zu Spezifikation und Schätzung von räumlichen Paneldatenmodellen gibt Elhorst (2003). Erste statistische Tests bezüglich der räumlichen Modellierung im Kontext von Paneldatenmodellen sind von Baltagi et al. (2003) entwickelt worden. Speziell für Paneldatenmodelle mit fixen Effekten, wie sie in der vorliegenden Arbeit verwendet werden, entwickelten Debarsy und Ertur (2010) einen Test bezüglich der Spezifikation der räumlichen Komponente. Zwei Beispiele für die Anwendung von räumlichen Paneldatenmodellen sind Longhi und Nijkamp (2007) für den Deutschen Arbeitsmarkt und Angulo und Trivez (2010) für den spanischen Arbeitsmarkt.

8.3. Fazit und Punktprognose bis ins Jahr 2015

Als Fazit für die durchgeführten empirischen Analysen hinsichtlich

1. Gliederungstiefe der Daten
 - a) Blossfeld-Bundesland-Ebene
 - b) Jones-Arbeitsagenturbezirk-Ebene
2. Spezifikation der Schätz- und Prognoseansätze

- a) Dynamische linear-(semi)parametrische Modelle
- b) Dynamische nichtlinear-semi- und nichtparametrische Modelle

3. Hierarchisch kalibrierte Prognosen

4. Räumliche Assoziationsstrukturen als Prädiktorkomponenten

sei festgehalten, dass sich die erwarteten Unterschiede in der Performance der einzelnen Methoden in Abhängigkeit der Gliederungstiefe gezeigt haben. Reguläre und irreguläre Muster in den Daten, Nichtlinearitäten und Brüche werden durch die Aggregationsvorgänge auf kaum kontrollierbare Weise verändert. Notwendige Nichtlinearitäten auf hohen Aggregationsstufen werden zwar durch die Disaggregation, die einer lokalen Linearisierung entspricht, im Sinne der Prognoseperformance nahezu obsolet, liefern jedoch wertvolle Hinweise darauf, welche Strategien bei zukünftigen Änderungen in der Gebiets- und/oder Berufesystematik gefahren werden sollten. Analog zur funktionalen Form der Schätz- und Prognoseansätze gelten die Aggregationsproblematiken auch für die Relevanz potentieller Prädiktorvariablen. Für die Kalibrierung bestehender Prognosen, wie sie dieses Forschungsprojekt auf vielfältigste Art auf sehr unterschiedlichen Aggregationsstufen liefert, besteht ein nahezu beliebiger Spielraum, insbesondere, was eine mögliche zukünftige Einbindung von vorläufigen IST-Daten oder Nebenbedingungen – die aus anderen Modellen oder aus Experteneinschätzungen stammen können – betrifft. Für eine zuverlässigere Bewertung der Performance hierarchisch kalibrierter Prognosen ist zudem zuverlässiges aktuelles IST-Datenmaterial notwendig.

Sämtliche in dieser Arbeit vorgestellten Ergebnisse beruhen auf Analysen der BeH-Auszüge, die zu Beginn des Forschungsprojekts vom IAB geliefert wurden. Die Daten reichen bis ins Jahr 2008. Zum Abschluss des Projekts sind BeH-Auszüge der Jahre 2009 und 2010 geliefert worden, um die letztendlich zu erstellenden Prognosen für die Jahre von 2011 bis 2015 zu berechnen.

Die aktuellsten Daten reichen bis ins Jahr 2010. Noch aktuellere Daten weisen einen geringeren Füllgrad⁵ auf und werden daher nicht berücksichtigt. Da sich aber auch kleinere Änderungen für die Jahre vor 2009 ergeben haben, sind die in den Berichten vorgestellten Ergebnisse nicht mit den aktuellsten BeH-Auszügen exakt replizierbar. Mit der Übergabe der für die Analyse und Prognose benötigten Stata-Dateien und R-Skripte, sind auch die ursprünglich gelieferten BeH-Auszüge aus

⁵Einige Meldungen erfolgen mit bis zu 18 Monaten Verspätung durch die Arbeitgeber.

8. Resultate für die Prognosevergleiche

Datenschutzgründen gelöscht worden. Neben den Programmen wurden auch die Prognosen⁶ mit dem Abschlussbericht an das IAB gesandt.

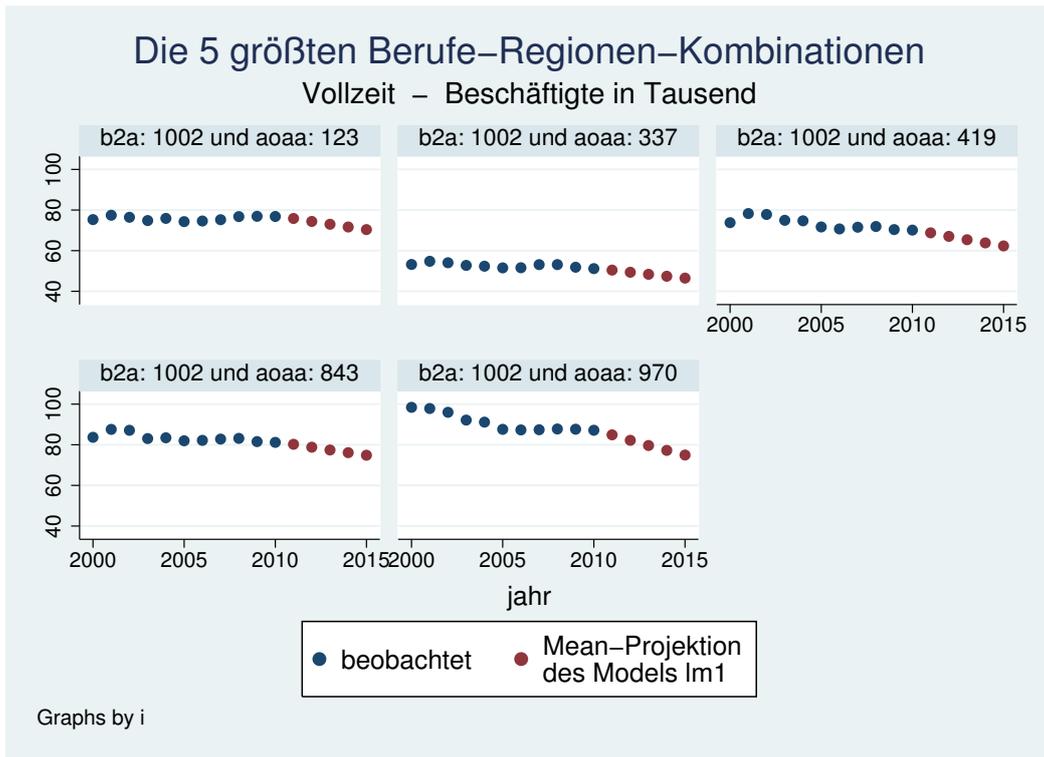
Die artifiziellen Out-of-Sample-Prognosevergleiche in Tabellen A.35 zeigen, dass das Modell **lm2-1** – parametrisches Paneldatenmodell mit fixen Effekten für Beruf, Region und Zeit sowie der verzögerten Beschäftigung und dem Anteil der weiblichen Beschäftigten als erklärende Variablen – für die finalen Prognosen der Vollzeitbeschäftigten zu wählen wäre. Ein Wiederholung der Analyse⁷ für die aktualisierten Daten bestätigt im Wesentlichen die gezeigten Ergebnisse, jedoch sind nun die Prognosen des Modells **lm1** marginal besser. Daher werden die finalen Prognosen mit dem Modell **lm1** mit Hilfe der Mittelwert-Regression erstellt. Für die Beschäftigten in Großer Teilzeit wird auch das Modell **lm1** gewählt, jedoch mit Quantilsregression geschätzt, siehe Tabellen A.36 und A.37. Auch für die Große Teilzeit bestätigt die erneute Analyse auf Grundlage der aktualisierten BeH-Auszüge die hier präsentierten Ergebnisse.

Weder für die Vollzeit noch für die Große Teilzeit werden die Prognosen durch die Methode Top-down-FP modifiziert.

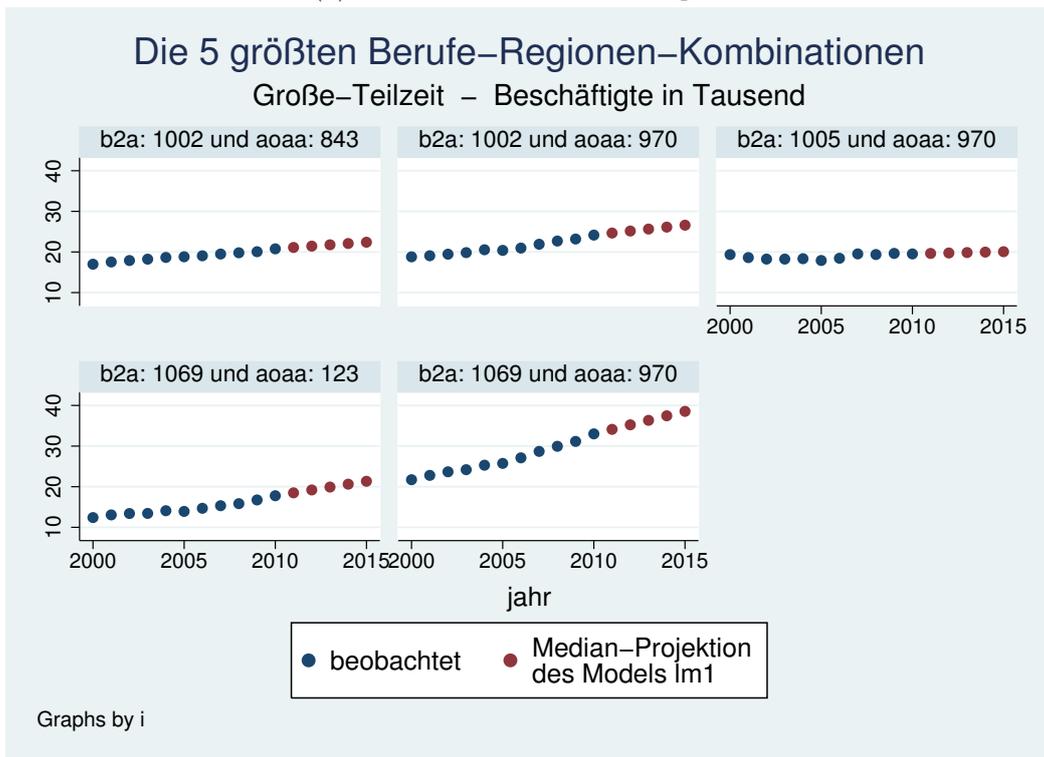
Abschließend werden – getrennt nach Arbeitszeit – exemplarisch die Punktprognosen der fünf beschäftigungsstärksten Berufe-Regionen-Kombinationen in Zeitreihenplots visualisiert. In Abbildung 8.1a auf der nächsten Seite ist die Anzahl der Beschäftigten in Vollzeit für die Jahre 2000 bis 2010 in Blau eingetragen; die Prognosen des Modells **lm1** sind in Rot eingetragen. Die Abbildung 8.1b auf der nächsten Seite zeigt die fünf beschäftigungsstärksten Zeitreihen für die Große Teilzeit. Die explorativen Analysen aus Kapitel 4 haben gezeigt, dass die Anzahl der Vollzeitbeschäftigten zugunsten der Beschäftigten in Großer Teilzeit zurückgeht. Die Prognosen geben ein Indiz darauf, dass sich dieser Trend möglicherweise fortsetzen wird.

⁶Die Lieferung geschah nach den vereinbarten Datenschutzbestimmungen in verschlüsselter Form.

⁷Die zwei zusätzlichen Jahre wurden genutzt, um die Validierungsstichprobe zu vergrößern.



(a) Vollzeit – Mittelwert-Prognose



(b) Große Teilzeit – Median-Prognose

Abbildung 8.1.: Fünf exemplarische Prognosen

9. Intervallprognosen

Die Prognosevergleiche des vorhergehenden Kapitels beruhen auf den Punktprognosen für die Beschäftigten in den Berufe-Regionen-Kombinationen. In diesem Kapitel wird das Vorgehen zur Berechnung von Intervallprognosen dargelegt und auf einige Probleme bei der Anwendung auf das vorliegende Prognosevorhaben hingewiesen.

9.1. Berechnung der 1-Schritt-Prognoseintervalle

Die Punktprognosen beruhen auf dem Modell `lm1`, einem dynamischen Panel-datenmodell mit fixen Effekten für Beruf (b), Region (r) und Zeit (t), sowie der verzögerten Beschäftigung (y_{brt-1}) als erklärende Variable:

$$\log(y_{brt}) = \sum_{j=2}^B \kappa_j D_{b,j} + \sum_{k=2}^R \eta_k D_{r,k} + \sum_{l=2}^T \lambda_l D_{t,l} + \gamma_0 + \gamma_1 \log(y_{brt-1}) + u_{brt}, \quad (9.1)$$

mit $D_{b,j}$ als Dummy-Variable für Beruf j , $D_{r,k}$ als Dummy-Variable für Region k und $D_{t,l}$ als Dummy-Variable für Jahr l . Für die Vollzeit ist das Modell (9.1) mit der Mittelwert-Regression geschätzt worden und für die Große Teilzeit durch die Median-Regression. Die Rücktransformation der Punktprognosen $\widehat{\log(y_{brT+p})}$ mittels Exponentialfunktion liefert \hat{y}_{brT+p} , siehe Gleichung (6.20). Um diesen Wert herum soll nun ein Intervall

$$\left[\hat{y}_{brT+p}^u, \hat{y}_{brT+p}^o \right], \quad \text{mit } 0 \leq \hat{y}_{brT+p}^u < \hat{y}_{brT+p} < \hat{y}_{brT+p}^o,$$

konstruiert werden, welches der Unsicherheit bei der Prognose Rechnung trägt.

Im Folgenden werden alternative Ansätze zur Berechnung der Intervallgrenzen, \hat{y}_{brT+p}^u und \hat{y}_{brT+p}^o , vorgestellt und die Entscheidung für das gewählte Vorgehen detailliert begründet.

9.1.1. Quantile bzw. Expektile

Eine Herangehensweise, um Intervallprognosen für die Beschäftigung ($\log(y_{brt})$) zu berechnen, besteht darin, bei der Modellschätzung Quantile für die Große Teilzeit bzw. Expektile für die Vollzeit zu schätzen. Auf diese Art wird jeweils dieselbe Verlustfunktion wie bei der Punktprognose zugrunde gelegt. Bei der vorliegenden Datenstruktur kommt es jedoch zu Quantils- bzw. Expektilsüberschneidungen. In Abbildung 9.1 ist dies für ein künstliches Beispiel mit nur einer erklärenden Variable visualisiert. Wie zu erkennen ist, kommt es aufgrund von Heteroskedastie und nur sehr wenigen Beobachtungen für sehr kleine x-Werte zu Expektilsüberschneidungen.

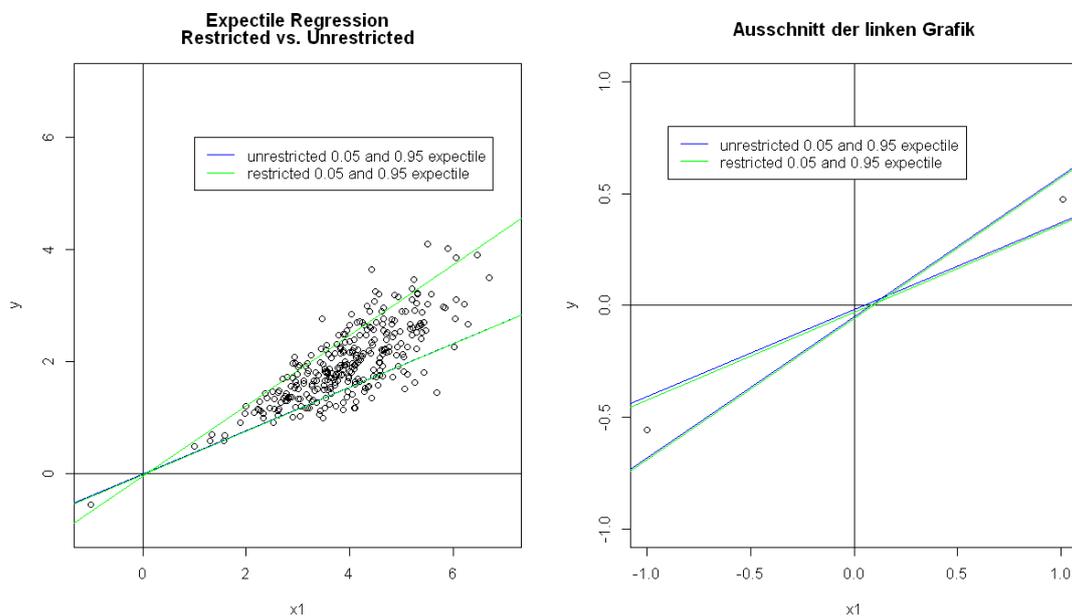


Abbildung 9.1.: Beispiel für Expektilsüberschneidungen bei Verwendung des Befehls `expectreg.ls` des R-Pakets `expectreg` Version 0.36.
R-Skript: `expectreg-restricted-crossing-error.R`

He (1997) hat einen Algorithmus entwickelt, um dieses Problem zu vermeiden. Zum jetzigen Zeitpunkt ist dieser noch nicht komplett implementiert¹ und hat weiterhin den Nachteil, dass Überschneidungen nur für den beobachteten Wertebereich vermieden werden. Bei trendbehafteten Zeitreihen stellt dies im Prognosekontext weiterhin ein Problem dar. Aus diesen Gründen wird diese Methode nicht genutzt.

¹Der für die Paketpflege zuständige Ansprechpartner, Dr. Sobotka, ist schon informiert.

9.1.2. Schätzung der Prognosefehlervarianz

Obwohl die vorliegenden Prognosen anhand eines dynamischen Paneldatenmodells berechnet werden, wird zu Beginn die Konstruktion von Prognoseintervallen im einfachst möglichen Fall der Querschnittsanalyse erläutert. Die Reduktion der Komplexität dient der leichteren Verständlichkeit und bietet die Möglichkeit, auf kritische Punkte hinzuweisen, die beim Übergang in den Paneldatenkontext auftreten.

Ausgangspunkt ist das Modell $y_i = \mathbf{x}_i\boldsymbol{\beta} + u_i$, $i = 1, 2, \dots, N$, bei dem die abhängige Variable y durch den Störterm u und die erklärenden Variablen $\mathbf{x} = (x_1, x_2, \dots, x_k)$ bestimmt wird. Es wird angenommen, dass die Werte von \mathbf{x}_i für ein Individuum i bekannt sind, der Wert von y_i jedoch unbekannt ist und prognostiziert werden soll. Wie zuvor wird die Prognose mit \hat{y}_i bezeichnet und der Prognosefehler als $e_{i|\mathbf{x}_i} = y_i - \hat{y}_i$. Liegt ein geeigneter Datensatz vor, lassen sich die Modellparameter $\boldsymbol{\beta}$ durch die Mittelwert-Regression schätzen. Mit dem resultierenden Schätzergebnis $\hat{\boldsymbol{\beta}}$ kann die Prognose $\hat{y}_i = \mathbf{x}_i\hat{\boldsymbol{\beta}}$ berechnet werden. Bei Kenntnis der Prognosefehlervarianz σ_e^2 liefert

$$\left[\hat{y}_i - \sqrt{\sigma_e^2}; \hat{y}_i + \sqrt{\sigma_e^2} \right] \quad (9.2)$$

ein mögliches Prognoseintervall. Wie bei Konfidenzintervallen im Kontext der Schätzung unbekannter Modellparameter, wird für Prognoseintervalle meist eine wahrscheinlichkeitstheoretische Interpretation angestrebt. Erst durch zusätzliche Annahmen kann eine solche Interpretation gerechtfertigt werden. Für den hier beschriebenen Fall einer Prognose im Querschnittskontext, stellt (9.2) ein 68%-Prognoseintervall dar, falls \hat{y}_i eine erwartungstreue Prognose für y_i ist und die Prognosefehler identisch normalverteilt sind.

Bei einer Paneldatenanalyse wird für das Modell $y_{it} = \mathbf{x}_{it}\boldsymbol{\beta} + u_{it}$, $i = 1, 2, \dots, N$, $t = 1, 2, \dots, T$, oftmals angenommen, dass die Störterme u_{it} für die Individuen über die Zeit korreliert sind. Die Aufnahme von y_{it-1} als eine erklärende Variable, wie in (9.1), hat zum Ziel, diese serielle Korrelation zu modellieren. Da y_{it-1} nicht streng exogen ist, führt eine Mittelwert-Regression zwar nicht mehr zu einer erwartungstreuen Schätzung von $\boldsymbol{\beta}$, aber falls die Störterme des dynamischen Paneldatenmodells seriell unkorreliert sind, ist der Schätzer $\hat{\boldsymbol{\beta}}$ unter den üblichen Annahmen konsistent.

Doch muss die Grundvoraussetzung, dass das Modell korrekt spezifiziert ist, für

9. Intervallprognosen

die in dieser Arbeit spezifizierten Modelle als zweifelhaft angesehen werden, vgl. Erläuterungen des Abschnitts 6.3.

Die folgende Berechnung der Prognoseintervalle ist an (9.2) angelehnt, lässt aber aufgrund der eben aufgeführten Argumente keine exakte Interpretation im Sinne von Eintrittswahrscheinlichkeiten für die Realisation von y_{brT+1} zu. Dennoch spiegeln die Intervalle die Variabilität der Out-of-Sample-Prognosefehler wider und betonen die mit jeder Prognose einhergehende Unsicherheit. Zur Schätzung der Prognosefehlervarianz wurden verschiedene Varianten getestet. Im Folgenden wird die Variante vorgestellt, mit der die ans IAB gelieferten Prognoseintervalle berechnet wurden. Die übrigen Varianten und die Begründung für die gewählte Variante sind in Anhang A.1 zu finden. Anstatt des Doppelindex br wird wieder der Index i für die Berufe-Regionen-Kombination verwendet.

Die Varianz der Prognosefehler ist größer als die der Störterme. Die Residualvarianz unterschätzt daher möglicherweise Prognosefehlervarianz. Aus diesem Grund geschieht die Schätzung anhand der artifiziellen 1-Schritt-Prognosefehler. Die Intervallgrenzen werden wie folgt berechnet:

$$\log(\widehat{y_{iT+1}}) \pm \widehat{sd}(e_{iT+1|\mathcal{T}}), \quad (9.3)$$

wobei

$$\widehat{sd}(e_{iT+1|\mathcal{T}}) = \sqrt{\frac{1}{8-1} \sum_{\mathcal{T}=2002}^{2009} (e_{iT+1|\mathcal{T}} - \bar{e}_{iT+1|\mathcal{T}})^2} \quad (9.4)$$

die empirische Standardabweichung der acht artifiziellen 1-Schritt-Prognosefehler $e_{iT+1|\mathcal{T}} = \log(y_{iT+1}) - \log(\widehat{y_{iT+1|\mathcal{T}}})$ für Berufe-Regionen-Kombination i ist und $\bar{e}_{iT+1|\mathcal{T}}$ ihren Mittelwert bezeichnet.

Die so berechneten Intervallprognosen werden durch Exponentieren wieder in die Zieleinheit (tausend Personen) gebracht:

$$\exp\left(\log(\widehat{y_{iT+1}}) \pm \widehat{sd}(e_{iT+1|\mathcal{T}})\right). \quad (9.5)$$

Dies entspricht der gängigen Praxis und ist z. B. in der Zeitreihensoftware EViews 7 in dieser Weise implementiert.

9.2. Steigende Unsicherheit für p-Schritt-Prognosen

Der steigenden Prognoseunsicherheit wird durch sukzessive Vergrößerung der Intervalle Rechnung getragen. Für Prognosehorizonte $p > 1$ stehen immer weniger artifizielle Prognosefehler zur Verfügung. Anstatt die Prognosefehlervarianz z. B. für $p = 5$ anhand der vier artifiziellen Prognosefehler abzuschätzen, wird der Anstieg der *MAPEPs* verwendet, um die geschätzte Standardabweichung der 1-Schritt-Prognosefehler zu vergrößern. Die Intervallprognosen für die Prognosehorizonte $p = 2, \dots, 5$ werden folgendermaßen berechnet:

$$\widehat{\log(y_{iT+p})} \pm \frac{MAPEP(p)}{MAPEP(1)} \widehat{sd}(e_{i\mathcal{T}+1|\mathcal{T}}) \quad (9.6)$$

mit $MAPEP(p)$ als *MAPEP* für den p -Schritt-Prognosehorizont und dementsprechend $MAPEP(1)$ als *MAPEP* für den 1-Schritt-Prognosehorizont.

In Tabelle 9.1 sind die resultierenden Multiplikatoren getrennt nach Vollzeit und Großer Teilzeit aufgeführt.

Tabelle 9.1.: Multiplikatoren für die Standardabweichung der Prognosefehler

	Prognosehorizont				
	1	2	3	4	5
Vollzeit	1,00	1,52	1,98	2,30	2,64
Große Teilzeit	1,00	1,44	1,83	2,15	2,43

9.3. Empirische Ergebnisse

Die Intervallprognosen für $\log(y)$ werden durch die Exponentialfunktion wieder auf die Zieleinheit von tausend Personen gebracht.²

Vollzeit Für jeden Prognosehorizont ist ein Boxplot der 24.054 Intervallbreiten erstellt worden, siehe obere Grafik in Abbildung 9.2 auf der nächsten Seite. Aufgrund der Ausreißer erscheinen die Boxen lediglich als Striche. Wie gewünscht nimmt die Intervallbreite mit steigendem Horizont zu. Um zu prüfen, ob die

²Die Berechnung der Prognoseintervalle und die hier durchgeführten Analysen sind mit `prognoseintervalle_vz.R` und `prognoseintervalle_gtz.R` durchgeführt worden.

9. Intervallprognosen

Schiefe der Verteilung allein durch die Schiefe bei der Verteilung der Beschäftigtenzahlen über die Berufe-Regionen-Kombinationen hervorgerufen wird³, sind in der unteren Grafik von Abbildung 9.2 für den Prognosehorizont $p = 1$ die Intervallbreiten gegen die Punktprognosen abgetragen. Wie erwartet, steigt die Intervallbreite mit dem Niveau der Beschäftigtenzahlen innerhalb einer Berufe-Regionen-Kombination. Die in Rot eingefassten Ausreißer zeigen, dass für einige Zeitreihen die Intervallbreite im Verhältnis zur Punktprognose sehr groß ist. Die maximale Intervallbreite (1-Schritt-Prognose) von ca. 9000 Personen tritt für eine Zeitreihe auf, deren Punktprognose lediglich bei ca. 1000 Personen liegt. Verhältnismäßig große Prognoseintervalle deuten im Allgemeinen darauf hin, dass die Prognosefehlervarianz der Zeitreihe groß ist.

Für $p = 1$ wird der größte Ausreißer mit einer Intervallbreite von fast 10.000 herausgegriffen und näher untersucht. Es handelt sich um die Zeitreihe für den

³Je größer die Beschäftigtenzahl in einer Berufe-Regionen-Kombination, desto größer fällt das Prognoseintervall typischerweise aus.

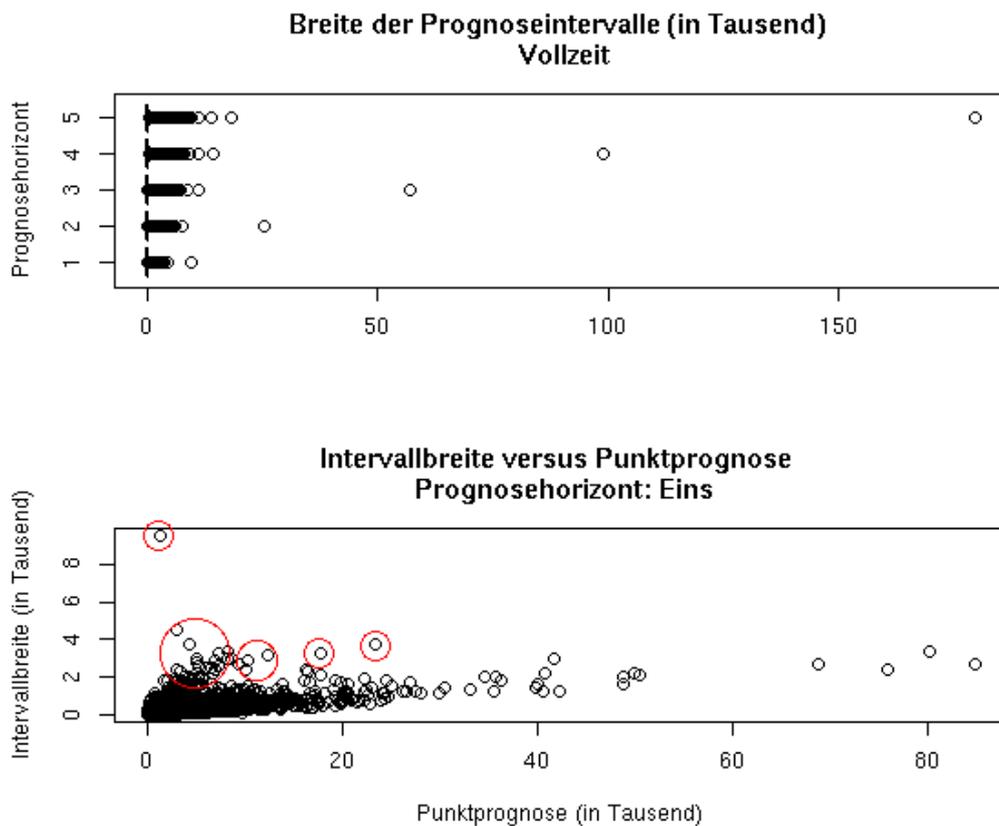


Abbildung 9.2.: Breite der Prognoseintervalle – Vollzeit

Berufscode 1059 im Agenturbezirk Bochum. In Abbildung 9.3 sind die Zeitreihe sowie die gefitteten Werte und die Prognosen für die Jahre von 2011 bis 2015 gezeigt. Die obere Grafik zeigt die logarithmierten Werte und die untere die rücktransformierten Werte. Für die logarithmierten Beschäftigtenzahlen liegen die Prognoseintervalle symmetrisch um die Punktprognose. Bei der Rücktransformation durch das Exponentieren wird diese Symmetrie aufgehoben und die obere Intervallgrenze wird unplausibel groß, siehe untere Grafik. Die obere Grenze des Prognoseintervalls für das Jahr 2015 ist mit ca. 179.000 um ein Vielfaches größer als die entsprechende Punktprognose, die lediglich um die 1000 liegt.

Das eben vorgestellte Beispiel wirft zwei Fragen auf.

1. Wie können solche unplausibel großen oberen Intervallgrenzen identifiziert werden?
2. Wie ist mit ihnen umzugehen?

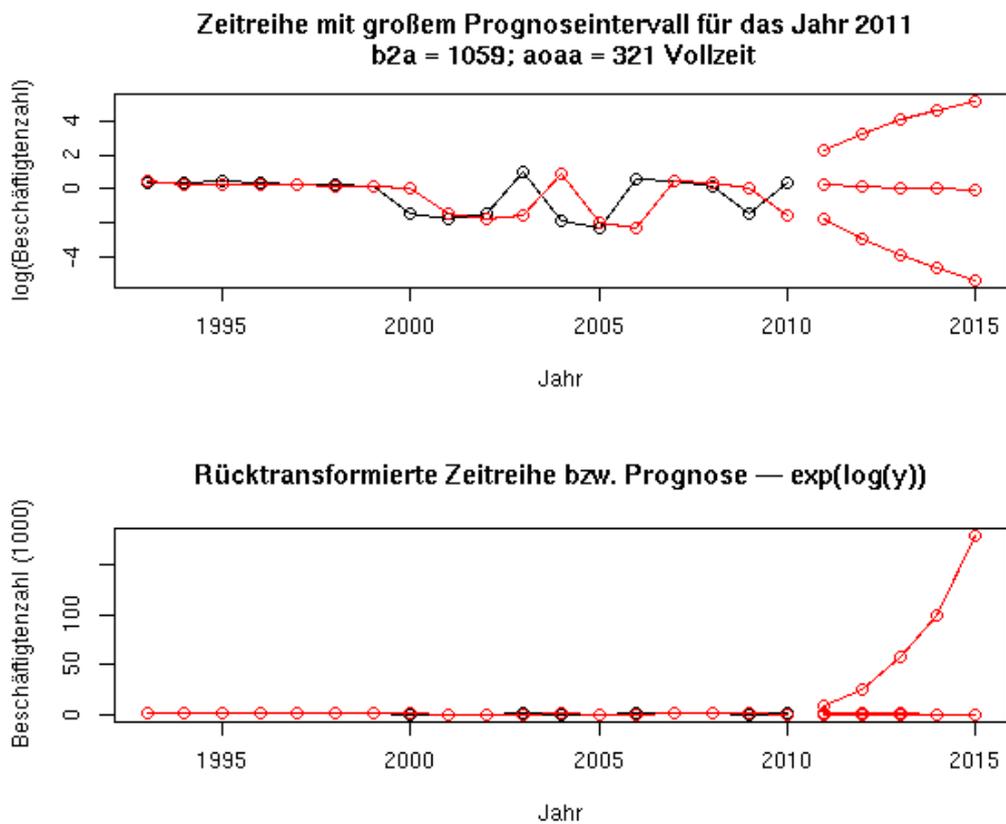


Abbildung 9.3.: Berufe-Regionen-Kombination mit sehr großem Prognoseintervall

9. Intervallprognosen

Die erste zu klärende Frage ist, ab wann eine obere Intervallgrenze als kritisch groß zu betrachten ist. Wird beispielsweise der doppelte Wert der Punktprognose als Grenze gewählt, werden insgesamt 11 Zeitreihen bzw. deren Prognoseintervalle als kritisch groß identifiziert. Wie das folgende Beispiel zeigt, ist damit jedoch kein automatisiertes Urteil über die Plausibilität möglich, siehe Abbildung 9.4. Zwar ist die obere Grenze des Prognoseintervalls um ein Vielfaches größer als die Punktprognose, jedoch ist ohne Kenntnis für den Grund des Bruches bzw. abrupten Absinkens der Beschäftigtenzahl im Jahr 2010 keine Aussage über die Plausibilität des Prognoseintervalls möglich.

Die Behandlung solcher Problemfälle hängt von den Gründen für den ungewöhnlichen Verlauf der Zeitreihe ab. Diese lassen sich bekannterweise nicht mit den Mitteln der Statistik klären. Von daher bleibt im Rahmen dieser Arbeit lediglich die Möglichkeit, auf die Problematik hinzuweisen. In Absprache mit dem Projektbetreuer am IAB sind in der Datenlieferung mit den Intervallprognosen alle

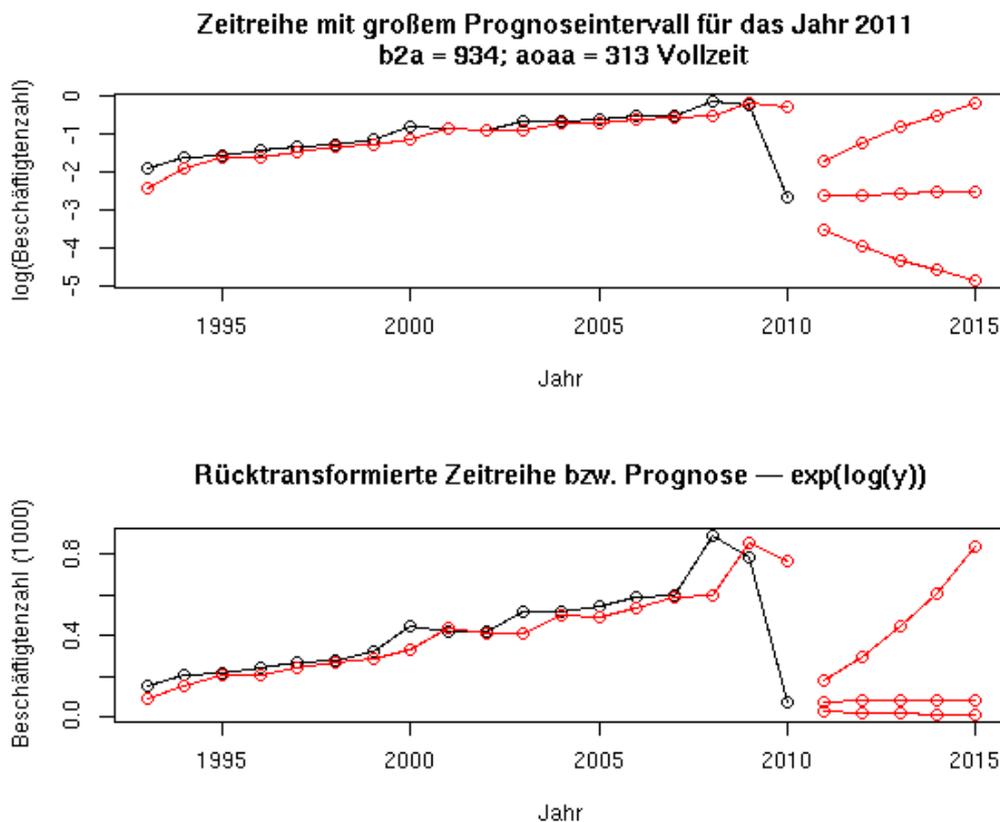


Abbildung 9.4.: Zeitreihe mit großem Prognoseintervall – Vollzeit

Zeitreihen markiert, deren oberes Prognoseintervall für die 1-Schritt-Prognose die entsprechende Punktprognose um 25 Prozent oder mehr übersteigt.

Große Teilzeit Für die Zeitreihen der Beschäftigten in Großer Teilzeit kommt die Analyse qualitativ zu denselben Ergebnissen. Einziger Unterschied ist, dass es keinen so extrem großen Ausreißer bei der absoluten Breite des Prognoseintervalls gibt. Analog zu Abbildung 9.2 sind in Abbildung 9.5 die Intervallbreiten für die 6399 Zeitreihen der Teilzeitbeschäftigten in Boxplots dargestellt sowie die Intervallbreiten für die 1-Schritt-Prognosen gegen die entsprechenden Punktprognosen abgetragen. Im Verhältnis zur Punktprognose sind dennoch einige, möglicherweise kritisch große Prognoseintervalle, zu beobachten (in Rot eingefasst). Daher werden auch hier die Zeitreihen mit verhältnismäßig großen Prognoseintervallen markiert.

Extrem große Prognoseintervalle Um einen Eindruck davon zu gewinnen, ob die Plausibilität der oberen Intervallgrenze ab einem gewissen Schwellenwert

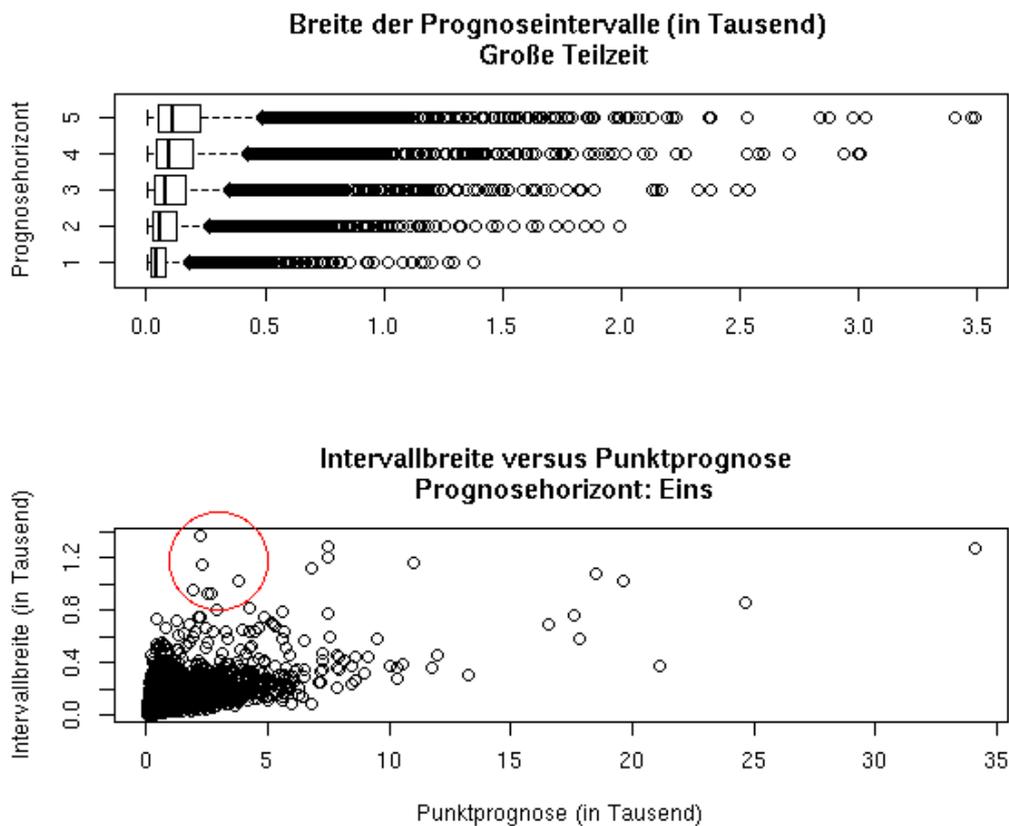


Abbildung 9.5.: Breite der Prognoseintervalle – Große Teilzeit

9. Intervallprognosen

ausgeschlossen werden kann, sind in den Abbildungen A.96 bis A.105 auf den Seiten 261–265 die Zeitreihen, bei denen die obere Intervallgrenze doppelt so groß ist wie die Punktprognose (je bezogen auf den Prognosehorizont Eins), geplottet.

Trotz dieser sehr großen Prognoseintervalle erscheinen diese für einige Berufe-Regionen-Kombinationen plausibel (siehe Abbildungen A.96, A.97 und A.98). Für andere wiederum ergeben sich völlig unplausible Intervalle. Es kann keine pauschale Empfehlung für den Umgang mit den großen Intervallen gegeben werden. Die einzige Ausnahme stellt die Zeitreihe für den Berufscodex 1059 im Agenturbezirk Bochum dar. Hier ist es offensichtlich, dass die Prognosen nach unten korrigiert werden müssen.

10. Fazit

Zu Zwecken der Berufsberatung und Konzeption von arbeitsmarktpolitischen Maßnahmen besteht der Bedarf an Prognosen der Beschäftigungsentwicklung für einzelne Berufe innerhalb der Agenturbezirke. In der vorliegenden Arbeit wurden verschiedene Methoden und Modelle auf ihre Tauglichkeit zur Erstellung solcher Prognosen getestet. Im Gegensatz zu anderen Arbeiten auf diesem Gebiet, sind in dieser Arbeit Prognosen für alle 176 Agenturbezirke¹ in Deutschland bei einer relativ feinen beruflichen Differenzierung erstellt worden. Zu diesem Zweck ist eine Neugruppierung der 342 Berufsordnungen aus der Klassifikation der Berufe (KldB 1988) erarbeitet worden. Diese Neugruppierung beruht auf einer Ähnlichkeitsmessung von Berufen, bei der die beobachteten Berufswechsel und die vorherrschenden Bildungsabschlüsse einfließen. Damit ergeben sich aus den 342 Berufsordnungen 260 Berufsgruppen.

Um Prognosen für diese 45.760 Berufe-Regionen-Kombinationen zu erstellen, sind ausschließlich Verfahren eingesetzt worden, die weitestgehend automatisiert funktionieren. Zum Einsatz kamen univariate Innovation-State-Space-Modelle nach Hyndman et al. (2002), parametrische Paneldatenmodelle (fixe Effekte), nichtparametrische Modelle (Kernschätzung) und als Benchmark die Status-quo-Prognose.

Die verschiedenen Modelle und Methoden wurden anhand von artifiziellen Out-of-Sample-Prognosen verglichen. Als Kriterium der Prognosegüte sind die mittleren relativen absoluten Prognosefehler (*MAPEP*) berechnet worden. Die Ergebnisse lassen sich wie folgt zusammenfassen:

- Wie erwartet, vergrößern sich die *MAPEPs* mit dem Prognosehorizont.
- In der kurzen Frist sind die Unterschiede der *MAPEPs* zwischen den Verfahren nicht so stark wie in der langen Frist.
- Die sparsamste Modellspezifikation der Paneldatenmodelle schneidet sehr gut ab. Die Modellselektionskriterien AIC und BIC sind im vorliegenden

¹Die Berliner Agenturbezirke wurden zusammengefasst.

Prognosekontext bei der Auswahl der Spezifikation nicht zielführend.

- Die Punktprognosen für die Beschäftigtenzahlen auf höheren Aggregations-ebenen sind im Mittel sehr viel genauer als bei stärkerer Disaggregation. Dies trifft zu für die Vergleiche zwischen Prognosen:
 - Blossfeld-Berufe und Bundesländer versus Jones-Berufe und Agenturbezirke
 - Berufe-Regionen-Kombinationen versus Aggregate

Zusätzlich zum Vergleich der *MAPEPs* sind Boxplots der absoluten prozentualen Prognosefehler erstellt worden. Diese zeigen, dass das hier vorgestellte automatische Prognosesystem nicht in der Lage ist, mit Strukturbrüchen, z. B. einem extremen Rückgang der Beschäftigtenzahl, gegen Ende des Beobachtungszeitraums umzugehen. Ohne weitere Information ist das System nicht in der Lage zu beurteilen, ob es sich z. B. um die Schließung einer großen Firma oder nur um einen Datenfehler handelt. Für einige Zeitreihen resultieren daraus sehr weite Prognoseintervalle. Die Plausibilität solcher extremen Intervalle kann nur im Einzelfall von Experten geprüft werden. Das Prognosesystem lässt sich jedoch verwenden, um kritische Berufe-Regionen-Kombinationen zu identifizieren. In Absprache mit dem Projektbetreuer am IAB ist vereinbart worden, obere Intervallgrenzen, die 25 % über der Punktprognose liegen, zu markieren.

Ebenso wenig ist die Prognose solcher Strukturbrüche ohne zusätzliche Information und manuelle Analysen möglich. Eine Möglichkeit, Expertenwissen oder Prognosen aus anderen Modellen für Aggregate (beruflich oder regional) zu nutzen, ist die Methode Top-down-FP von Athanasopoulos et al. (2009). In der vorliegenden Arbeit sind Aggregatsprognosen erstellt worden. Mittels Top-down-FP sind diese dazu genutzt worden, um die Prognosen auf Ebene der Berufe-Regionen-Kombinationen zu modifizieren. Obwohl die Prognosen der Aggregate exakter sind als die Summen der Prognosen für die Berufe-Regionen-Kombinationen, führt die Anwendung von Top-down-FP für die artifiziellen Out-of-Sample-Prognosen nicht zu Verbesserungen auf Ebene der Berufe-Regionen-Kombinationen.

Ein Ansatzpunkt für weitere Forschung ist die Untersuchung der räumlichen Abhängigkeiten. Dies betrifft die Modellierung und Verwendung im Prognoseprozess. Hier besteht ein großer Spielraum zur Sammlung und Einbeziehung weiterer Modellbestandteile, etwa aus geographischen Informationssystemen, Modellen zur Erfassung von Mobilitätsmustern geographischer Natur sowie über Tätigkeitsfel-

der und der zeitlich-dynamischen Struktur dieser Phänomene. Vor dem Hintergrund der massiven Datenstrukturen des vorliegenden Problems sind die mitunter hohen Rechenintensitäten zu berücksichtigen. Denkbar ist es, die Agenturbezirke ähnlich der siedlungsstrukturellen Kreistypen des Bundesinstituts für Bau-, Stadt- und Raumforschung oder gemäß der von Blien et al. (2010) entwickelten Typisierung zu klassifizieren und für diese Dummy-Variablen in das Modell einzufügen. Um direkte Austauschbeziehungen zwischen benachbarten Regionen zur Prognose zu nutzen, könnten die verzögerten Beschäftigtenzahlen der relevanten Nachbarn ins Modell aufgenommen werden.

Ein dringenderes Problem stellt jedoch die Umstellung bei den Sozialversicherungsmeldungen auf die Klassifikation der Berufe 2010 dar, denn die KldB 1988 lässt sich nicht direkt in die KldB 2010 umschlüsseln. Damit sind auch die hier erstellten Prognosen nicht für die Berufe der KldB 2010 umzurechnen. Sind letztere von Interesse, ergibt sich die Notwendigkeit neue Prognosen unter Verwendung der KldB 2010 zu erstellen. Prinzipiell ließe sich hier die Methode Top-down-FP nutzen. Aggregatsprognosen für die Agenturbezirke lassen sich weiterhin unter Verwendung langer Zeitreihen erstellen. Diese Aggregatsprognosen könnten anhand von Status-quo-Prognosen für die Berufe-Regionen-Kombinationen (jetzt mit der KldB 2010) aufgeteilt werden. Sukzessive, je länger die Zeitreihen der Berufe-Regionen-Kombinationen Jahr für Jahr werden, können dann wieder komplexere Methoden bei deren Prognose verwendet werden.

Literaturverzeichnis

- Aiolfi, M., C. Capistan, und A. Timmermann (2011). *Forecast Combinations*, Chapter 12, pp. 355–391. Oxford Univ. Press.
- Allen, P. und R. Fildes (2003). Econometric forecasting. In J. S. Armstrong (Ed.), *Principles of Forecasting: A Handbook for Researchers and Practitioners*, pp. 303–362. Boston [u.a.]: Kluwer.
- Angulo, A. M. und F. J. Trivez (2010). The impact of spatial elements on the forecasting of spanish labour series. *Journal of Geographical Systems* 12(2), 155–174.
- Armstrong, J. S. (1984). Forecasting by extrapolation: Conclusions from 25 years of research [with comment and reply]. *Interfaces* 14(6), 52–66.
- Armstrong, J. S. und F. Collopy (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting* 8(1), 69–80.
- Armstrong, J. S. und R. Fildes (1995). Correspondence on the selection of error measures for comparisons among forecasting methods. *Journal of Forecasting* 14(1), 67–71.
- Armstrong, J. S. und E. Lusk (1983). The accuracy of alternative extrapolation models: Analysis of a forecasting competition through open peer review. *Journal of Forecasting* 2(3), 259–262.
- Athanasopoulos, G., R. A. Ahmed, und R. J. Hyndman (2009). Hierarchical forecasts for australian domestic tourism. *International Journal of Forecasting* 25(1), 146–166.
- BA (2007). http://www.arbeitsagentur.de/nm_29920/zentraler-Content/A11-Arbeitsmarkt/Allgemein/Arbeitsmarkt-Berufsforschung.html. Zugriff am 22.05.2013.

- BA (2011a). <http://statistik.arbeitsagentur.de/Navigation/Statistik/Grundlagen/Klassifikation-der-Berufe/KldB1975-1992/KldB1975-1992-Nav.html>. Zugriff am 07.06.2013.
- BA (2011b). <http://statistik.arbeitsagentur.de/Navigation/Statistik/Grundlagen/Regionalisierung/Fragen-Antworten-Nav.html>. Zugriff am 23.02.2011.
- BA (2013a). http://www.arbeitsagentur.de/nn_26264/Navigation/zentral/Buerger/Zwischenzeit/Beratung/Beratung-Nav.html. Zugriff am 17.05.2013.
- BA (2013b). Zeitarbeit in Deutschland - Aktuelle Entwicklungen. *Arbeitsmarktberichterstattung: Der Arbeitsmarkt in Deutschland*. Nürnberg.
- Baltagi, B. H. (2008). Forecasting with panel data. *Journal of Forecasting* 27(2), 153–173.
- Baltagi, B. H. (2010). *Econometric analysis of panel data*. Chichester, West Sussex [u.a.]: Wiley.
- Baltagi, B. H., S. H. Song, und W. Koh (2003). Testing panel data regression models with spatial error correlation. *Journal of Econometrics* 117(1), 123–150.
- Blien, U., A. Haas, F. Hirschenauer, E. Maierhofer, A. Tassinopoulos, D. Vollkommer, und K. Wolf (2001). Regionale Arbeitsmarktforschung im IAB. *Mitteilungen aus der Arbeitsmarkt- und Berufsforschung* 34(1), 45–73.
- Blien, U., A. Haas, F. Hirschenauer, E. Maierhofer, A. Tassinopoulos, D. Vollkommer, und K. Wolf (2002). Konzeptionen regionaler Arbeitsmarktforschung im IAB. In G. Kleinhenz (Ed.), *IAB-Kompodium Arbeitsmarkt- und Berufsforschung. Beiträge zur Arbeitsmarkt- und Berufsforschung*, Beiträge zur Arbeitsmarkt- und Berufsforschung (BeitrAB) 250, pp. 293–308. Nürnberg: Institut für Arbeitsmarkt- und Berufsforschung der Bundesanstalt für Arbeit.
- Blien, U. und F. Hirschenauer (2005). Vergleichstypen 2005 Neufassung der Regionaltypisierung für Vergleiche zwischen Agenturbezirken. *IAB Forschungsbericht* (24).

- Blien, U., F. Hirschenauer, und V. Phan thi Hong (2010). Classification of regional labour markets for purposes of labour market policy. *Papers in Regional Science* 89(4), 859–880.
- Blien, U. und A. Tassinopoulos (2001). Forecasting regional employment with the entropy method. *Regional Studies* 35(2), 113–124.
- Blossfeld, H.-P. (1985). *Bildungsexpansion und Berufschancen, Empirische Analysen zur Lage der Berufsanfänger in der Bundesrepublik*. Campus Verlag.
- Borghans, L. und H. Heijke (1994). Een random-coefficienten-model voor het voorspellen van de beroepenstructuur van bedrijfstakken. ROA-W-1994/1, Research Centre for Education and the Labour Market, Maastricht.
- Bureau of Labor Statistics (1997, April). Employment projections. Veröffentlichung im Internet. Zugriff am: 22.07.2009.
- Carbone, R. und J. S. Armstrong (1982). Note. Evaluation of extrapolative forecasting methods: Results of a survey of academicians and practitioners. *Journal of Forecasting* 1(2), 215–217.
- Chatfield, C. (1988). Apples, oranges and mean square error. *International Journal of Forecasting* 4(4), 515–518.
- Chatfield, C. (2001). *Time Series Forecasting*. Chapman & Hall/CRC.
- Chatfield, C., A. B. Koehler, J. K. Ord, und R. D. Snyder (2001). A new look at models for exponential smoothing. *Journal of the Royal Statistical Society. Series D (The Statistician)* 50(2), 147–159.
- Clemen, R. T. (1989). Combining forecasts: A review and annotated bibliography. *International Journal of Forecasting* 5(4), 559–583.
- Cordes, A. (2010). Qualifikatorischer Strukturwandel und regionale Beschäftigungsentwicklung : eine empirische Analyse für Westdeutschland. Forschungsberichte des NIW 37, Niedersächsisches Institut für Wirtschaftsforschung e.V.
- Cörvers, F., A. de Grip, und H. Heijke (2002). Beyond manpower planning: A labour market model for the netherlands and its forecasts to 2006. In M. Neugart und K. Schomann (Eds.), *Forecasting labour markets in OECD countries:*

- Measuring and tackling mismatches*, Chapter 7, pp. 185–223. Edward Elgar Publishing.
- Cörvers, F. und M. Hensen (2007). Forecasting regional labour-market developments by occupation and education. In O. Strietska-Ilina und M. Tessaring (Eds.), *Systems, institutional frameworks and processes for early identification of skill needs*, Number 135 in Cedefop Panorama series, Luxembourg. Präsentiert auf der internationalen Konferenz: „Systems, institutional frameworks and processes for early identification of skill needs“.
- Dangerfield, B. J. und J. S. Morris (1992). Top-down or bottom-up: Aggregate versus disaggregate extrapolations. *International Journal of Forecasting* 8(2), 233–241.
- De Gooijer, J. und R. Hyndman (2006). 25 years of time series forecasting. *International Journal of Forecasting* 22(3), 443–472.
- Debary, N. und C. Ertur (2010). Testing for spatial autocorrelation in a fixed effects panel data model. *Regional Science and Urban Economics* 40(6), 453–470.
- Diebold, F. X. (2007). *Elements of Forecasting* (4. Auflage ed.). Mason, Ohio: South-Western.
- Diebold, F. X. und R. Mariano (1995). Comparing predictive accuracy. *Journal of Business & Economic Statistics* 13, 253–264.
- Diebold, F. X. und P. Pauly (1990). The use of prior information in forecast combination. *International Journal of Forecasting* 6(4), 503–508.
- Drews, N. (2006). Qualitätsverbesserung der Bildungsvariable in der IAB-Beschäftigtenstichprobe 1975-2001. *FDZ Methodenreport* (5).
- DUDEN (2001). *Duden-Fremdwörterbuch* (7. ed.). Mannheim [u.a.]: Dudenverlag.
- Dunn, E. S. J. (1960). A statistical and analytical technique for regional analysis. *Papers in Regional Science* 6(1), 97–112.
- Elhorst, J. P. (2003). Specification and estimation of spatial panel data models. *International Regional Science Review* 26(3), 244–268.

- Elliott, G. und A. Timmermann (2008). Economic forecasting. *Journal of Economic Literature* 46(1), 3–56.
- Fildes, R. (1992). The evaluation of extrapolative forecasting methods. *International Journal of Forecasting* 8(1), 81–98.
- Franses, P. H. (2000). *Time Series models for business and economic forecasting*. Cambridge University Press.
- Frees, E. W. und T. W. Miller (2004). Sales forecasting using longitudinal data models. *International Journal of Forecasting* 20(1), 99–114.
- Gabler-Wirtschafts-Lexikon (1997). *Gabler-Wirtschafts-Lexikon* (14. ed.). Wiesbaden: Gabler.
- Gardner, E. S. J. (1985). Exponential smoothing: The state of the art. *Journal of Forecasting* 4(1), 1–28.
- Gardner, E. S. J. und E. McKenzie (1985). Forecasting trends in time series. *Management Science* 31(10), 1237–1246.
- Ghysels, E., A. Sinko, und R. Valkanov (2007). Midas regressions: Further results and new directions. *Econometric Reviews* 26(1), 53–90.
- Hampel, K., M. Kunz, N. Schanne, R. Wapler, und A. Weyh (2007). Regional employment forecasts with spatial interdependencies. *IAB Discussion Paper* (2).
- Hansmann, K.-W. (1987). Prognose. In E. Dichtl (Ed.), *Vahlens großes Wirtschaftslexikon*. München: Beck [u.a.].
- Haupt, H., K. Kagerer, und J. Schnurbus (2011). Cross-validating fit and predictive accuracy of nonlinear quantile regressions. *Journal of Applied Statistics* 38(12), 2939–2954.
- Haupt, H. und W. Oberhofer (2005). Stochastic response restrictions. *Journal of Multivariate Analysis* 95(1), 66–75.
- He, X. (1997). Quantile curves without crossing. *The American Statistician* 51(2), 186–192.

- Henderson, D. J., R. J. Carroll, und Q. Li (2008). Nonparametric estimation and testing of fixed effects panel data models. *Journal of Econometrics* 144(1), 257–275.
- Hendry, D. F. und K. Hubrich (2011). Combining disaggregate forecasts or combining disaggregate information to forecast an aggregate. *Journal of Business & Economic Statistics* 29(2), 216–227.
- Herndon, T., M. Ash, und R. Pollin (2013). Does high public debt consistently stifle economic growth? a critique of reinhart and rogooff. Technical report, Political Economy Research Institute, UMass Amherst.
- Hsiao, C., Q. Li, und J. S. Racine (2007). A consistent model specification test with mixed discrete and continuous data. *Journal of Econometrics* 140(2), 802–826.
- Hubrich, K. und K. D. West (2010). Forecast evaluation of small nested model sets. *Journal of Applied Econometrics* 25(4), 574–594.
- Hurvich, C. M., J. S. Simonoff, und C.-L. Tsai (1998). Smoothing parameter selection in nonparametric regression using an improved akaike information criterion. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* 60(2), 271–293.
- Hyndman, R., R. Ahmed, G. Athanasopoulos, und H. Shang (2011). Optimal combination forecasts for hierarchical time series. *Computational Statistics and Data Analysis* 55(9), 2579–2589.
- Hyndman, R., A. Koehler, R. Snyder, und S. Grose (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting* 18, 439–454.
- Hyndman, R. J. und Y. Khandakar (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software* 27(i03).
- IAB (2013). <http://www.iab.de/de/forschung-und-beratung/bereiche.aspx>. Zugriff am 17.05.2013.
- Jones, O. (2010). Beschäftigtenprognosen differenziert nach Berufen und Regionen. Diplomarbeit eingereicht an der Fakultät für Wirtschaftswissenschaften an der Universität Bielefeld.

- Jones, O., J. Schnurbus, und H. Haupt (2013). Prognosevergleiche für die Beschäftigtenzahlen auf regionaler Ebene und bei beruflicher Differenzierung. Arbeitspapier.
- Kouassi, E., J. Sango, J. M. Bosson Brou, F. N. Teubissi, und K. O. Kymn (2011). Prediction from the regression model with two-way error components. *Journal of Forecasting* 30(6), 541–564.
- Li, Q. und J. S. Racine (2007). *Nonparametric econometrics*. Princeton, NJ [u.a.]: Princeton Univ. Press.
- Longhi, S. und P. Nijkamp (2007). Forecasting regional labor market developments under spatial autocorrelation. *International Regional Science Review* 30(2), 100–119.
- Makridakis, S., A. Andersen, R. Carbone, R. Fildes, M. Hibon, R. Lewandowski, J. Newton, E. Parzen, und R. Winkler (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of Forecasting* 1(2), 111–153.
- Makridakis, S., C. Chatfield, M. Hibon, M. Lawrence, T. Mills, K. Ord, und L. F. Simmons (1993). The m2-competition: A real-time judgmentally based forecasting study. *International Journal of Forecasting* 9(1), 5–22.
- Makridakis, S. und M. Hibon (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting* 16(4), 451–476.
- Matthes, B., C. Burkert, und W. Biersack (2008). Berufssegmente: Eine empirisch fundierte Neuabgrenzung vergleichbarer beruflicher Einheiten. *IAB Discussion Paper* (35).
- Murrell, P. (2009). *Introduction to Data Technologies*. Chapman and Hall/CRC.
- Ord, J. K., A. B. Koehler, und R. D. Snyder (1997). Estimation and prediction for a class of dynamic nonlinear statistical models. *Journal of the American Statistical Association* 92(440), 1621–1629.
- Parnes, H. S. (1962). *Forecasting educational needs for economic and social development*. Paris: OECD.

- Racine, J. S. (2008). Nonparametric econometrics: A primer. *Foundations and Trends in Econometrics* 3(1), 1–88.
- Reinhart, C. M. und K. S. Rogoff (2010). Growth in a time of debt. *American Economic Review* 100(2), 573–578.
- Schanne, N., R. Wapler, und A. Weyh (2008). Regional unemployment forecasts with spatial interdependencies. *IAB Discussion Paper* (28).
- Schanne, N., R. Wapler, und A. Weyh (2010). Regional unemployment forecasts with spatial interdependencies. *International Journal of Forecasting* 26(4), 908–926.
- Schmalensee, R., T. M. Stoker, und R. A. Judson (1998). World carbon dioxide emissions: 1950–2050. *Review of Economics and Statistics* 80(1), 15–27.
- Schwartz, A. (1973). Interpreting the effect of distance on migration. *Journal of Political Economy* 81(5), 1153–1169.
- Seitz, H. (1996). Prognose der regionalen Verteilung der Beschäftigung in Ostdeutschland. *Mitteilungen aus der Arbeitsmarkt- und Berufsforschung* 29(3), 378–387.
- Smith, D. A. (2002). Forecasting future skill needs in canada. In M. Neugart und K. Schomann (Eds.), *Forecasting labour markets in OECD countries: Measuring and tackling mismatches*, Chapter 3, pp. 66–89. Edward Elgar Publishing.
- Standop, D. (2006). Prognosemethoden, qualitative. In *Wirtschafts-Lexikon*, Handelsblatt. Stuttgart: Schäffer-Poeschel.
- Statistik der Bundesagentur für Arbeit (2010, August). Informationen der BA-Statistik für kommunale Träger. Im Internet. Zugriff am: 07.09.2010.
- Stier, W. (2001). *Methoden der Zeitreihenanalyse*. Berlin: Springer.
- Stock, J. H. (2003). Forecasting economic time series. In B. H. Baltagi (Ed.), *A companion to theoretical econometrics*, Blackwell companions to contemporary economics, Chapter 27, pp. 562–584. Malden, Mass. [u.a.]: Blackwell.
- Stock, J. H. und M. W. Watson (2004). Combination forecasts of output growth in a seven-country data set. *Journal of Forecasting* 23(6), 405–430.

- Swamy, P. A. V. B. (1970). Efficient inference in a random coefficient regression model. *Econometrica* 38(2), 311–323.
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review. *International Journal of Forecasting* 16(4), 437–450.
- Tashman, L. J. und J. M. Kruk (1996). The use of protocols to select exponential smoothing procedures: A reconsideration of forecasting competitions. *International Journal of Forecasting* 12(2), 235–253.
- Tassinopoulos, A. (1996). Eine regionale Beschäftigungsprognose: Ergebnisse für Arbeitsmarktregionen auf dem Gebiet der alten Bundesländer. *Mitteilungen aus der Arbeitsmarkt- und Berufsforschung* 29(3), 363–377.
- Tassinopoulos, A. (2000). *Die Prognose der regionalen Beschäftigungsentwicklung*. Beiträge zur Arbeitsmarkt- und Berufsforschung (BeitrAB) 239. Nürnberg.
- Tiemann, M., H.-J. Schade, R. Helmich, A. Hall, U. Braun, und P. Bott (2008). Berufsfeld-Definitionen des BIBB auf Basis der Klassifikation der Berufe 1992. Wissenschaftliche Diskussionspapiere 105, Bundesinstitut für Berufsbildung, Bonn.
- van der Laan, L. (1996). A review of regional labour supply and demand forecasting in the european union. *Environment and Planning A* 28(12), 2105–2123.
- Wolf, K. (2002). Analyse regionaler Beschäftigungsentwicklung mit einem ökonomischen Analogon zu Shift-Share-Techniken. In G. Kleinhenz (Ed.), *IAB-Kompendium Arbeitsmarkt- und Berufsforschung. Beiträge zur Arbeitsmarkt- und Berufsforschung*, Beiträge zur Arbeitsmarkt- und Berufsforschung (BeitrAB) 250, pp. 325–333. Nürnberg: Institut für Arbeitsmarkt- und Berufsforschung der Bundesanstalt für Arbeit (IAB).

A. Appendix

A.1. Alternative Schätzungen für die Prognosefehlervarianz

Version 1: Maximale Varianzschätzung Die Varianz der Prognosefehler ist größer als die der Störterme. Die Residualvarianz unterschätzt daher möglicherweise die Prognosefehlervarianz. Prinzipiell scheint eine Schätzung anhand der artifiziellen 1-Schritt-Prognosefehler geeigneter zu sein. Da von diesen für jede Zeitreihe (Berufe-Regionen-Kombination) lediglich acht zur Verfügung stehen, ist die Schätzunsicherheit relativ groß. Auch ist nicht ausgeschlossen, dass die empirische Standardabweichung der Prognosefehler

$$\widehat{sd}(e_{br\mathcal{T}+1|\mathcal{T}}) = \sqrt{\frac{1}{8-1} \sum_{\mathcal{T}=2002}^{2009} (e_{i\mathcal{T}+1|\mathcal{T}} - \bar{e}_{i\mathcal{T}+1|\mathcal{T}})^2}, \quad (\text{A.1})$$

mit $\bar{e}_{i\mathcal{T}+1|\mathcal{T}}$ als Mittelwert für die Berufe-Regionen-Kombination i , geringer ist als die der Residuen

$$\widehat{sd}(\hat{u}_{it}) = \sqrt{\frac{1}{18-1} \sum_{t=1993}^{2010} (\hat{u}_{it} - \bar{\hat{u}}_{it})^2}. \quad (\text{A.2})$$

Als Schätzung wird daher der größere der beiden Werte gewählt, um damit die obere und untere Grenze des Prognoseintervalls zu berechnen:

$$\widehat{\log(y_{i\mathcal{T}+1})} \pm \max \left[\widehat{sd}(\hat{u}_{it}); \widehat{sd}(e_{i\mathcal{T}+1|\mathcal{T}}) \right] \quad (\text{A.3})$$

Die mit dem Prognosehorizont steigende Unsicherheit wird über den Multiplikator $MAPEP(p)/MAPEP(1)$ berücksichtigt, siehe Abschnitt 9.2. Mit der Exponentialfunktion werden die Intervallgrenzen wieder in die ursprünglichen Einheiten rücktransformiert.

Für 14.093 der 24.054 Zeitreihen für die Beschäftigten in Vollzeit ist die Va-

A. Appendix

rianz der Residuen größer als die Varianz der artifiziellen Prognosefehler.¹ Das Problem ist, dass für einige Zeitreihen die Varianz der Residuen auf Grund von Ausreißern im Beobachtungszeitraum sehr viel größer ist. Die Konsequenz auf die Intervallbreiten wird im Folgenden untersucht.

Für jeden Prognosehorizont ist ein Boxplot der 24.054 Intervallbreiten erstellt worden, siehe obere Grafik in Abbildung A.1. Aufgrund der Ausreißer erscheinen die Boxen lediglich als Striche. Wie gewünscht, nimmt die Intervallbreite mit steigendem Horizont zu. Um zu prüfen, ob die Schiefe der Verteilung durch die Schiefe bei der Verteilung der Beschäftigtenzahlen über die Berufe-Regionen-Kombinationen hervorgerufen wird, sind in der unteren Grafik von Abbildung A.1 die Intervallbreiten gegen die Punktprognosen abgetragen. Wie erwartet, steigt die Intervallbreite mit dem Niveau der Beschäftigtenzahlen innerhalb einer Berufe-

¹Mit dem R-Skript `fcst/prognoseintervalle_vz-herleitung.R` sind alle folgenden Analysen durchgeführt worden.

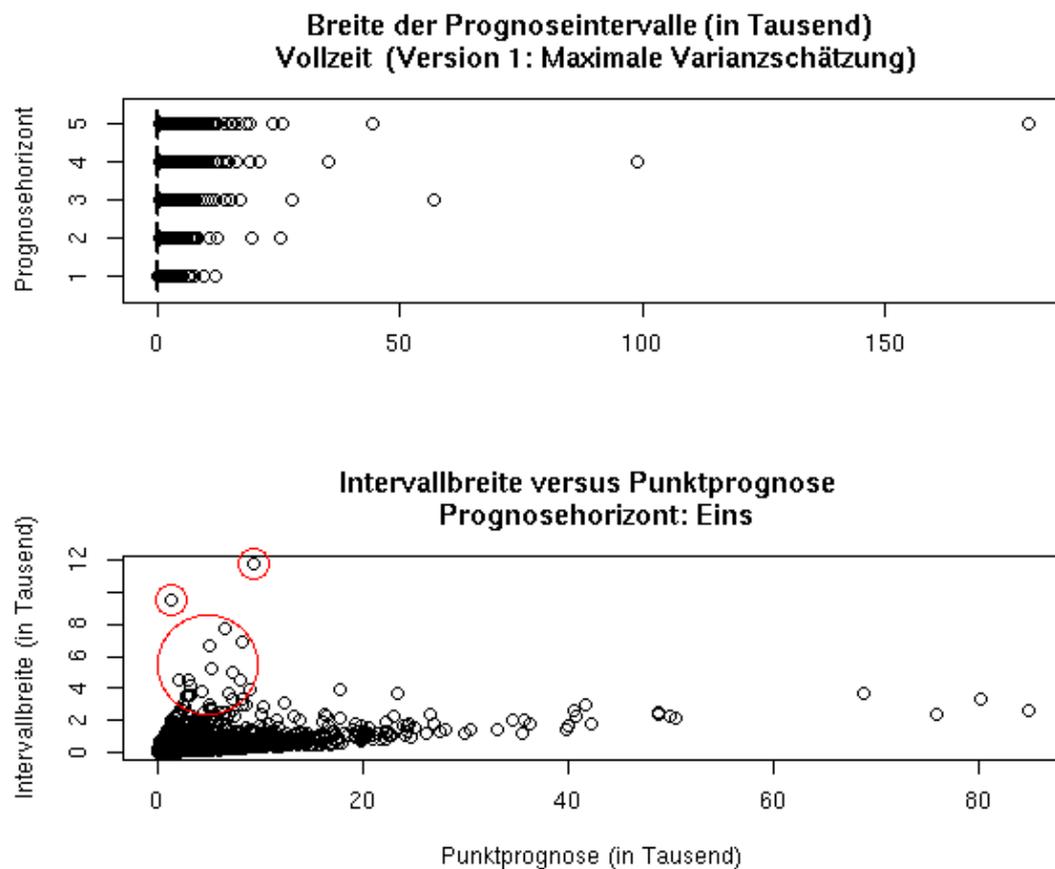


Abbildung A.1.: Breite der Prognoseintervalle – Version 1

A.1. Alternative Schätzungen für die Prognosefehlervarianz

Regionen-Kombination. Es wird aber auch deutlich, dass es Ausreißer (rot markiert) gibt, bei denen die Breite des Prognoseintervalls im Verhältnis zur Punktprognose extrem groß ist.

Für $p = 1$ wird exemplarisch die Zeitreihe mit dem größten Prognoseintervall herausgegriffen und untersucht, wie es zu einem so großen Intervall gekommen ist. In der oberen Grafik der Abbildung A.2 sind die Zeitreihe der logarithmierten Beschäftigtenzahlen (schwarze Kreise), die gefitteten Werte (rote Kreise bis ins Jahr 2010), die acht artifizienen 1-Schritt-Prognosen (blaue Kreuze für die Jahre 2003–2010) und die Prognosen gezeigt. Die Intervallgrenzen in Rot resultieren aus der in (A.3) vorgeschlagenen Berechnung. Die Intervallgrenzen in Blau ergeben sich, wenn die Prognosefehlervarianz anhand der artifizienen 1-Schritt-Prognosefehler geschätzt wird. Aufgrund des Ausreißers im Jahr 1999 ist die Varianz der Residuen viel größer als die Varianz der artifizienen 1-Schritt-Prognosefehler. Da bei

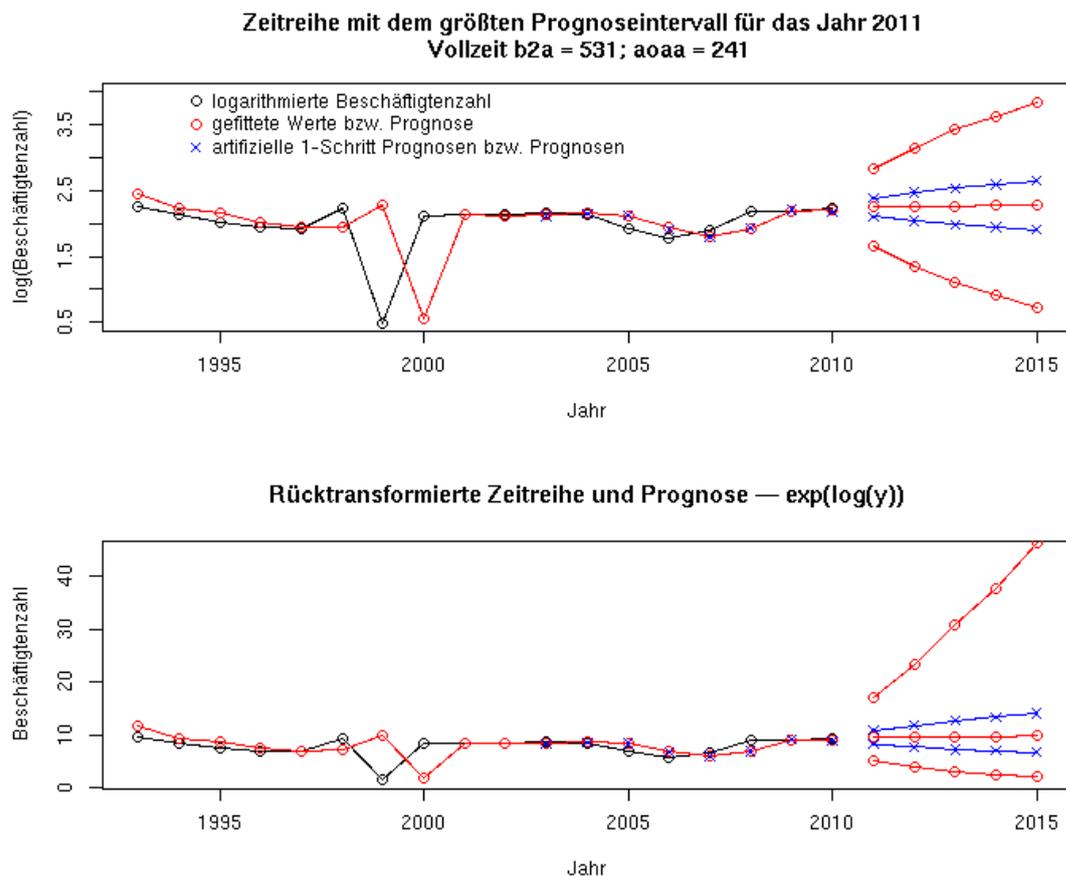


Abbildung A.2.: Zeitreihe mit dem größten Prognoseintervall

A. Appendix

der Berechnung der Prognoseintervalle gemäß (A.3) der größere der beiden Werte verwendet wird, resultieren viel größere Prognoseintervalle.

Die rücktransformierte Zeitreihe ist in der unteren Grafik der Abbildung A.2 dargestellt. Für die logarithmierten Beschäftigtenzahlen liegen die Prognoseintervalle symmetrisch um die Punktprognose. Bei der Rücktransformation durch das Exponentieren wird diese Symmetrie aufgehoben und es entstehen unplausibel große obere Intervallgrenzen (in Rot), wenn die Residualvarianz genutzt wird. Die Prognoseintervalle bei Nutzung der Varianz der artifiziellen 1-Schritt-Prognosefehler (in Blau) sind weiterhin plausibel.

Das eben beschriebene Phänomen tritt bei mehreren Zeitreihen auf. Daher wird im Weiteren zur Schätzung der Prognosefehlervarianz die Varianz der artifiziellen 1-Schritt-Prognosefehler genutzt.

Version 2: Varianz der artifiziellen Prognosefehler In Abschnitt 9.3 wurden die resultierenden Intervallbreiten untersucht. Durch das Exponentieren kommt es immer noch zu einigen extrem großen Intervallen.

Version 3: Berechnung direkt in der Zieleinheit Werden die Prognoseintervalle anstatt für $\log(y)$ für y berechnet, wird das Problem der explodierenden oberen Intervallgrenzen vermieden. Die Berechnung der Intervallprognosen auf Grundlage der in die Zieleinheit rücktransformierten Prognosen geschieht folgendermaßen:

$$\hat{y}_{iT+1} \pm \widehat{sd}(e_{i\mathcal{T}+1|\mathcal{T}}) \quad (\text{A.4})$$

mit

$$\hat{y}_{iT+1} = \exp(\widehat{\log(y_{iT+1})}) \cdot \exp(\hat{\sigma}_u^2/2), \quad (\text{A.5})$$

$$e_{i\mathcal{T}+1|\mathcal{T}} = y_{i\mathcal{T}+1} - \hat{y}_{i\mathcal{T}+1|\mathcal{T}} \quad (\text{A.6})$$

und

$$\widehat{sd}(e_{i\mathcal{T}+1|\mathcal{T}}) = \sqrt{\frac{1}{8-1} \sum_{\mathcal{T}=2002}^{2009} (e_{i\mathcal{T}+1|\mathcal{T}} - \bar{e}_{i\mathcal{T}+1|\mathcal{T}})^2}. \quad (\text{A.7})$$

In Abbildung A.3 auf der nächsten Seite sind wieder Boxplots der Intervallbreiten und eine Grafik der Intervallbreiten versus Punktprognosen zu finden. Das Problem der extrem großen Prognoseintervalle tritt nun nicht mehr auf. Für Punktprognosen in dem Bereich bis ca. 7.000 sind dennoch Intervallbreiten von mehreren Tausend zu beobachten, ob diese unverhältnismäßig groß sind, müsste

einzelnen geprüft werden. Ein Nachteil dieses Vorgehens ist, dass nicht gewährleistet werden kann, dass die Intervalle im positiven Wertebereich bleiben. Für 269 der 24.054 Zeitreihen fallen die Prognosen spätestens für den Horizont von fünf Jahren in den negativen Bereich.

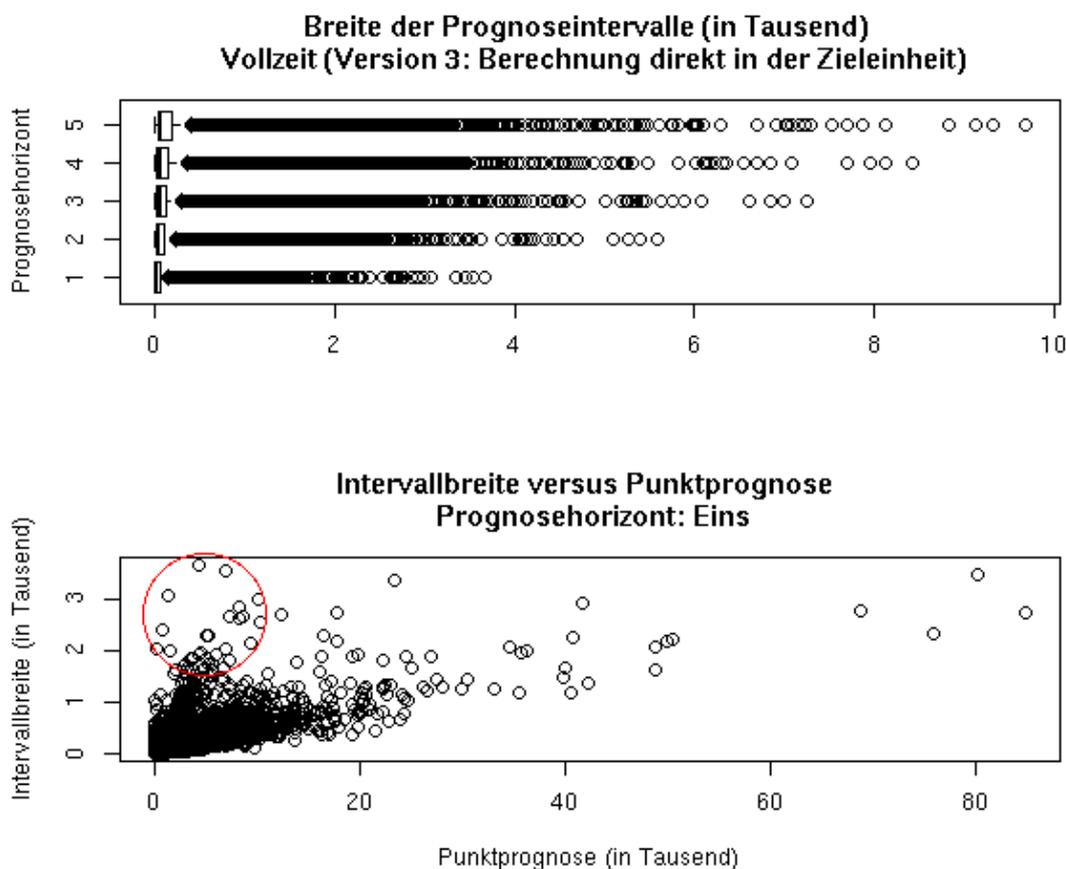


Abbildung A.3.: Breite der Prognoseintervalle – Version 3

Fazit Zur Auswahl stehen die folgenden drei Varianten:

- Version 1: Die Schätzung der Fehlervarianz aufgrund des Maximums aus Residuenvarianz und Fehlervarianz wird ausgeschlossen, da die Zahl der Zeitreihen mit Ausreißern und Brüchen im Beobachtungszeitraum unbekannt ist.
- Version 2: Schätzung der Prognosefehlervarianz anhand der artifiziellen 1-Schritt-Prognosen.

A. Appendix

- Version 3: Die Berechnung direkt in der Zieleinheit verhindert zwar Ausreißer bei den oberen Intervallgrenzen, aber gewährleistet nicht die Positivitätsbedingung.

Letztendlich wurden die Versionen 2 und 3 in die engere Wahl genommen. In Abbildung A.4 sind jeweils die oberen und unteren Intervallgrenzen dieser beiden Versionen gegeneinander abgetragen. In Blau ist jeweils die Winkelhalbierende eingezeichnet. Für die meisten Zeitreihen sind die Unterschiede nur minimal. Bei den unteren Grenzen sind die negativen Grenzen für die Version 3 zu erkennen. Bei den oberen Grenzen stechen ein paar Ausreißer für die Version 2 hervor. Da die Anzahl der Ausreißer bei den oberen Grenzen im Vergleich zu der Anzahl an negativen unteren Grenzen sehr gering ist, wird die Version 2 gewählt.

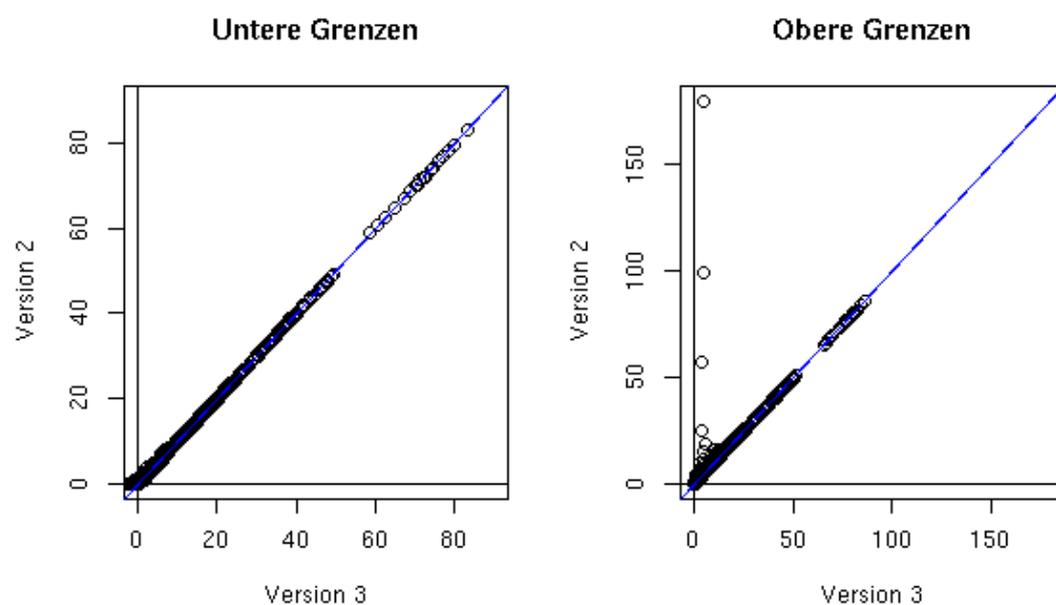


Abbildung A.4.: Intervallgrenzen der Versionen 2 und 3

A.2. Tabellen

Tabelle A.1.: Anzahl der verwendeten Berufs-Codes

Jahr	Berufs-Codes (inkl. Missing)				
	3-Steller			2-Steller	
	BeH Auszüge	einheitlicher Missing-Code	neue & veraltete Codes	BeH Auszüge	einheitlicher Missing-Code
1984	339	339		88	89
⋮	⋮	⋮		⋮	⋮
1988	339	339		88	89
1989	341	341	+(996) +(997)	88	89
1990	341	341		88	89
1991	342	342	+(677)	89	90
1992	341	341	-(677)	88	89
1993	342	341	+(-99)	89	89
1994	342	341		89	89
1995	343	342	+(888)	89	89
1996	344	343	+(924)	89	89
1997	344	343		89	89
1998	344	343		89	89
1999	343	343	-(-99) +(0) -(999)	89	89
2000	342	342	-(-996)	89	89
⋮	⋮	⋮		⋮	⋮
2005	342	342		89	89
2006	343	342	+(-99)	90	89
2007	342	342	-(-99)	89	89
2008	343	342	+(-99)	90	89

Anmerkung zu Tabelle A.1:

Die Berechnung geschieht mittels `anzahl-Berufe.do`. Die Spalte „neue / alte Codes“, welche die Codes enthält, die im Laufe der Zeit hinzukommen bzw. verschwinden, wurden mit Hilfe `anzahl-beruford.do` und `get-miss-codes.do` ermittelt. In Tabelle A.2 werden die Berufsbezeichnungen zu den Codes welche verschwinden und hinzukommen, aufgeführt.

Tabelle A.2.: Liste der Berufs-Codes, welche nicht über den gesamten Zeitraum existieren

Tritt auf in den Jahren	Code	Bezeichnung
bis 1998	(999)	Missing
1993–1998; 2006; 2008	(-99)	Missing
seit 1999	(0)	Missing
1989 - 1999	(996)	Altersteilzeit
seit 1989	(997)	Ausgleichsgeldbezieher
seit 1995	(888)	Pflegepersonen
seit 1996	(924)	Haushaltshilfen

Tabelle A.3.: Anzahl der verwendeten Regionen-Codes

Jahr	Regionen-Codes (inkl. Missing)				
	Kreise		Regierungs- bezirke	Arbeitsagenturen	
	BeH- Auszüge	Berlin zusammen- gefasst	Berlin zusammen- gefasst	BeH- Auszüge	Berlin zusammen- gefasst
1984	329	328	32	146	143
⋮	⋮	⋮	⋮	⋮	⋮
1989	329	328	32	146	143
1990	332	331 (+ 3)	34 (+2)	149	146 (+3)
1991	400	399 (+68)	39 (+5)	173	170 (+24)
1992	415	414 (+15)	39	180	177 (+7)
⋮	⋮	⋮	⋮	⋮	⋮
1998	415	414	39	180	177
1999	414	414	39	179	177
⋮	⋮	⋮	⋮	⋮	⋮
2008	414	414	39	179	177

Anmerkung zu der Tabelle A.3:

Die Berechnung geschieht mittels `anzahl-Regionen.do`. Die Angaben in runden Klammern geben an wieviele Region in dem jeweiligen Jahr hinzukommen. Dabei wurde auch überprüft, ob einige Regionen verwinden. Dies ist nur in Berlin der Fall.

Jahr	Beruf	Arbeitsort	Männer		Frauen		Männer		Frauen		(60 weitere Spalten)	
			VZ	GTZ	KTZ	VZ	GTZ	KTZ	VZ	GTZ	KTZ	10 Altersklassen
1984	0	0										
	:	AA 1										
	:	AA 2										
	0	:										
		AA 142										
:	B 1	0										
	:	AA 1										
	:	AA 2										
	B 1	:										
		AA 142										
:	B 2	0										
	:	AA 1										
	:	AA 2										
	B 2	:										
		AA 142										
	:	:										
	:	:										
:	B 338	0										
	:	AA 1										
	:	AA 2										
	B 338	:										
1984		AA 142										

Tabelle A.4.: Schematische Darstellung der Berufe-Regionen-Häufigkeitsmatrix

A. Appendix

Tabelle A.5.: 60 weitere Spalten der Häufigkeitsmatrix

					Männer			Frauen		
					VZ	GTZ	KTZ	VZ	GTZ	KTZ
[10 Altersklassen (AK)]										
bis 20 Jahre	21 – 25 Jahre	26 – 30 Jahre	...	61 oder älter	10 AK	10 AK	10 AK	10 AK	10 AK	10 AK

60 Spalten

Anmerkung zu den Tabellen A.4 und A.5:

Die Häufigkeitsmatrizen wie sie in Tabelle A.4 skizziert sind, werden erstellt durch `gen-Berufe-Regionen-Tabellen-aoaa-b3.do`.

Tabelle A.6.: Liste der Nicht-Berufe

3-Steller		3-Steller	
Code	Bezeichnung	Code	Bezeichnung
(555)	Behinderte	(971)	Mithelfende Familienangehörige
(666)	Rehabilitanden	(981)	Azubis o. Berufsangabe
(982)	Praktikanten, Volontäre	(983)	arbeitssuchende Arbeitskräfte
(991)	ohne Tätigkeitsangabe	(995)	Vorruhestand
(996)	Altersteilzeit	(997)	Ausgleichsgeldbezieher

Tabelle A.7.: Beschreibung des Datensatzes der Berufe-Regionen-Zeitreihen auf Ebene der Berufsordnungen und Agenturbezirke (Daten bis zum Jahr 2008)

Contains data from oj/data-final/Berufe-Regionen-ZR-aoaa-b3.dta

obs: 1,428,159
vars: 91 18 Aug 2010 11:20
size: 334,189,206 (37.3% of memory free) (_dta has notes)

variable name	storage type	display format	value label	variable label
jahr	int	%8.0g		
beruford	int	%36.0g	lbl_beruford	Beruf: 3-Steller
aoaa	int	%31.0g	lbl_aoaa	Region: Arbeitsamt
m_pers_gesamt	long	%12.0g		
w_pers_gesamt	long	%12.0g		
m_vz	long	%12.0g		
w_vz	long	%12.0g		
m_gtz	int	%12.0g		
w_gtz	int	%12.0g		
m_ktz	int	%12.0g		
w_ktz	int	%12.0g		
m_age20	long	%12.0g		
⋮				
m_age65	int	%12.0g		
w_age20	long	%12.0g		
⋮				
w_age65	int	%12.0g		
m_vz_age20	int	%12.0g		
⋮				
m_vz_age65	int	%12.0g		
m_gtz_age20	int	%12.0g		
⋮				
m_gtz_age65	int	%12.0g		
m_ktz_age20	int	%12.0g		
⋮				
m_ktz_age65	int	%12.0g		
w_vz_age20	int	%12.0g		
⋮				
w_vz_age65	int	%12.0g		
w_gtz_age20	int	%12.0g		
⋮				
w_gtz_age65	int	%12.0g		
w_ktz_age20	int	%12.0g		
⋮				
w_ktz_age65	int	%12.0g		

Sorted by: beruford aoaa jahr

Tabelle A.8.: Verschiedene Aggregationsniveaus:

Bezeichnung und Anzahl der Berufe-Regionen-Kombinationen.
 Die Anzahl der Berufe und Regionen bezieht sich auf das Jahr 2008.
 Da die Kategorie „Ohne Angabe“ nicht hinzu gezählt wird, ist die
 Anzahl der Berufs- bzw. Regionencodes um Eins größer als hier an-
 gegeben.

		Beruf		
		Berufsordnungen (3-Steller)	Berufsgruppen (2-Steller)	Berufsklassen nach Blossfeld
		341	88	12
Region	Kreise 413	B3-K 141 Tsd.	B2-K 36 Tsd.	BB-K 5 Tsd.
	Agenturbezirke 176	B3-A 60 Tsd.	B2-A 15 Tsd.	BB-A 2 Tsd.
	Regierungsbezirke 38	B3-R 13 Tsd.	B2-R 3 Tsd.	BB-R 456
	Länder 16	B3-L 5 Tsd.	B2-L 1,4 Tsd	BB-L 192
	Ost, West 2	B3-OW 682	B2-OW 176	BB-OW 24

Anmerkung zu Tabelle A.8:

Da es im Laufe der Jahre immer wieder zu geografischen Neuabgrenzungen der Zuständigkeitsgebiete in Berlin kam, werden die Agenturen in Berlin nicht getrennt betrachtet. Im Jahr 2008 existieren drei Agenturen in Berlin, aber da sie für unsere Zwecke zusammengelegt werden, wird nur eine "Agentur" gezählt.

Tabelle A.9.: Anzahl der Berufe und Arbeitsagenturen

Jahr(e)	Arbeitsagenturen (inkl. Missing & Berlin zusammengefasst)	Berufe (inkl. Missing & nicht-Berufen)	Anzahl der Berufe- Regionen- Kombinationen
1984–1988	143	339	48.477
1989	143	341	48.763
1990	146	341	49.786
1991	170	341	57.970
1992–1994	177	341	60.357
1995	177	342	60.534
1996–1999	177	343	60.711
2000–2008	177	342	60.534

Anmerkung zu Tabelle A.9:

Berechnungen durch `anzahl-aoaa.do` und `anzahl-beruford.do`.

Tabelle A.10.: Regionale Verteilung der Meldungen ohne Berufsangaben – Westdeutschland

Jahr	Anteil an Regionen in denen Meldungen ohne Berufsangabe auftreten (in %)	Region mit dem größten Anteil an Meldungen ohne Berufsangabe	Größter Anteil an Meldungen ohne Berufsangabe (in %)	Abstand zur Region mit dem zweitgrößten Anteil (in % vom größten Anteil)	Schiefe
1984	0,7	Bonn [323]	0,018	100,0	11,7
1985	0,7	Bonn [323]	0,007	100,0	11,7
1986	1,4	Bonn [323]	0,015	98,4	11,7
1987	3,5	Bonn [323]	0,214	99,5	11,7
1988	2,8	Bonn [323]	0,008	75,8	10,8
1989	2,1	Bonn [323]	0,013	95,2	11,7
1990	5,0	Bonn [323]	0,006	74,4	9,7
1991	9,9	Lüneburg [251]	0,085	71,6	10,7
1992	19,1	Lüneburg [251]	0,015	57,6	7,8
1993	85,1	Bonn [323]	0,050	49,5	3,9
1994	97,2	Bonn [323]	0,128	63,2	6,1
1995	96,5	Bonn [323]	0,261	56,5	6,9
1996	100,0	Bonn [323]	0,529	35,9	7,8
1997	100,0	Bonn [323]	3,782	93,6	11,4
1998	100,0	Bonn [323]	27,795	54,4	9,6
1999	98,6	Wuppertal [391]	0,824	78,9	10,8
2000	9,2	Wuppertal [391]	0,105	29,6	5,9
2001	9,9	Rastatt [657]	0,144	46,1	7,3
2002	9,9	Rastatt [657]	0,294	72,0	9,0
2003	14,9	Rastatt [657]	0,247	66,1	8,2
2004	13,5	Rastatt [657]	0,242	60,5	7,9
2005	9,9	Saarlouis [559]	0,188	45,2	6,9
2006	9,9	Wuppertal [391]	0,265	76,1	9,9
2007	15,6	Wuppertal [391]	0,449	86,0	11,1
2008	22,0	Wuppertal [391]	0,168	88,4	11,3

Anmerkung zu Tabelle A.10:

Berechnung durch `analyse-missing-west.do`. Die Werte aus Spalte zwei beziehen sich nur auf die alten Bundesländer, Berlin ausgenommen. Die Werte in Spalte

vier werden folgendermaßen berechnet:

$$\frac{\text{Anzahl an Meldungen ohne Berufsangabe in Region X}}{\text{Anzahl an Meldungen insgesamt in Region X}} \cdot 100. \quad (\text{A.8})$$

Die Spalte fünf zeigt an wie weit der größte Anteil, in Relation zu sich selbst, vom zweitgrößten Anteil entfernt ist. Die Berechnung geschieht demnach durch:

$$\frac{\text{größter Anteil} - \text{zweitgrößter Anteil}}{\text{größter Anteil}} \cdot 100. \quad (\text{A.9})$$

Ein Wert von 100%, wie er in den ersten beiden Zeilen auftaucht, bedeutet dass der zweitgrößte Anteilswert gleich Null ist. Somit ist in den beiden Fällen Bonn die einzige Region in der Meldungen ohne Berufsangaben auftreten.

Anmerkung zu Tabelle A.11:

Berechnung durch `analyse-missing-ost.do`.

Tabelle A.11.: Regionale Verteilung der Meldungen ohne Berufsangaben – Ostdeutschland

Jahr	Anteil an Regionen in denen Meldungen ohne Berufsangabe auftreten (in %)	Region mit dem größten Anteil an Meldungen ohne Berufsangabe	Größter Anteil an Meldungen ohne Berufsangabe (in %)	Abstand zur Region mit dem zweitgrößten Anteil (in % vom größten Anteil)	Schiefe
1991	96,4	Gera [94]	98,022	0,8	-3,1
1992	100,0	Potsdam [39]	0,447	18,0	0,3
1993	94,3	Plauen [78]	0,016	11,3	1,1
1994	100,0	Frankfurt (Oder) [37]	0,047	15,1	1,3
1995	100,0	Plauen [78]	0,110	39,4	3,1
1996	100,0	Plauen [78]	0,058	7,9	1,1
1997	100,0	Dresden [74]	0,140	2,1	0,0
1998	100,0	Suhl [98]	0,345	7,7	0,8
1999	88,6	Leipzig [75]	0,021	12,8	1,7
2000	11,4	Leipzig [75]	0,016	42,8	4,1
2001	14,3	Leipzig [75]	0,010	38,9	3,7
2002	14,3	Leipzig [75]	0,006	14,2	3,6
2003	20,0	Leipzig [75]	0,016	46,9	4,0
2004	20,0	Leipzig [75]	0,014	49,4	4,1
2005	17,1	Leipzig [75]	0,017	90,5	5,5
2006	14,3	Leipzig [75]	0,010	87,5	5,5
2007	20,0	Leipzig [75]	0,011	88,1	5,4
2008	11,4	Leipzig [75]	0,008	89,9	5,5

Anmerkung zu Tabelle A.12:

Berechnung durch `analyse-missing.do`. Der Anteil an Meldungen ohne Arbeitsortangabe bezieht sich auf die die Anzahl an Personen des jeweiligen Berufs und wird demnach wie folgt berechnet:

$$\frac{\text{Anz. Meldungen für Beruf X ohne Arbeitsortangabe}}{\text{Anz. Meldungen für Beruf X}} \cdot 100. \quad (\text{A.10})$$

Aus Platzgründen sind nur die Berufs-Codes und nicht die Berufsbezeichnungen in der Tabelle aufgeführt. Zur Erinnerung der Berufs-Code Null steht für „keine Angabe“.

Tabelle A.12.: Berufe mit den größten Anteilen an Meldungen ohne Arbeitsortangabe

Jahr	Top 1		Top 2		Top 3		Schiefe
	Anteil	Beruf	Anteil	Beruf	Anteil	Beruf	
1984	0,08	43	0,03	53	0,02	804	10,3
1985	0,08	43	0,04	52	0,04	485	10,4
1986	0,09	43	0,01	875	0,01	991	15,0
1987	0,09	43	0,03	804	0,02	53	12,8
1988	0,28	892	0,15	376	0,05	43	13,9
1989	0,04	31	0,04	43	0,02	842	8,2
1990	0,40	812	0,09	43	0,04	724	16,8
1991	92,00	0	86,20	983	79,39	991	5,8
1992	0,20	995	0,15	463	0,12	43	6,8
1993	26,82	555	8,16	666	1,68	0	16,4
1994	9,63	555	3,01	666	1,19	0	16,1
1995	100,00	888	2,15	0	0,25	854	18,4
1996	100,00	888	12,23	0	3,41	936	18,0
1997	100,00	888	4,73	0	3,63	936	18,3
1998	100,00	888	3,22	936	2,26	854	18,4
1999	48,73	0	1,73	936	0,81	666	18,4
2000	81,83	0	1,36	936	0,70	463	18,4
2001	81,97	0	1,12	936	0,61	463	18,4
2002	59,48	0	0,21	814	0,06	371	18,4
2003	59,06	0	0,02	704	0,00	793	18,4
2004	55,43	0	0,00	832	0,00	882	18,4
2005	54,96	0	0,00	751	0,00	997	18,4
2006	46,33	0	0,00	751	0,00	997	18,4
2007	31,53	0	0,00	751	0,00	781	18,4
2008	63,80	0	0,07	22	0,00	774	18,4

Tabelle A.13.: Beschäftigtenzahlen der Berufe-Regionen-Kombinationen (3-Steller & Agenturbezirke), 8 Größenklassen, relative Häufigkeiten

Jahr	Anzahl Beschäftigter							
	0	1–5	6–10	11–25	26–50	51–100	101–300	> 300
1984	6,2	9,9	5,3	10,3	10,5	12,4	20,4	25,1
1985	6,0	9,8	5,3	10,3	10,4	12,3	20,5	25,3
1986	5,8	9,8	5,3	10,0	10,4	12,2	20,6	25,9
1987	5,6	9,7	5,1	10,2	10,4	12,2	20,7	26,1
1988	6,2	9,6	5,2	9,9	10,4	12,1	20,5	26,0
1989	6,6	9,6	5,2	9,9	10,2	12,0	20,4	26,1
1990	8,2	9,5	5,0	9,6	9,9	11,7	20,1	26,0
1991	17,9	9,9	4,5	8,6	8,5	10,1	17,5	22,9
1992	5,7	9,3	5,0	10,1	10,2	12,1	20,5	27,0
1993	5,4	9,7	5,2	10,5	10,3	12,3	20,3	26,3
1994	5,4	9,8	5,4	10,5	10,5	12,4	20,2	25,8
1995	5,6	9,7	5,5	10,6	10,5	12,3	20,1	25,6
1996	5,9	9,8	5,6	10,7	10,6	12,3	20,1	25,0
1997	5,5	10,0	5,7	10,7	10,7	12,6	20,1	24,7
1998	5,3	10,0	5,6	10,6	10,7	12,4	20,2	25,3
1999	4,9	9,6	5,3	10,5	10,4	12,1	20,5	26,7
2000	4,7	9,5	5,3	10,4	10,3	12,2	20,4	27,2
2001	4,6	9,7	5,4	10,4	10,4	12,1	20,3	27,2
2002	4,8	10,1	5,3	10,4	10,4	12,2	20,0	26,8
2003	5,0	10,2	5,2	10,4	10,3	12,2	20,2	26,4
2004	4,8	10,3	5,5	10,4	10,3	12,2	20,1	26,4
2005	4,9	10,3	5,7	10,4	10,3	12,2	20,0	26,2
2006	4,9	10,4	5,6	10,4	10,3	12,1	20,0	26,4
2007	4,7	10,4	5,7	10,3	10,1	12,0	20,0	26,7
2008	4,8	10,5	5,7	10,3	10,1	12,0	19,9	26,8

Anmerkung zu Tabelle A.13:

Berechnung durch `tab-Zellenbelegung-b3-aoaa.do`. Die Tabelle dient als Datengrundlage für das Balkendiagramm A.12.

Tabelle A.14.: Meldungen ohne Arbeitsort- und/oder Berufsangabe

Jahr	Anzahl Meldungen insgesamt	Meldungen ohne Berufsangabe	Meldungen ohne Arbeitsort	Weder Ort noch Beruf
1984	19.936.747	38	216	0
1985	20.028.505	16	197	0
1986	20.700.502	34	217	0
1987	20.926.855	484	156	0
1988	20.966.845	21	121	0
1989	21.342.450	33	160	0
1990	22.001.996	20	292	0
1991	26.150.427	3.096.602	3.255.954	2.848.933
1992	28.510.373	13.721	2.143	14
1993	27.681.996	1.366	2.174	23
1994	27.030.527	3.277	4.022	39
1995	26.904.933	4.095	42.142	88
1996	26.465.110	8.359	43.241	1.022
1997	26.067.387	31.940	55.116	1.512
1998	26.624.835	219.798	209.987	4.461
1999	30.370.749	9.905	13.493	4.827
2000	31.192.212	7.204	17.424	5.895
2001	313.25.059	6.912	12.365	5.666
2002	30.765.447	6.131	4.538	3.647
2003	30.345.696	6.048	3.604	3.572
2004	30.592.874	5.845	3.262	3.240
2005	30.077.523	5.031	2.767	2.765
2006	30.487.143	3.512	1.629	1.627
2007	31.053.718	2.877	912	907
2008	31.397.242	1.768	1.136	1.128

Anmerkung zu Tabelle A.14:
Berechnung durch `tab-missing.do`.

Tabelle A.15.: Klassifikation der Berufe nach Blossfeld (1985)

Berufsklasse	Beschreibung	Zugehörige Berufsordnungen	Beispiele
Agrarberufe	Berufe mit dominant landwirtschaftlicher Orientierung	011–022, 041–051, 053–062	Landwirte, Gärtner etc.
Einfache manuelle Berufe	alle manuellen Berufe, die 1970 mindestens einen 60prozentigen Anteil von Ungelernten aufwiesen	071–133, 135–141, 143, 151–162, 164, 176–193, 203–213, 222–244, 252, 263, 301, 313, 321–323, 332–346, 352–371, 373, 375–377, 402–403, 412, 423–433, 442, 452–463, 465–472, 482, 486, 504, 512–531, 543–549	Schweißer, Bauhelfer etc.
Qualifizierte manuelle Berufe	alle manuellen Berufe, die 1970 höchstens einen 40prozentigen Anteil von Ungelernten aufwiesen	134, 142, 144, 163, 171–175, 201, 202, 221, 251, 261–262, 270–291, 302, 305–312, 314, 315, 331, 351, 372, 374, 378–401, 411, 421–422, 441, 451, 464, 481, 483–485, 491–503, 511, 541, 542	Glasbläser, Schriftsetzer etc.
Techniker	alle technischen Fachkräfte	303, 304, 621–635, 721, 722, 733, 857	Funker, Medizinallaboranten etc.
Ingenieure	hochqualifizierte Fachkräfte zur Lösung naturwissenschaftlicher und technischer Probleme	032, 052, 601–612, 726, 883	Architekten, Chemiker etc.
Einfache Dienste	alle einfachen persönlichen Dienste	685, 686, 688, 706, 713–716, 723–725, 741–744, 791–794, 805, 834, 838, 911–913, 923–937	Wäscher, Kellner etc.
Qualifizierte Dienste	im wesentlichen Ordnungs- und Sicherheitsberufe sowie qualifizierte Dienstleistungsberufe	684, 704, 705, 711, 712, 801–804, 812, 814, 831, 832, 833, 835, 836, 837, 851, 852, 854–857, 892–902, 921–922	Polizisten, Friseur etc.
Semiprofessionen	Dienstleistungsberufe, die sich durch eine Verwissenschaftlichung der Berufsposition auszeichnen	821–823, 853, 861–864, 873–877	Krankenpfleger, Dolmetscher etc.
Professionen	Freie Berufe und hochqualifizierte Dienstleistungsberufe	811, 813, 841–844, 871, 872, 881, 882, 891	Ärzte, Geisteswissenschaftler etc.
Einfache kaufmännische und Verwaltungsberufe	relativ unqualifizierte Büro- und Handelsberufe	682, 687, 731, 732, 734, 782–784, 773	Verkäufer, Postverteiler etc.
Qualifizierte kaufmännische und Verwaltungsberufe	Berufe mit mittleren und höheren verwaltenden und distributiven Funktionen	031, 681, 683, 691–703, 771, 772, 774–781	Bankfachleute, Bürofachkräfte etc.
Manager	Berufe, die die Kontrolle und Entscheidungsgewalt über den Einsatz von Produktionsfaktoren besitzen, sowie Funktionäre in Organisationen	751–763	Geschäftsführer, Steuerberater etc.

Tabelle A.16.: Berufspaare, die gegenseitig jeweils Top-1-Ziel sind

Landarbeitskräfte (41)	Landwirte (11)
Flach-, Tiefdrucker (174)	Buchdrucker (Hochdruck) (173)
Formgießer (202)	Former, Kernmacher (201)
Fräser (222)	Dreher (221)
Sonstige Bauhilfsarbeiter (472)	Maurer (441)
Lager-, Transportarbeiter (744)	Hilfsarbeiter ohne Angabe (531)
Bürofachkräfte (781)	Verkäufer (682)
Diätassistenten (855)	Apothekenhelferinnen (685)
Wächter, Aufseher (792)	Werkschutzleute, Detektive (791)
Sozialarbeiter, Sozialpfleger (861)	Krankenschwestern, -pfleger (853)
Real-, Volks-, Sonderschull. (873)	Gymnasiallehrer (872)

Tabelle A.17.: Regionen mit weniger als 20 Beschäftigten – Große Teilzeit – Die 24 größten Berufe

Beruf	Anzahl an Regionen mit weniger als 20 Beschäftigten getrennt nach Bildungsabschlüssen bzw. deren Kombinationen							
	NA (0)	ohne (1)	mit (2)	FH-Uni (3)	(0),(1),(2)	(0),(1)	(2),(3)	(0),(1),(3)
(781)	40	2	0	0	0	0	0	0
(682)	11	0	0	148	0	0	0	0
(933)	5	0	0	155	0	0	0	0
(853)	102	105	0	143	0	95	0	64
(864)	134	81	0	66	0	64	0	16
(861)	142	6	0	12	0	5	0	1
(411)	25	2	0	137	0	1	0	1
(691)	51	75	0	123	0	76	0	30
(856)	148	117	0	162	0	83	0	62
(862)	120	100	0	2	0	95	0	2
(854)	146	3	0	142	0	2	0	2
(782)	112	68	0	144	0	66	0	53
(773)	149	22	0	113	0	18	0	18
(744)	91	18	2	116	1	12	2	11
(923)	128	16	0	128	0	14	0	12
(873)	81	109	93	5	77	28	5	5
(784)	130	36	0	149	0	22	0	17
(912)	59	22	1	114	0	9	1	9
(531)	98	10	1	134	0	7	1	7
(714)	141	34	0	136	0	26	0	22
(852)	154	168	0	138	0	45	0	82
(732)	112	77	0	96	0	71	0	68
(681)	133	120	0	148	0	106	0	77
(774)	115	122	26	97	20	115	15	72

Tabelle A.18.: 3-Steller-Berufe die aufgesplittet werden

Neuer Berufscode	aufgesplitteter Beruf (3-Steller Code)	Ausbildungsniveau
1001	Bürofachkräfte (781)	ohne Ausbildung oder ohne Angabe
1002	Bürofachkräfte (781)	mit Ausbildung
1003	Bürofachkräfte (781)	Uni/FH
1004	Verkäufer (682)	ohne Ausbildung oder ohne Angabe
1005	Verkäufer (682)	mit Ausbildung oder Uni/FH

Tabelle A.19.: Neue Berufsgruppen bei ÄR 5

Neuer Berufscode	Aggregierte 3-Steller	Neuer Berufscode	Aggregierte 3-Steller
1006	41,11	1061	723,721,722
1007	392,391	1065	873,872,874
1010	842,841	1067	202,201,191
1012	402,401	1068	883,871,882
1014	734,703	1069	854,853,864,862
1015	512,511	1070	694,693,691
1020	835,832	1071	773,686,936
1024	875,831	1079	633,626,142,141
1026	607,601	1082	174,173,177,163,172,171
1028	491,486	1087	501,181
1035	912,911	1088	362,361,342,341,344
1042	712,711	1094	222,221,226,225,285
1043	62,61	1095	275,271,272
1046	685,684	1097	793, 51,262,261,281,472, 441,442,466,462,452,451, 482,622,311,628,621,751, 681,687,744,714,741,522, 323,322,549,270,241,274, 273,923,921,913,411
1047	44,42		
1050	164,161		
1051	813,811		
1053	876,852		
1054	544,192		
1057	352,351,356	1099	546,545,470,471
1059	72,71,301		

Tabelle A.20.: Neue Berufsgruppen nach dem manuellen Aufsplitten der großen Berufsgruppe mit 35 3-Stellern

Neuer Berufscode	Aggregierte 3-Steller	Neuer Berufscode	Aggregierte 3-Steller
1100	241, 261, 262, 270, 273, 274, 281	1105	522, 714, 741, 744
1101	311, 322, 323, 549	1106	621, 622, 628
1102	441, 442, 462, 466, 472, 482	1107	793, 913
1103	451, 452	1108	921, 923
1104	681, 687, 751		

Tabelle A.21.: Zeitreihen mit extrem großen 1-Schritt *APEP*'s – Jones-Berufe & Agenturbezirke – Vollzeit

Jahr	Berufe-Regionen-Kombination	ne1	np1	lm1	lm2-1	lm2-2	lm2-3	lm2-4
2003	Verfelfältiger (176) – Recklinghausen (375)	504	483	451	450	450	450	462
2008	Fischverarbeiter (403) – Deggendorf (815)	775	854	772	772	770	772	780
2007	Maschinenwärter (547) – Rastatt (657)	557	561	510	510	509	509	508
2007	Werkschutz., Detektive (791) – Darmstadt (415)	720	696	672	672	668	669	669
2004	Seelsorger (891) – Darmstadt (415)	741	760	679	679	673	680	690
2004	aggregierte 3-Steller (1059) – Bochum (321)	1752	1668	1525	1525	1515	1518	1508
2008	aggregierte 3-Steller (1059) – Dortmund (333)	512	490	481	481	478	479	481

Tabelle A.22.: Anpassungsgüte der linearen Modelle (alle Prädiktorkombinationen) – Vollzeit – Blossfeld-Berufe & Bundesländer

Modell	Anz. <i>x</i> -Kov.	Verwendete <i>x</i> -Kov.	<i>AIC</i>	<i>SIC</i>
lm2-1	1	fem.share	-9102,042	-8830,688
lm2-2	1	young.num	-9095,478	-8824,125
lm2-3	1	old.num	-9095,346	-8823,992
lm2-4	1	dwage.med	-9139,726	-8868,372
lm2-5	1	smaco.share	-9104,790	-8833,436
lm2-6	2	fem.share, young.num	-9100,392	-8823,008
lm2-7	2	fem.share, old.num	-9100,070	-8822,686
lm2-8	2	fem.share, dwage.med	-9138,589	-8861,205
lm2-9	2	fem.share, smaco.share	-9107,773	-8860,389
lm2-10	2	young.num, old.num	-9093,681	-8816,297
lm2-11	2	young.num, dwage.med	-9140,113	-8862,729
lm2-12	2	young.num, smaco.share	-9102,947	-8825,563
lm2-13	2	old.num, dwage.med	-9138,011	-8860,627
lm2-14	2	old.num, smaco.share	-9103,029	-8825,645
lm2-15	2	dwage.med, smaco.share	-9138,584	-8861,201
lm2-16	3	fem.share, young.num, old.num	-9098,510	-8815,096
lm2-17	3	fem.share, young.num, dwage.med	-9139,107	-8855,693
lm2-18	3	fem.share, young.num, smaco.share	-9106,118	-8822,704
lm2-19	3	fem.share, old.num, dwage.med	-9136,947	-8853,533
lm2-20	3	fem.share, old.num, smaco.share	-9105,836	-8822,422
lm2-21	3	fem.share, dwage.med, smaco.share	-9137,380	-8853,966
lm2-22	3	young.num, old.num, dwage.med	-9138,705	-8855,291
lm2-23	3	young.num, old.num, smaco.share	-9102,148	-8818,734
lm2-24	3	young.num, dwage.med, smaco.share	-9138,832	-8855,418
lm2-25	3	old.num, dwage.med, smaco.share	-9136,725	-8853,311
lm2-26	4	fem.share, young.num, old.num, dwage.med	-9137,621	-8848,177
lm2-27	4	fem.share, young.num, old.num, smaco.share	-9105,014	-8815,569
lm2-28	4	fem.share, young.num, dwage.med, smaco.share	-9137,755	-8848,311
lm2-29	4	fem.share, old.num, dwage.med, smaco.share	-9135,578	-8846,134
lm2-30	4	young.num, old.num, dwage.med, smaco.share	-9137,747	-8848,303
lm2-31	5	fem.share, young.num, old.num, dwage.med, smaco.share	-9136,561	-8841,087
		Min.	-9140,113	-8868,372
		Max.	-9093,681	-8815,096

Tabelle A.23.: Prognosegüte (*MAPEP*) der linearen Modelle (alle Prädiktorkombinationen) – Vollzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm2-1	2,13	3,77	5,02	5,48	6,19	4,52
lm2-2	2,15	3,83	5,10	5,62	6,39	4,62
lm2-3	2,15	3,83	5,11	5,64	6,43	4,63
lm2-4	2,44	4,49	6,23	7,35	8,76	5,85
lm2-5	2,20	3,96	5,33	5,95	6,81	4,85
lm2-6	2,13	3,78	5,03	5,49	6,22	4,53
lm2-7	2,13	3,78	5,04	5,52	6,27	4,55
lm2-8	2,47	4,58	6,43	7,64	9,18	6,06
lm2-9	2,19	3,93	5,28	5,88	6,73	4,80
lm2-10	2,15	3,83	5,12	5,64	6,43	4,63
lm2-11	2,46	4,55	6,33	7,50	8,94	5,96
lm2-12	2,20	3,97	5,34	5,97	6,85	4,87
lm2-13	2,45	4,53	6,30	7,44	8,90	5,92
lm2-14	2,20	3,96	5,33	5,96	6,84	4,86
lm2-15	2,44	4,48	6,22	7,34	8,73	5,84
lm2-16	2,14	3,78	5,04	5,52	6,27	4,55
lm2-17	2,49	4,64	6,51	7,77	9,33	6,15
lm2-18	2,19	3,93	5,29	5,89	6,77	4,81
lm2-19	2,48	4,60	6,45	7,68	9,24	6,09
lm2-20	2,20	3,93	5,28	5,89	6,76	4,81
lm2-21	2,47	4,57	6,40	7,60	9,11	6,03
lm2-22	2,47	4,55	6,33	7,50	8,94	5,96
lm2-23	2,22	3,97	5,34	5,97	6,85	4,87
lm2-24	2,46	4,54	6,31	7,47	8,91	5,94
lm2-25	2,45	4,51	6,27	7,41	8,85	5,90
lm2-26	2,50	4,64	6,52	7,77	9,35	6,16
lm2-27	2,20	3,94	5,29	5,90	6,76	4,82
lm2-28	2,49	4,63	6,49	7,73	9,29	6,13
lm2-29	2,48	4,60	6,44	7,65	9,20	6,07
lm2-30	2,46	4,55	6,31	7,47	8,91	5,94
lm2-31	2,50	4,64	6,50	7,74	9,30	6,14
Min.	2,13	3,77	5,02	5,48	6,19	4,52
Max.	2,50	4,64	6,52	7,77	9,35	6,16

Tabelle A.24.: Anpassungsgüte der linearen Modelle (alle Prädiktorkombinationen) – Große Teilzeit – Blossfeld-Berufe & Bundesländer

Modell	Anz. x -Kov.	Verwendete x -Kov.	AIC	SIC
lm2-1	1	fem.share	-4457,528	-4186,174
lm2-2	1	young.num	-4458,486	-4187,132
lm2-3	1	old.num	-4459,378	-4188,024
lm2-4	1	dwage.med	-4456,517	-4185,163
lm2-5	1	smaco.share	-4659,962	-4388,608
lm2-6	2	fem.share, young.num	-4470,542	-4193,158
lm2-7	2	fem.share, old.num	-4471,598	-4194,214
lm2-8	2	fem.share, dwage.med	-4467,150	-4189,766
lm2-9	2	fem.share, smaco.share	-4663,138	-4385,755
lm2-10	2	young.num, old.num	-4459,112	-4181,728
lm2-11	2	young.num, dwage.med	-4468,667	-4191,283
lm2-12	2	young.num, smaco.share	-4668,315	-4390,932
lm2-13	2	old.num, dwage.med	-4468,010	-4190,626
lm2-14	2	old.num, smaco.share	-4671,909	-4394,525
lm2-15	2	dwage.med, smaco.share	-4658,066	-4380,682
lm2-16	3	fem.share, young.num, old.num	-4471,763	-4188,349
lm2-17	3	fem.share, young.num, dwage.med	-4482,554	-4199,140
lm2-18	3	fem.share, young.num, smaco.share	-4673,229	-4389,815
lm2-19	3	fem.share, old.num, dwage.med	-4481,762	-4198,348
lm2-20	3	fem.share, old.num, smaco.share	-4677,116	-4393,703
lm2-21	3	fem.share, dwage.med, smaco.share	-4661,380	-4377,966
lm2-22	3	young.num, old.num, dwage.med	-4468,681	-4185,267
lm2-23	3	young.num, old.num, smaco.share	-4670,552	-4387,138
lm2-24	3	young.num, dwage.med, smaco.share	-4666,662	-4383,248
lm2-25	3	old.num, dwage.med, smaco.share	-4670,044	-4386,630
lm2-26	4	fem.share, young.num, old.num, dwage.med	-4483,080	-4193,636
lm2-27	4	fem.share, young.num, old.num, smaco.share	-4675,962	-4386,518
lm2-28	4	fem.share, young.num, dwage.med, smaco.share	-4671,885	-4382,441
lm2-29	4	fem.share, old.num, dwage.med, smaco.share	-4675,443	-4385,999
lm2-30	4	young.num, old.num, dwage.med, smaco.share	-4668,758	-4379,314
lm2-31	5	fem.share, young.num, old.num, dwage.med, smaco.share	-4674,418	-4378,944
		Min.	-4677,116	-4394,525
		Max.	-4456,517	-4181,728

Tabelle A.25.: Prognosegüte (*MAPEP*) der linearen Modelle (alle Prädiktorkombinationen) – Große Teilzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm2-1	4,15	6,51	9,25	10,91	12,77	8,72
lm2-2	4,14	6,55	9,21	10,63	12,47	8,60
lm2-3	4,10	6,44	9,01	10,38	12,22	8,43
lm2-4	4,54	7,36	10,68	12,76	15,04	10,08
lm2-5	4,78	7,84	10,69	12,18	14,18	9,93
lm2-6	4,39	6,98	9,99	11,93	13,96	9,45
lm2-7	4,43	7,03	10,05	12,00	14,08	9,52
lm2-8	4,83	7,95	11,70	14,28	16,88	11,13
lm2-9	4,78	7,82	10,76	12,28	14,26	9,98
lm2-10	4,15	6,55	9,19	10,62	12,48	8,60
lm2-11	4,79	7,87	11,44	13,77	16,27	10,83
lm2-12	4,88	8,04	11,04	12,64	14,75	10,27
lm2-13	4,73	7,70	11,11	13,25	15,61	10,48
lm2-14	4,83	7,88	10,78	12,32	14,35	10,03
lm2-15	4,90	8,06	11,15	12,79	14,62	10,30
lm2-16	4,46	7,12	10,17	12,15	14,23	9,63
lm2-17	4,85	7,95	11,35	14,29	17,37	11,16
lm2-18	4,91	8,04	11,13	12,79	14,85	10,34
lm2-19	5,25	8,27	12,33	15,34	18,24	11,89
lm2-20	4,88	7,93	10,96	12,60	14,61	10,19
lm2-21	4,93	8,11	11,32	13,06	14,95	10,48
lm2-22	4,82	7,90	11,45	13,76	16,23	10,83
lm2-23	4,85	7,93	10,86	12,42	14,47	10,11
lm2-24	5,03	8,31	11,58	13,36	15,29	10,71
lm2-25	4,99	8,23	11,41	13,12	15,02	10,55
lm2-26	4,84	7,99	11,40	14,36	17,36	11,19
lm2-27	4,90	7,96	11,02	12,67	14,70	10,25
lm2-28	5,10	8,43	11,86	13,80	15,79	11,00
lm2-29	5,07	8,32	11,66	13,51	15,47	10,81
lm2-30	5,01	8,24	11,45	13,20	15,09	10,60
lm2-31	5,10	8,39	11,79	13,71	15,67	10,93
Min.	4,10	6,44	9,01	10,38	12,22	8,43
Max.	5,25	8,43	12,33	15,34	18,24	11,89

Tabelle A.26.: Prognosegüte (*MAPEP*) der ausgewählten Modelle – Vollzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	2,15	3,82	5,09	5,60	6,36	4,60
lm2-1	2,13	3,77	5,02	5,48	6,19	4,52
ne1	2,10	3,77	5,07	5,63	6,29	4,57
ne2	2,43	4,15	5,62	6,37	7,44	5,20
np1	2,35	4,15	5,69	6,11	7,50	5,16
np2	2,08	3,66	4,91	5,33	5,97	4,39

Tabelle A.27.: Prognosegüte (*MAEP*) der ausgewählten Modelle – Vollzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	2.048	3.685	4.821	5.033	5.588	4.235
lm2-1	2.037	3.665	4.820	5.044	5.639	4.241
ne1	2.033	3.633	4.627	4.663	4.924	3.976
ne2	2.185	3.845	5.191	5.575	6.240	4.607
np1	2.248	3.862	5.045	5.257	6.853	4.653
np2	2.010	3.544	4.495	4.430	4.642	3.824

Tabelle A.28.: Prognosegüte (*MSEP*) der ausgewählten Modelle – Vollzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	0,0000168	0,0000531	0,0000913	0,0000997	0,0001231	0,0000768
lm2-1	0,0000171	0,0000544	0,0000948	0,0001067	0,0001329	0,0000812
ne1	0,0000163	0,0000480	0,0000815	0,0000825	0,0000833	0,0000623
ne2	0,0000190	0,0000589	0,0001047	0,0001230	0,0001606	0,0000932
np1	0,0000205	0,0000572	0,0000899	0,0000900	0,0001644	0,0000844
np2	0,0000156	0,0000450	0,0000756	0,0000728	0,0000715	0,0000561

A. Appendix

Tabelle A.29.: Prognosegüte ($MAPEP$) der ausgewählten Modelle – Große Teilzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	3,96	6,19	8,59	9,85	11,55	8,03
lm2-3	4,10	6,44	9,01	10,38	12,22	8,43
ne1	4,71	8,01	11,28	13,61	16,75	10,87
ne2	6,09	9,20	13,10	14,98	17,64	12,20
np1	6,64	10,19	13,30	15,98	18,75	12,97
np2	4,67	7,92	11,12	13,36	16,56	10,73

Tabelle A.30.: Prognosegüte ($MAEP$) der ausgewählten Modelle – Große Teilzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	0.453	0.796	1.139	1.442	1.781	1.122
lm2-3	0.625	1.039	1.453	1.792	2.138	1.410
ne1	0.660	1.229	1.763	2.277	2.895	1.765
ne2	0.554	0.886	1.303	1.689	2.197	1.326
np1	1.036	1.646	2.159	2.726	3.337	2.181
np2	0.660	1.229	1.762	2.272	2.895	1.764

Tabelle A.31.: Prognosegüte ($MSEP$) der ausgewählten Modelle – Große Teilzeit – Blossfeld-Berufe & Bundesländer

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	0,0000007	0,0000022	0,0000046	0,0000075	0,0000115	0,0000053
lm2-3	0,0000027	0,0000078	0,0000152	0,0000228	0,0000311	0,0000159
ne1	0,0000014	0,0000048	0,0000098	0,0000165	0,0000265	0,0000118
ne2	0,0000010	0,0000025	0,0000058	0,0000105	0,0000202	0,0000080
np1	0,0000036	0,0000090	0,0000154	0,0000241	0,0000358	0,0000176
np2	0,0000014	0,0000050	0,0000100	0,0000166	0,0000268	0,0000120

Tabelle A.32.: Anzahl und Prozentsatz der Fälle, bei denen der tatsächliche Wert den vorhergesagten Wert übersteigt (Blossfeld-Berufe & Bundesländer) – Vollzeit

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	$\frac{605}{1152} = 52,5\%$	$\frac{491}{960} = 51,1\%$	$\frac{372}{768} = 48,4\%$	$\frac{273}{576} = 47,4\%$	$\frac{185}{384} = 48,2\%$	$\frac{1926}{3840} = 50,2\%$
lm2-1	$\frac{608}{1152} = 52,8\%$	$\frac{495}{960} = 51,6\%$	$\frac{372}{768} = 48,4\%$	$\frac{268}{576} = 46,2\%$	$\frac{186}{384} = 48,4\%$	$\frac{1927}{3840} = 50,2\%$
ne1	$\frac{519}{1152} = 45,1\%$	$\frac{385}{960} = 40,1\%$	$\frac{280}{768} = 33,9\%$	$\frac{173}{576} = 30\%$	$\frac{121}{384} = 31,5\%$	$\frac{1458}{3840} = 38\%$
ne2	$\frac{671}{1152} = 58,2\%$	$\frac{538}{960} = 56\%$	$\frac{429}{768} = 55,9\%$	$\frac{326}{576} = 55,9\%$	$\frac{221}{384} = 58,3\%$	$\frac{2184}{3840} = 56,9\%$
np1	$\frac{639}{1152} = 55,5\%$	$\frac{528}{960} = 55\%$	$\frac{411}{768} = 57,4\%$	$\frac{328}{576} = 56,6\%$	$\frac{210}{384} = 62,5\%$	$\frac{3174}{3840} = 56,6\%$
np2	$\frac{561}{1152} = 48,7\%$	$\frac{414}{960} = 43,1\%$	$\frac{304}{768} = 39,6\%$	$\frac{210}{576} = 36,5\%$	$\frac{138}{384} = 35,9\%$	$\frac{1627}{3840} = 42,4\%$

Tabelle A.33.: Anzahl und Prozentsatz der Fälle, bei denen der tatsächliche Wert den vorhergesagten Wert übersteigt (Blossfeld-Berufe & Bundesländer) – Große Teilzeit

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	$\frac{544}{1152} = 47,2\%$	$\frac{500}{960} = 52,1\%$	$\frac{410}{768} = 53,4\%$	$\frac{300}{576} = 52,1\%$	$\frac{221}{384} = 57,6\%$	$\frac{1975}{3840} = 51,4\%$
lm2-1	$\frac{470}{1152} = 40,8\%$	$\frac{418}{960} = 43,5\%$	$\frac{336}{768} = 43,8\%$	$\frac{248}{576} = 43,1\%$	$\frac{175}{384} = 45,6\%$	$\frac{1647}{3840} = 42,9\%$
ne1	$\frac{967}{1152} = 83,9\%$	$\frac{853}{960} = 88,9\%$	$\frac{686}{768} = 89,3\%$	$\frac{526}{576} = 91,3\%$	$\frac{361}{384} = 94\%$	$\frac{3393}{3840} = 88,4\%$
ne2	$\frac{572}{1152} = 49,7\%$	$\frac{481}{960} = 50,1\%$	$\frac{363}{768} = 47,3\%$	$\frac{258}{576} = 44,8\%$	$\frac{174}{384} = 45,3\%$	$\frac{1848}{3840} = 48,1\%$
np1	$\frac{1004}{1152} = 87,2\%$	$\frac{856}{960} = 89,2\%$	$\frac{691}{768} = 90\%$	$\frac{528}{576} = 91,7\%$	$\frac{356}{384} = 92,7\%$	$\frac{3435}{3840} = 89,5\%$
np2	$\frac{936}{1152} = 81,2\%$	$\frac{839}{960} = 87,4\%$	$\frac{684}{768} = 89,1\%$	$\frac{523}{576} = 90,8\%$	$\frac{363}{384} = 94,5\%$	$\frac{3345}{3840} = 87,1\%$

Tabelle A.34.: Anzahl der Berufe-Regionen-Kombinationen mit konstant mindestens 30 Beschäftigten (Anteile der Beschäftigten im Jahr 2008) – Jones-Berufe & Agenturbezirke

	Anzahl “große” Zeitreihen (Beschäftigtenanteil)	Anzahl “kleine” Zeitreihen (Beschäftigtenanteil)
Vollzeit	24.359 (98,3 %)	21.049 (1,7 %)
Große Teilzeit	6.429 (89,2 %)	38.979 (10,8 %)

Tabelle A.35.: Prognosegüte (*MAPEP*) verschiedener Modelle – Jones-Berufe & Agenturbezirke – Vollzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	6,43	9,80	12,70	14,76	16,95	12,13
lm2-1	6,43	9,80	12,70	14,76	16,96	12,13
lm2-2	6,44	9,83	12,76	14,85	17,07	12,19
lm2-3	6,44	9,82	12,74	14,82	17,02	12,17
lm2-4	6,50	9,95	12,94	15,13	17,39	12,38
np1	6,54	10,07	13,11	15,59	17,93	12,65
ne1	6,63	10,41	13,85	16,84	19,59	13,46

Tabelle A.36.: Prognosegüte (*MAPEP*) verschiedener Modelle – Jones-Berufe & Agenturbezirke – Große Teilzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	7,46	10,85	13,93	16,48	18,70	13,48
lm2-1	7,73	11,46	14,97	18,02	20,73	14,58
lm2-2	7,56	11,07	14,28	16,97	19,42	13,86
lm2-3	7,52	10,97	14,12	16,73	19,00	13,67
lm2-4	7,56	11,13	14,36	17,05	19,39	13,90
np1	7,81	11,43	14,52	16,99	19,28	14,01
ne1	7,41	11,17	14,38	17,29	20,12	14,07

Tabelle A.37.: Prognosegüte (*MAPEP*) verschiedener Modelle – Jones-Berufe & Agenturbezirke – Große Teilzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten – Median-Regression

Modell	$p = 1$		$p = 2$		$p = 3$		$p = 4$		$p = 5$		Mittelwert	
	Median	Mean	Median	Mean	Median	Mean	Median	Mean	Median	Mean	Median	Mean
1m1	7,05	7,46	10,17	10,85	12,90	13,93	15,16	16,48	17,10	18,70	12,48	13,48
1m2-1	7,24	7,73	10,67	11,46	13,85	14,97	16,65	18,02	19,18	20,73	13,52	14,58
1m2-2	7,08	7,56	10,23	11,07	13,00	14,28	15,28	16,97	17,26	19,42	12,57	13,86
1m2-3	7,06	7,52	10,18	10,97	12,93	14,12	15,19	16,73	17,13	19,00	12,50	13,67
1m2-4	7,06	7,56	10,19	11,13	12,93	14,36	15,21	17,05	17,12	19,39	12,50	13,90

Tabelle A.38.: Prognosegüte (*MAPEP*) der Bottom-up-Prognosen verschiedener Modelle – Jones-Berufe & Agenturbezirke – Vollzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten

Modell	Aggregation über	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	Berufe ($y_{\bullet r}$)	1,52	3,00	4,83	5,45	8,13	4,59
lm2-1	Berufe ($y_{\bullet r}$)	1,52	3,00	4,83	5,45	8,13	4,59
lm2-2	Berufe ($y_{\bullet r}$)	1,52	3,10	5,06	5,85	8,62	4,83
lm2-3	Berufe ($y_{\bullet r}$)	1,50	2,93	4,75	5,36	8,05	4,52
lm2-4	Berufe ($y_{\bullet r}$)	1,51	2,91	4,67	5,19	7,76	4,41
np1	Berufe ($y_{\bullet r}$)	1,83	3,22	4,22	4,08	4,31	3,53
ne1	Berufe ($y_{\bullet r}$)	1,79	3,22	4,13	4,12	4,23	3,50
lm1	Regionen ($y_{b\bullet}$)	3,42	6,52	9,63	11,42	14,21	9,04
lm2-1	Regionen ($y_{b\bullet}$)	3,42	6,52	9,63	11,42	14,22	9,04
lm2-2	Regionen ($y_{b\bullet}$)	3,46	6,57	9,69	11,50	14,24	9,09
lm2-3	Regionen ($y_{b\bullet}$)	3,45	6,55	9,66	11,42	14,16	9,05
lm2-4	Regionen ($y_{b\bullet}$)	3,46	6,55	9,61	11,29	13,84	8,95
np1	Regionen ($y_{b\bullet}$)	3,67	6,58	9,27	11,47	13,46	8,89
ne1	Regionen ($y_{b\bullet}$)	3,95	7,35	10,69	13,72	16,30	10,40
lm1	Berufe und Regionen ($y_{\bullet\bullet}$)	1,21	3,07	5,59	7,01	10,20	5,41
lm2-1	Berufe und Regionen ($y_{\bullet\bullet}$)	1,21	3,07	5,59	7,01	10,20	5,41
lm2-2	Berufe und Regionen ($y_{\bullet\bullet}$)	1,15	2,09	3,56	3,81	5,90	3,30
lm2-3	Berufe und Regionen ($y_{\bullet\bullet}$)	1,14	2,01	3,37	3,82	6,06	3,28
lm2-4	Berufe und Regionen ($y_{\bullet\bullet}$)	1,19	2,98	5,45	6,80	9,88	5,26
np1	Berufe und Regionen ($y_{\bullet\bullet}$)	1,55	2,67	3,18	2,36	1,80	2,31
ne1	Berufe und Regionen ($y_{\bullet\bullet}$)	1,62	3,04	3,60	2,87	2,59	2,74

Tabelle A.39.: *MAPEP* Vergleich für Top-down-FP – Jones-Berufe & Agenturbezirke – Vollzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm2-1 (original)	6,43	9,80	12,70	14,76	16,96	12,13
lm2-1 (Top-down-FP)	6,54	9,92	12,86	15,03	17,21	12,31
Differenz	0,11	0,12	0,16	0,27	0,25	0,18

Tabelle A.40.: Prognosegüte (*MAPEP*) der Bottom-up-Prognosen verschiedener Modelle – Jones-Berufe & Agenturbezirke – Große Teilzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten

Modell	Aggregation über	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1	Berufe ($y_{\bullet r}$)	2,04	2,83	3,77	4,32	4,91	3,57
lm2-1	Berufe ($y_{\bullet r}$)	2,30	3,23	4,34	5,11	5,79	4,16
lm2-2	Berufe ($y_{\bullet r}$)	2,27	3,23	4,47	5,52	6,65	4,43
lm2-3	Berufe ($y_{\bullet r}$)	2,31	3,26	4,43	5,27	6,01	4,26
lm2-4	Berufe ($y_{\bullet r}$)	2,01	2,83	3,75	4,29	4,84	3,55
np1	Berufe ($y_{\bullet r}$)	2,91	4,54	6,26	7,51	8,78	6,00
ne1	Berufe ($y_{\bullet r}$)	2,54	4,78	6,73	8,73	11,07	6,77
lm1	Regionen ($y_{b\bullet}$)	5,92	9,27	12,75	15,29	17,66	12,18
lm2-1	Regionen ($y_{b\bullet}$)	6,26	10,04	13,98	17,11	20,05	13,49
lm2-2	Regionen ($y_{b\bullet}$)	6,03	9,43	12,99	15,66	18,44	12,51
lm2-3	Regionen ($y_{b\bullet}$)	6,01	9,40	12,94	15,57	18,02	12,39
lm2-4	Regionen ($y_{b\bullet}$)	6,01	9,36	12,75	15,23	17,54	12,18
np1	Regionen ($y_{b\bullet}$)	7,01	10,54	13,87	16,32	18,62	13,27
ne1	Regionen ($y_{b\bullet}$)	6,05	9,45	12,95	15,59	18,48	12,50
lm1	Berufe und Regionen ($y_{\bullet\bullet}$)	1,10	1,67	1,74	1,31	1,40	1,44
lm2-1	Berufe und Regionen ($y_{\bullet\bullet}$)	1,42	1,86	2,47	2,45	2,42	2,13
lm2-2	Berufe und Regionen ($y_{\bullet\bullet}$)	2,84	4,74	7,54	11,31	15,88	8,46
lm2-3	Berufe und Regionen ($y_{\bullet\bullet}$)	2,53	3,86	5,67	7,44	8,73	5,65
lm2-4	Berufe und Regionen ($y_{\bullet\bullet}$)	1,11	1,77	1,81	1,27	1,33	1,46
np1	Berufe und Regionen ($y_{\bullet\bullet}$)	2,67	4,36	5,83	6,71	7,60	5,43
ne1	Berufe und Regionen ($y_{\bullet\bullet}$)	2,28	4,73	6,80	8,97	11,42	6,84

Tabelle A.41.: *MAPEP* Vergleich für Top-down-FP – Jones-Berufe & Agenturbezirke – Große Teilzeit und nur Zeitreihen mit Werten konstant über 29 Beschäftigten zu allen Zeitpunkten

Modell	$p = 1$	$p = 2$	$p = 3$	$p = 4$	$p = 5$	Mittelwert
lm1 (original)	7,05	10,17	12,90	15,16	17,10	12,48
lm1 (Top-down-FP)	7,05	10,16	12,89	15,15	17,08	12,47
Differenz	-0,02	-0,01	-0,01	-0,01	-0,02	-0,01

A.3. Abbildungen

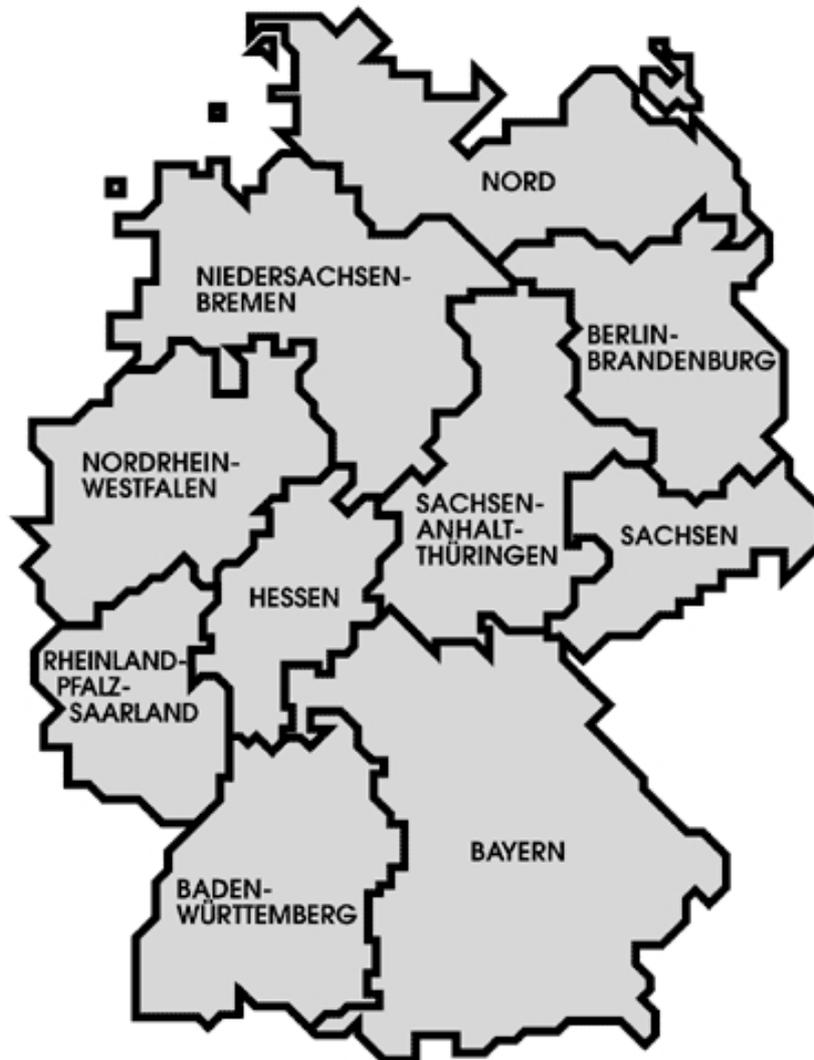
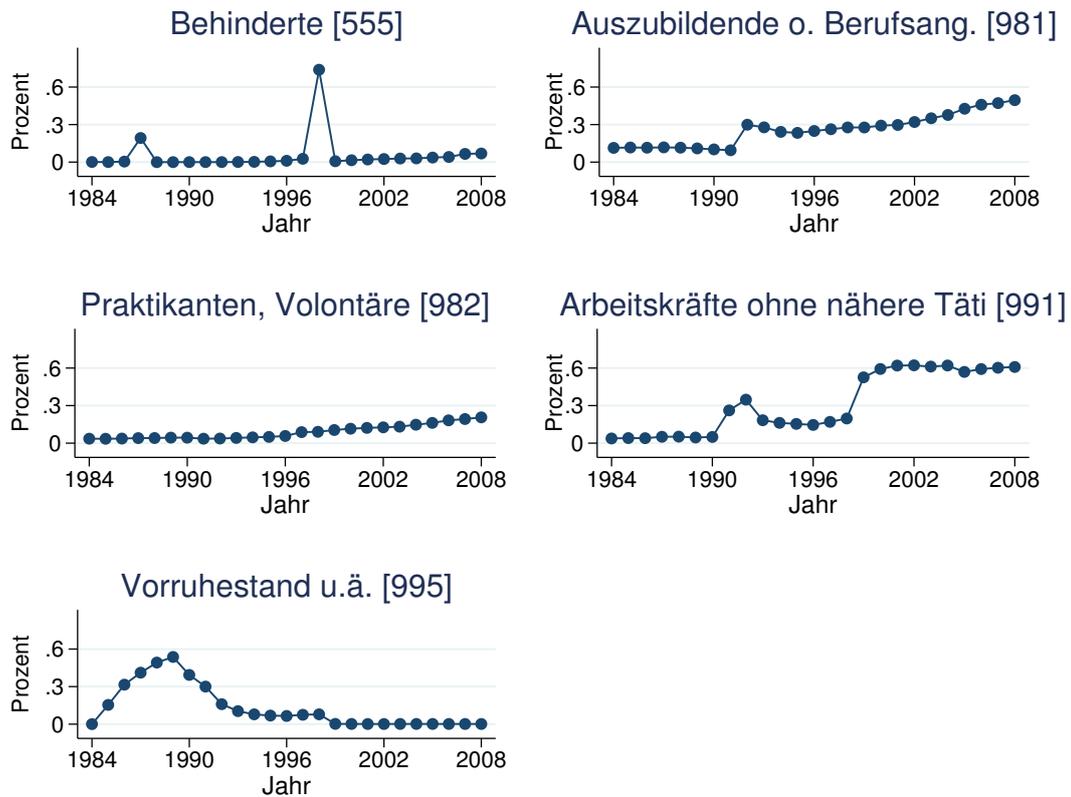


Abbildung A.5.: Karte der 10 Regionaldirektionen

Meldungen zu den "Nicht-Berufen"



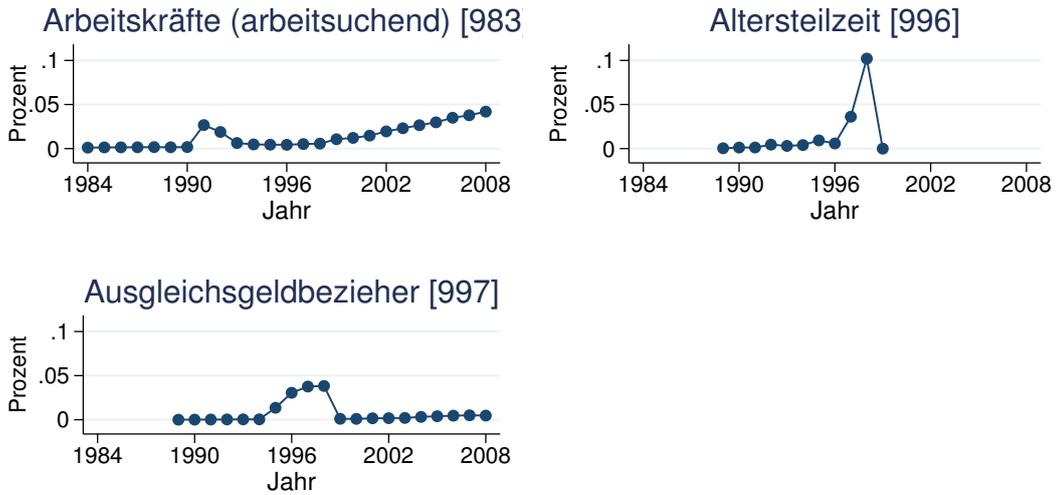
Prozentuale Anteile bezogen auf alle am 30.06. beschäftigten Personen eines Jahres.

Abbildung A.6.: Anteile der Meldungen zu den Nicht-Berufen, Teil A

Anmerkung zu Abbildung A.6:

Auszählungen: `tab-nicht-berufe.do`. Grafik: `plot-nicht-berufe.do`.

Meldungen zu den "Nicht-Berufen"



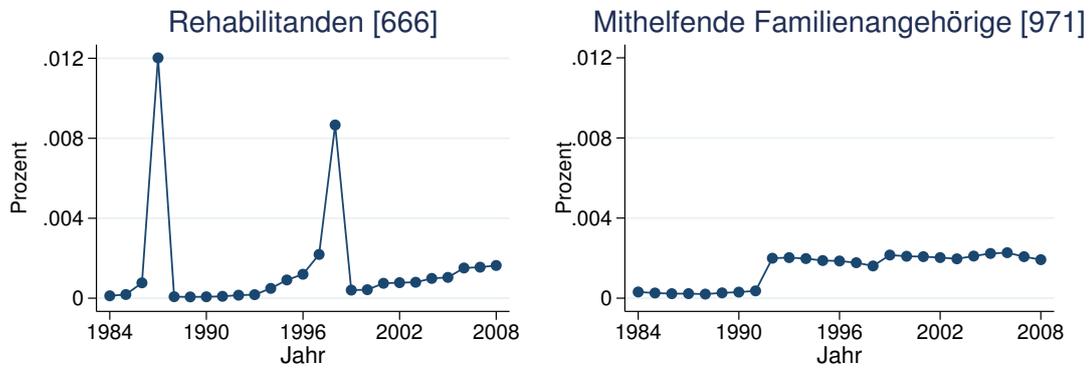
Prozentuale Anteile bezogen auf alle am 30.06. beschäftigten Personen eines Jahres.

Abbildung A.7.: Anteile der Meldungen zu den Nicht-Berufen, Teil B

Anmerkung zu Abbildung A.7:

Auszählungen: `tab-nicht-berufe.do`. Grafik: `plot-nicht-berufe.do`.

Meldungen zu den "Nicht-Berufen"



Prozentuale Anteile bezogen auf alle am 30.06. beschäftigten Personen eines Jahres.

Abbildung A.8.: Anteile der Meldungen zu den Nicht-Berufen, Teil C

Anmerkung zu Abbildung A.8:

Auszählungen: `tab-nicht-berufe.do`. Grafik: `plot-nicht-berufe.do`.

Regionale Verteilung der Meldungen zu "Nicht-Berufe"

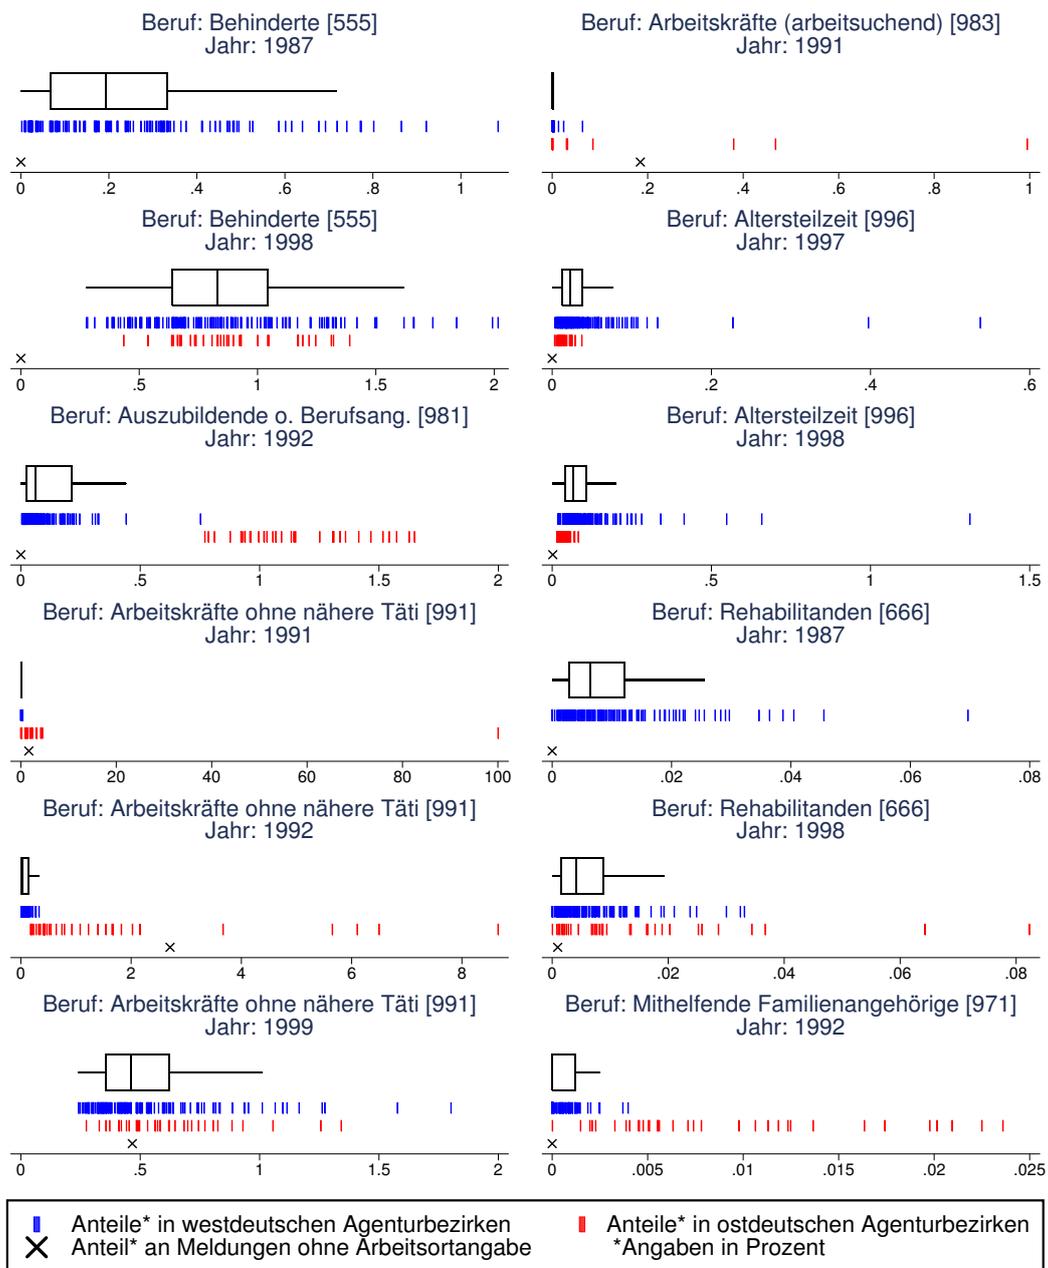


Abbildung A.9.: Regionale Verteilung der anomalen Meldungen zu den Nicht-Berufen, Werte in Prozent

Anmerkung zu Abbildung A.9:

Die Grafik wurde durch `analyse-ausreisser-nicht-berufe.do` erstellt. Die Wer-

A. Appendix

te sind wie folgt berechnet:

$$\left(\frac{\text{Anzahl Altersteilzeit in Bielefeld}}{\text{Anzahl Beschäftigte in Bielefeld}} \right)_t, \quad (\text{A.11})$$

wobei exemplarisch der Nicht-Beruf Altersteilzeit und der Agenturbezirk Bielefeld gewählt sind und t für das Jahr steht.

Differenzen zwischen den Anteilen der Meldungen zu "Nicht-Berufe" für alle Regionen

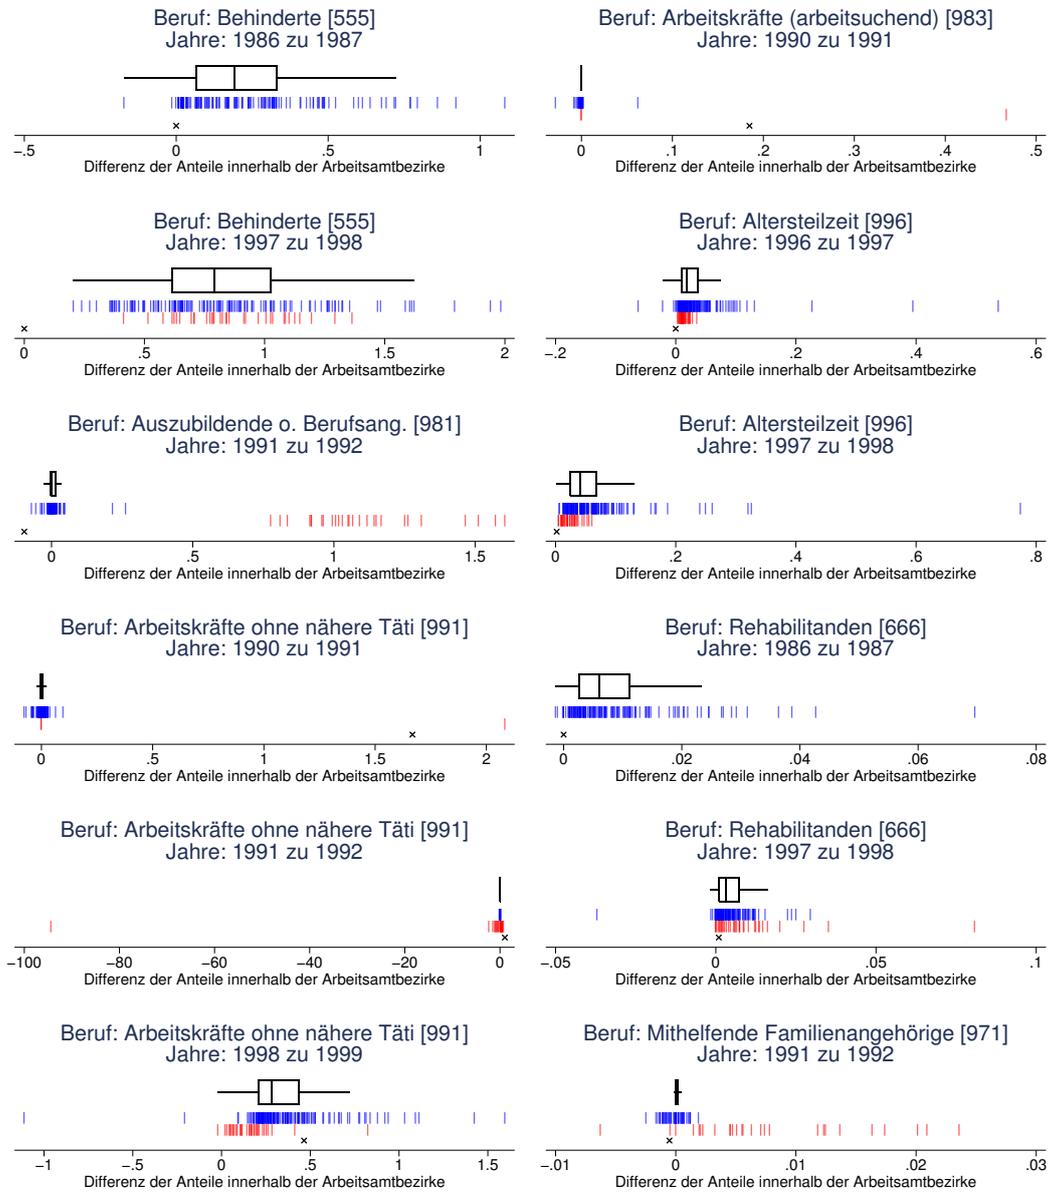


Abbildung A.10.: Differenzen der Anteile der Meldungen zu den Nicht-Berufen innerhalb der Regionen, Werte in Prozentpunkten

Anmerkung zu Abbildung A.10:

Die Grafik wurde durch `analyse-ausreisser-nicht-berufe.do` erstellt. Die Wer-

A. Appendix

te sind wie folgt berechnet:

$$\left(\frac{\# \text{Behinderte in BI}}{\# \text{Beschäftigte in BI}} \right)_t - \left(\frac{\# \text{Behinderte in BI}}{\# \text{Beschäftigte in BI}} \right)_{t-1}, \quad (\text{A.12})$$

wobei # für Anzahl steht und exemplarisch der Nicht-Beruf Behinderte und der Agenturbezirk Bielefeld (BI) gewählt sind; t steht für das Jahr.

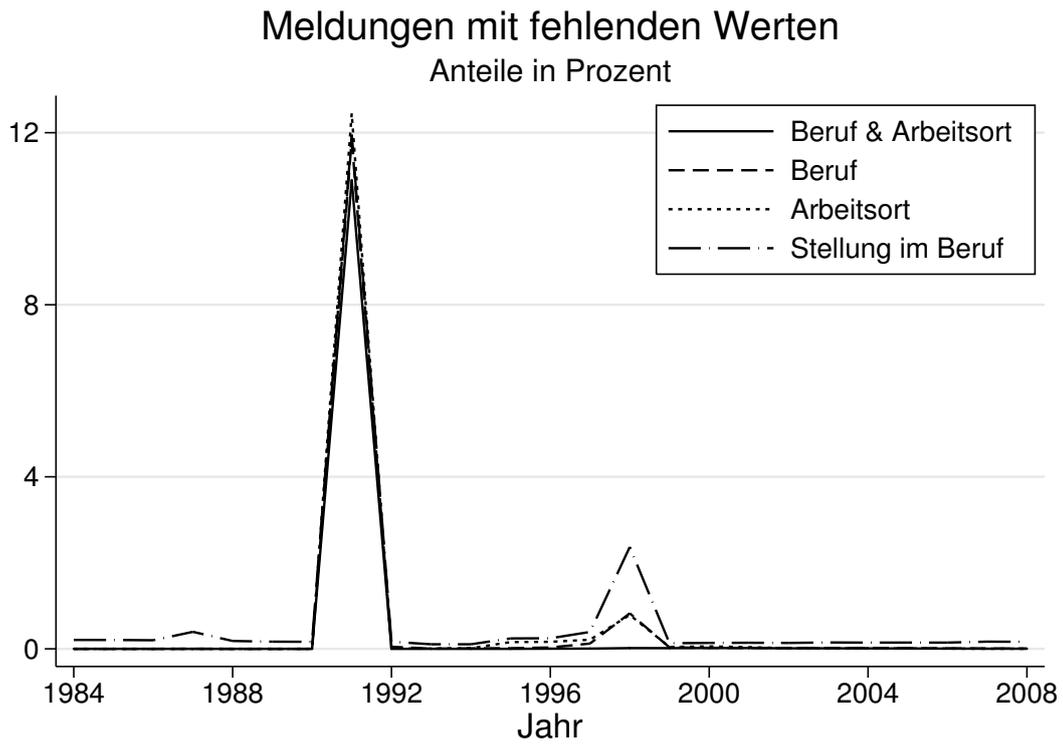


Abbildung A.11.: Anteile der Meldungen mit fehlenden Werten bezogen auf alle Meldungen der jeweiligen Jahre

Anmerkung zu Abbildung A.11: Die Grafik beruht auf den Zahlen aus Tabelle A.14 und wurde durch `plot-missing.do` erstellt.

Zellenbelegung der Berufe-Regionen-Matrix

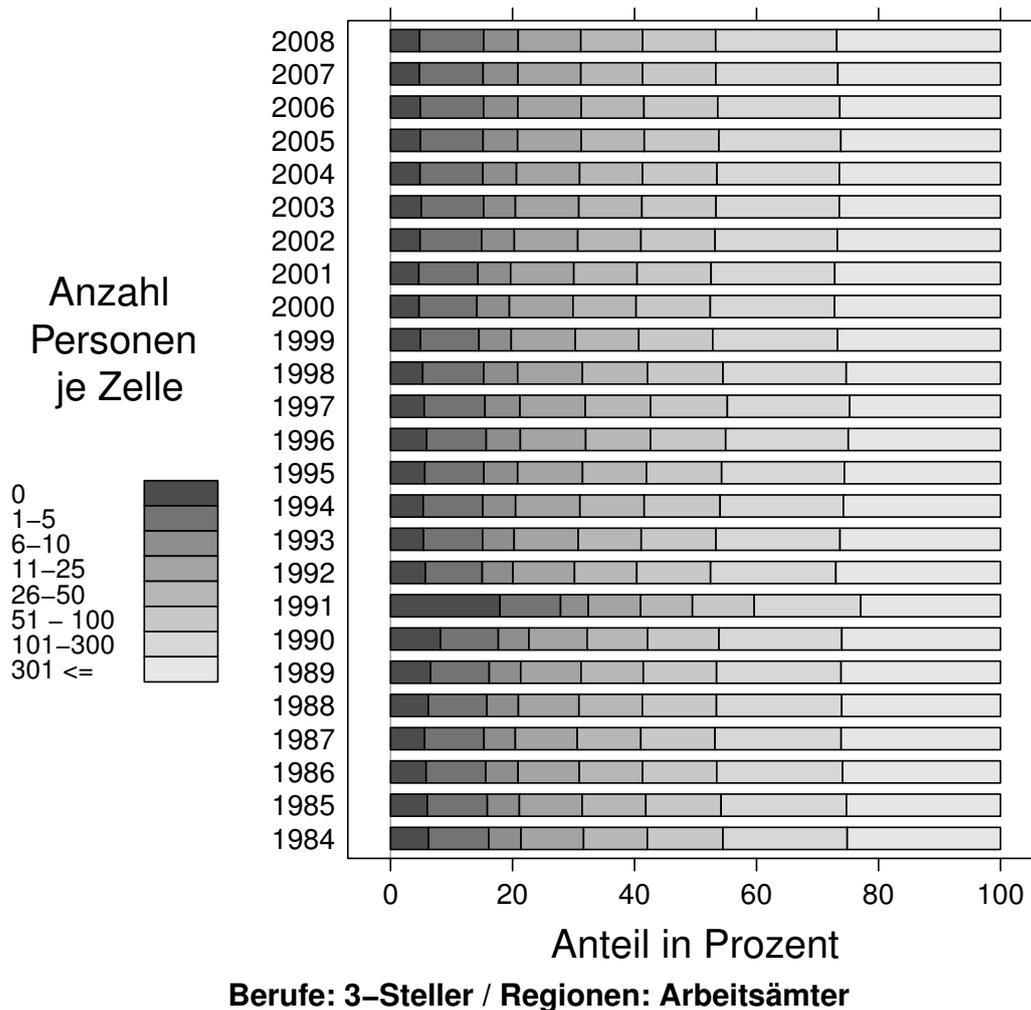


Abbildung A.12.: Anteile der klassierten Zellenbelegungen der Häufigkeitsmatrix

Anmerkung zu Abbildung A.12:

Die Grafik beruht auf den Zahlen aus Tabelle A.13, welche berechnet wurden durch `tab-Zellenbelegung-b3-aoaa.do`.

Erstellt wurde die Grafik durch `plot-Zellenbelegung-b3-aoaa.R`.

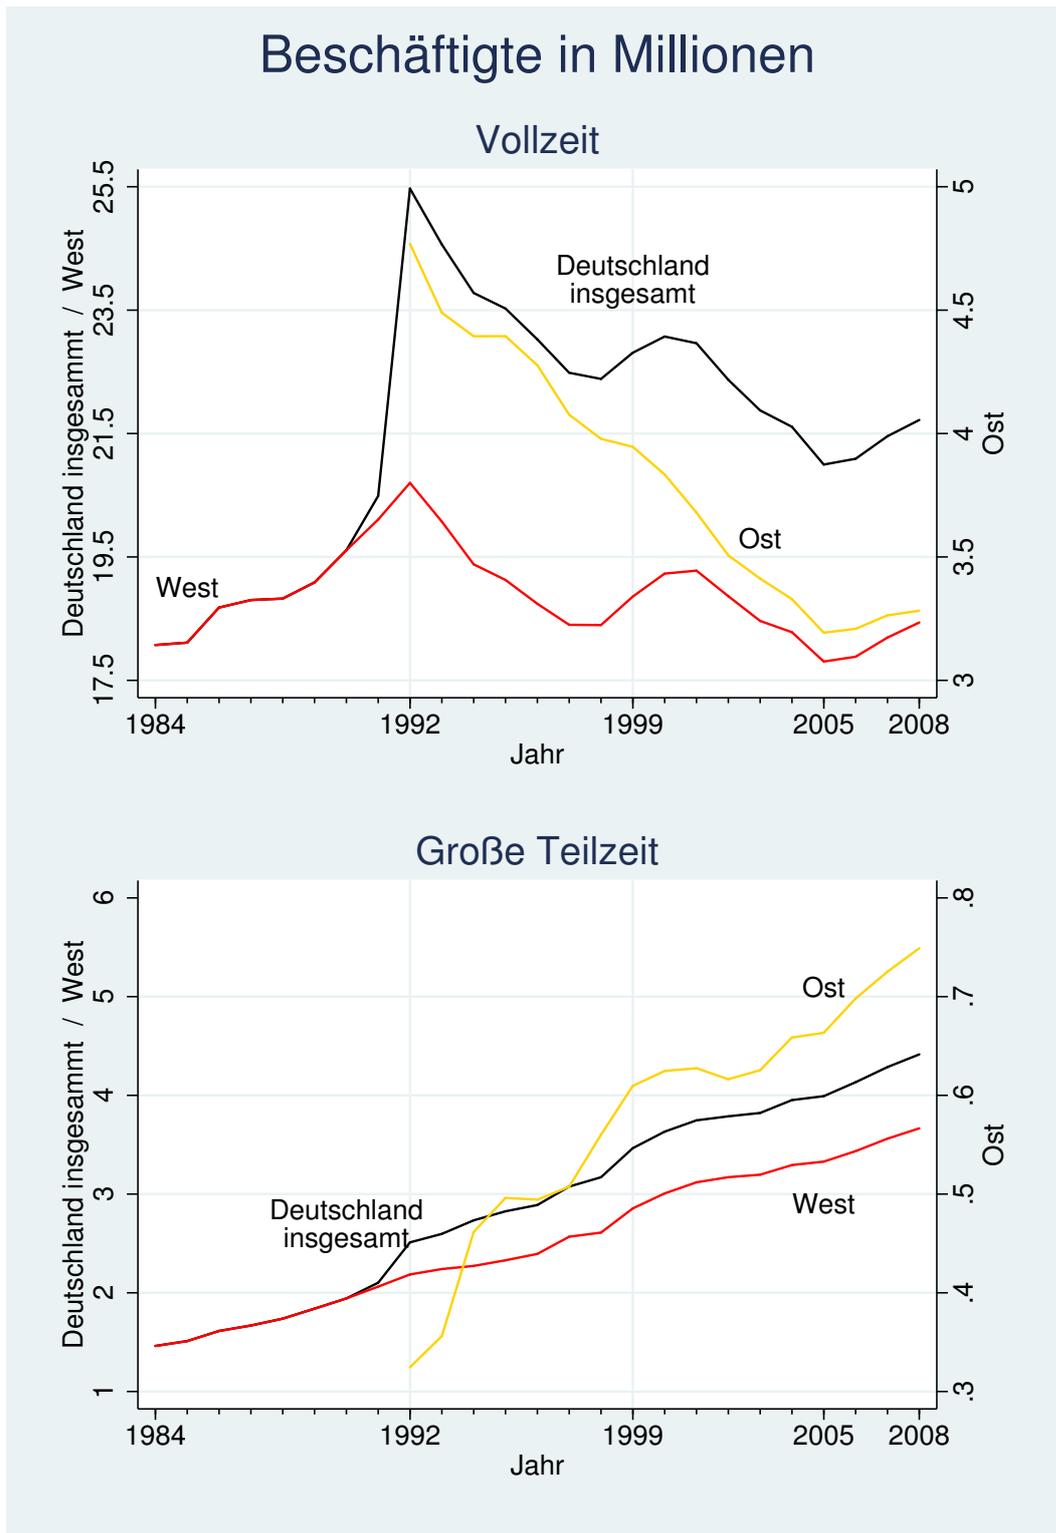


Abbildung A.13.: Anzahl Beschäftigter in West, Ost und Deutschland insgesamt
(individuelle Skalen)
Grafik erstellt mit plot-ZR-aoo-land-regbez.do

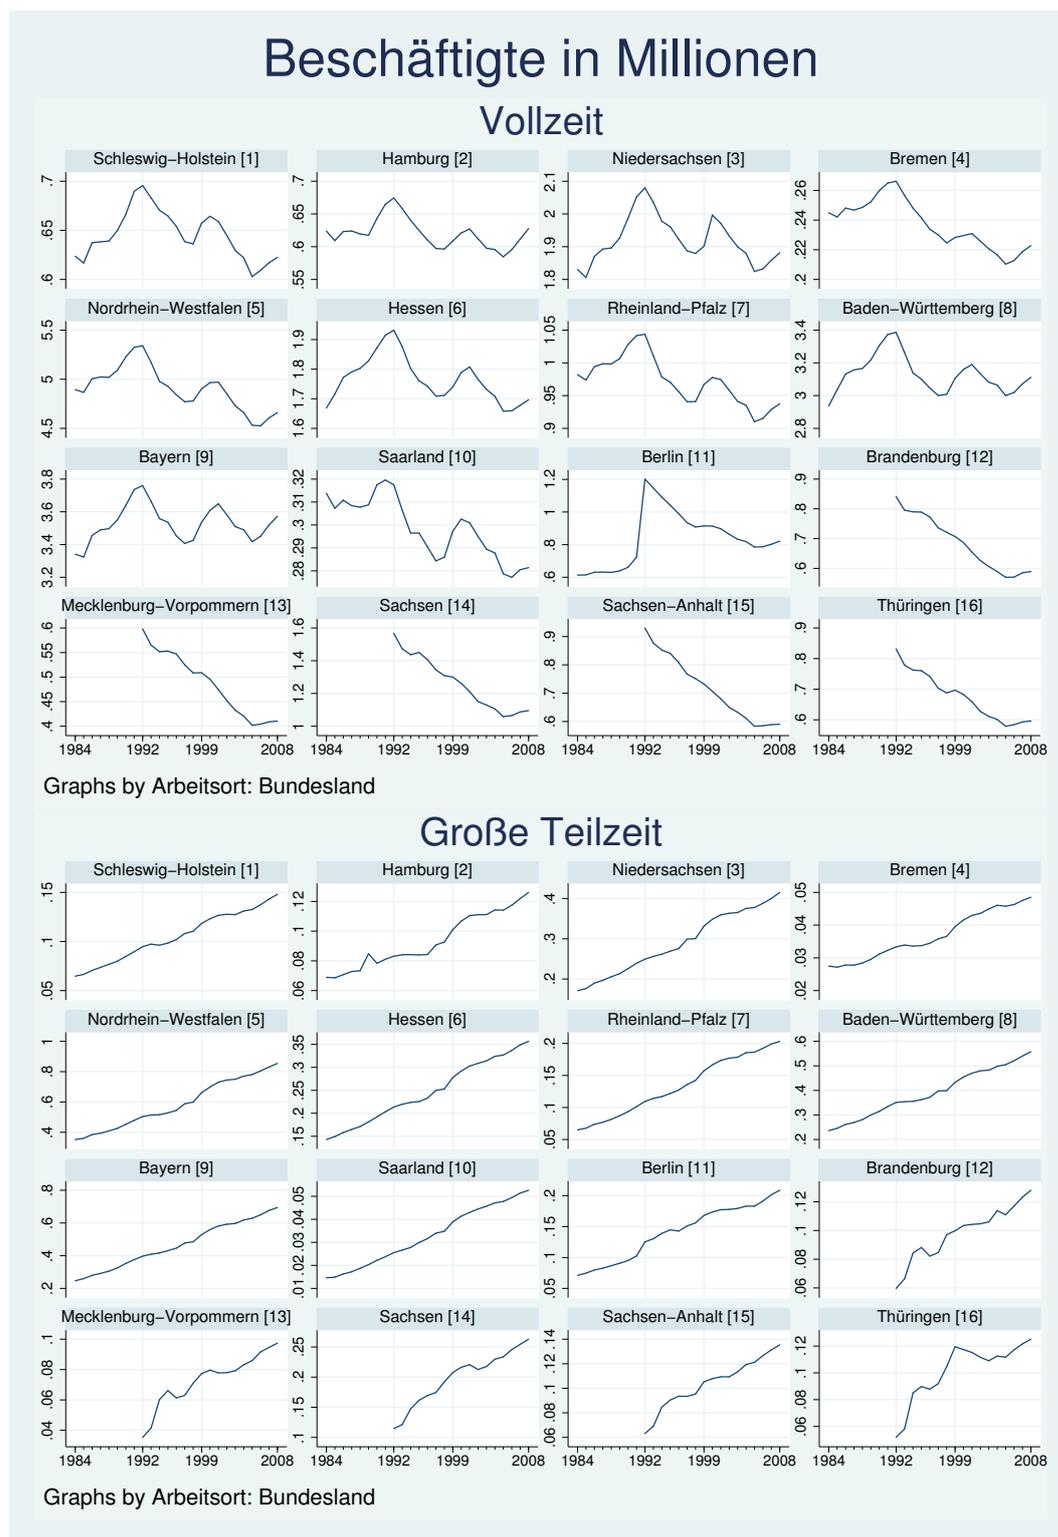


Abbildung A.14.: Anzahl Beschäftigter nach Bundesländern
 (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aooow-land-regbez.do`

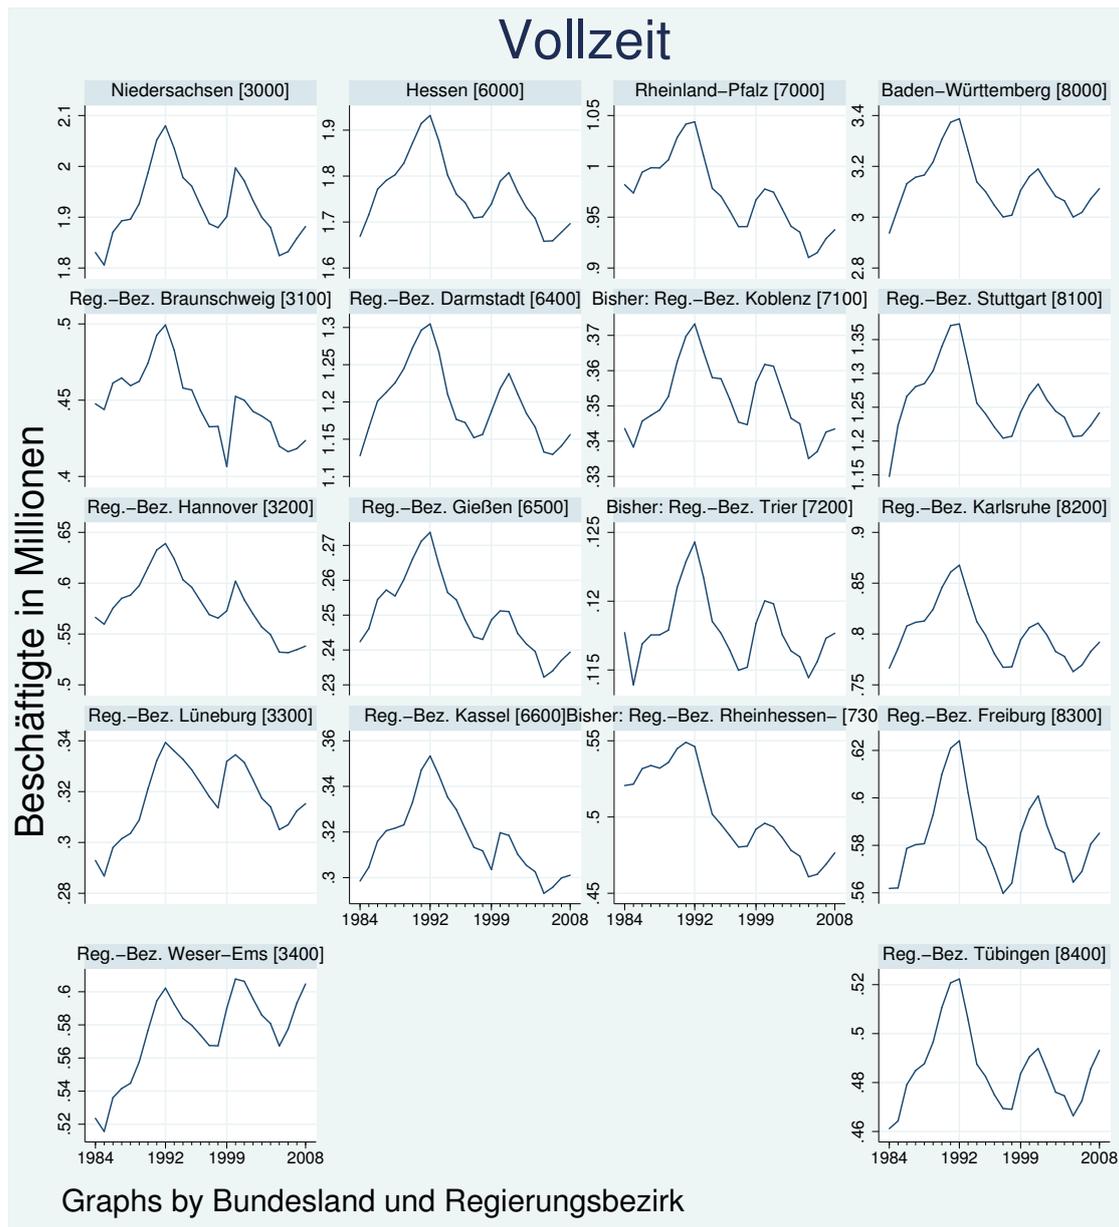


Abbildung A.15.: Anzahl Beschäftigter nach Bundesländern und Regierungsbezirken, A
 Vollzeit (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aow-land-regbez.do`

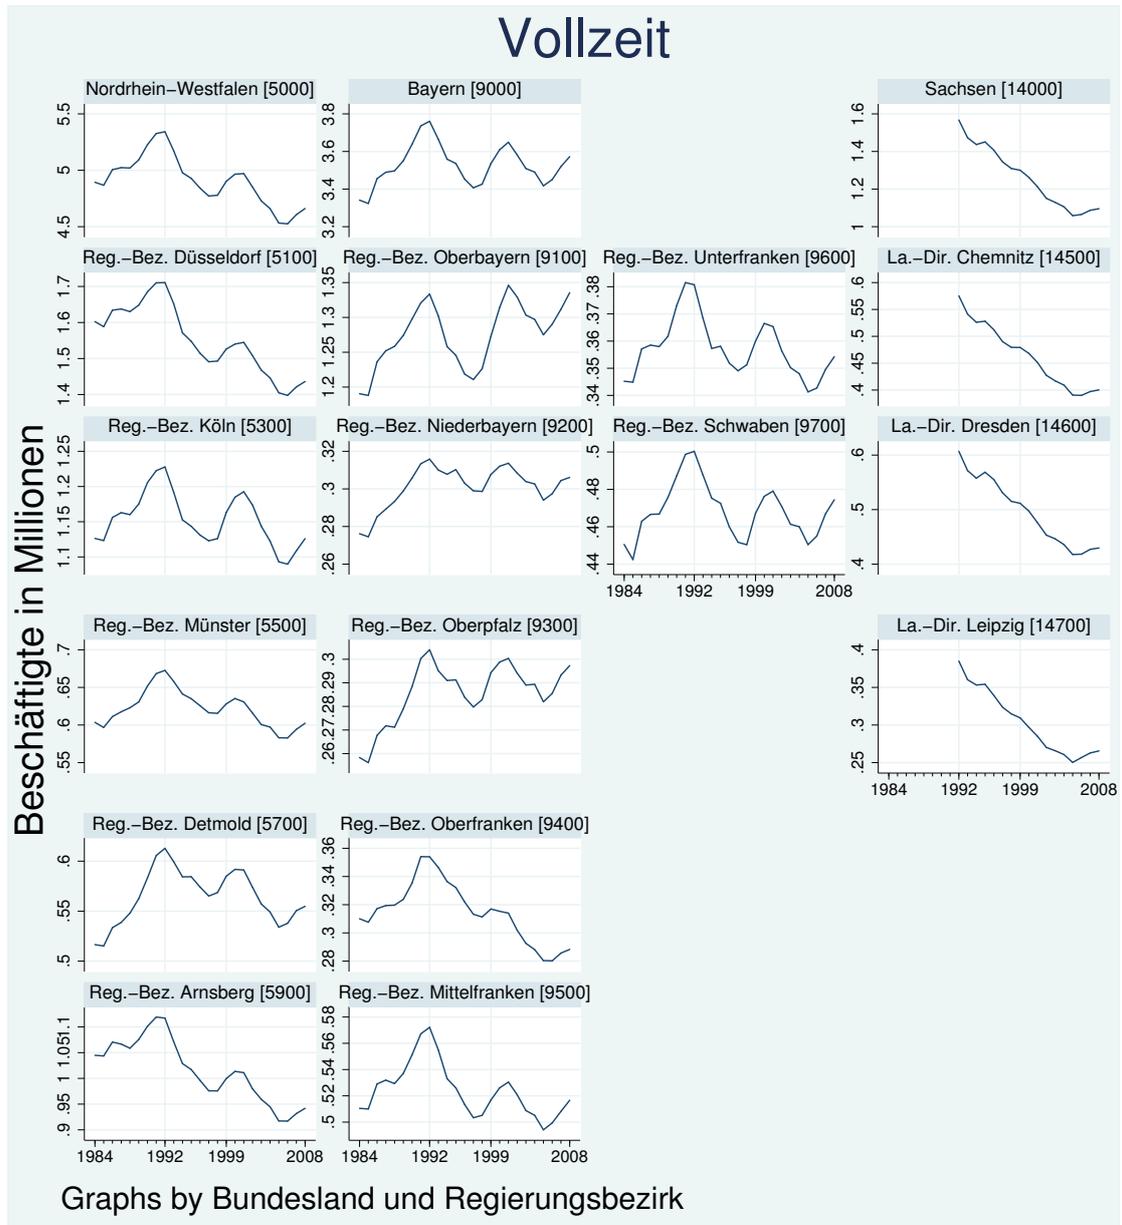


Abbildung A.16.: Anzahl Beschäftigter nach Bundesländern und Regierungsbezirken, B
 Vollzeit (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aow-land-regbez.do

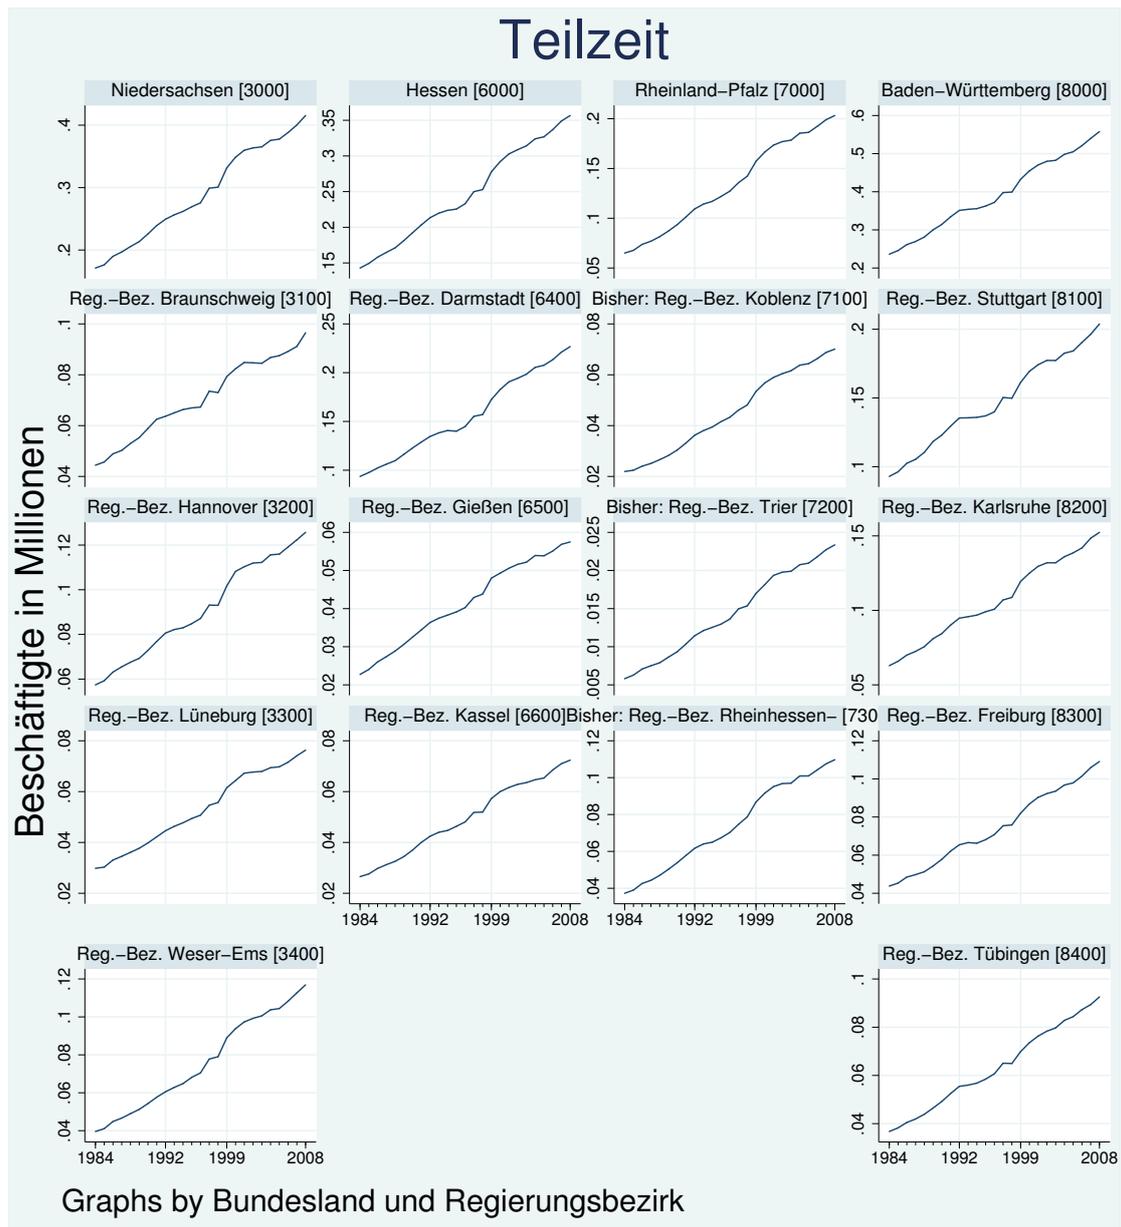


Abbildung A.17.: Anzahl Beschäftigter nach Bundesländern und Regierungsbezirken, A
 Teilzeit (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aow-land-regbez.do`

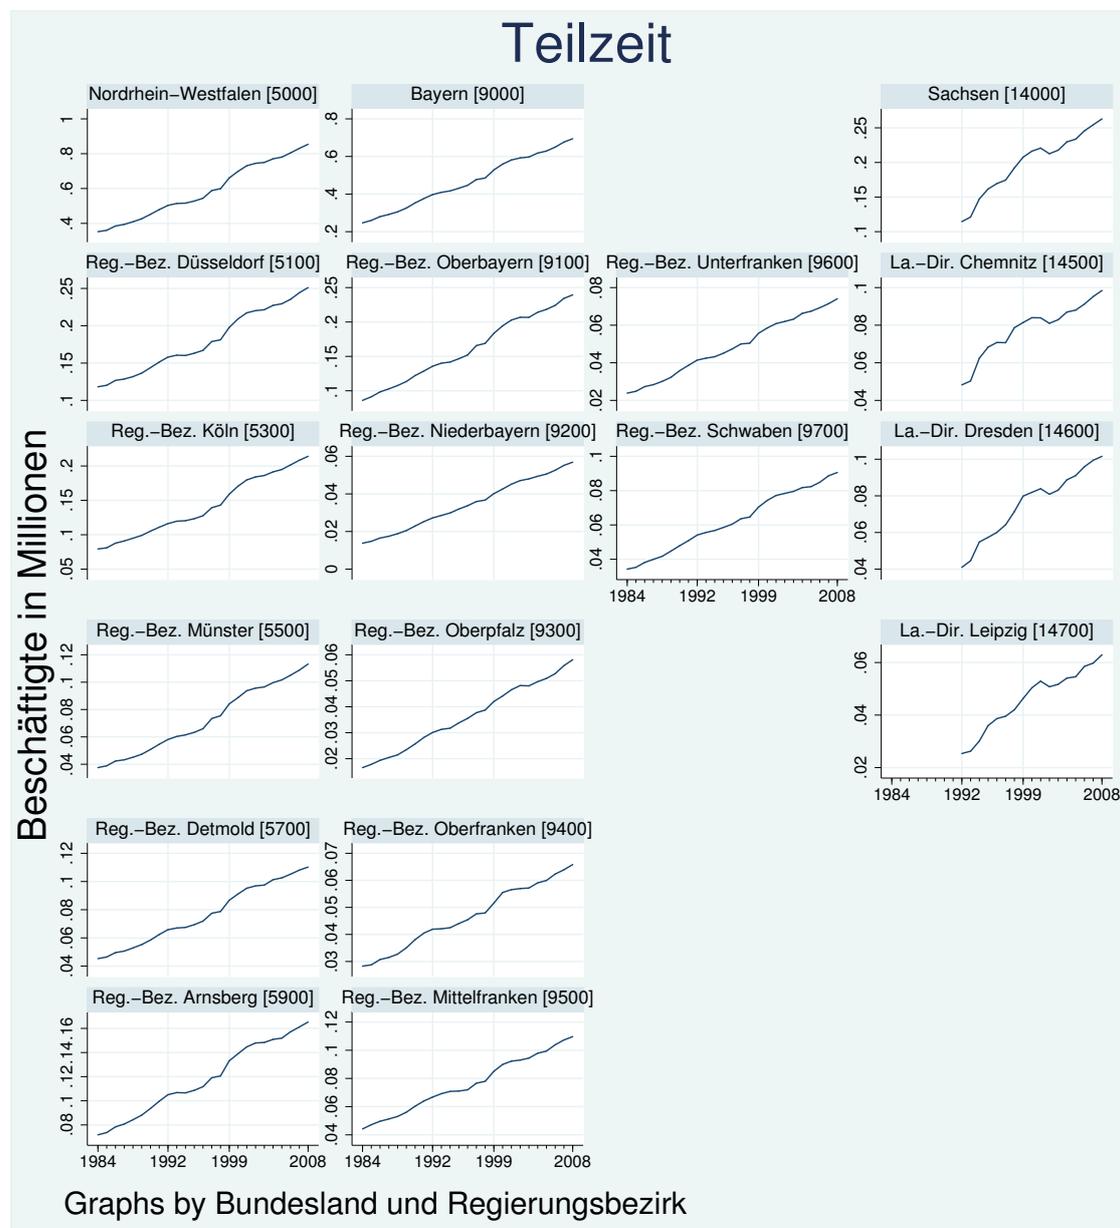


Abbildung A.18.: Anzahl Beschäftigter nach Bundesländern und Regierungsbezirken, B
 Teilzeit (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aow-land-regbez.do`

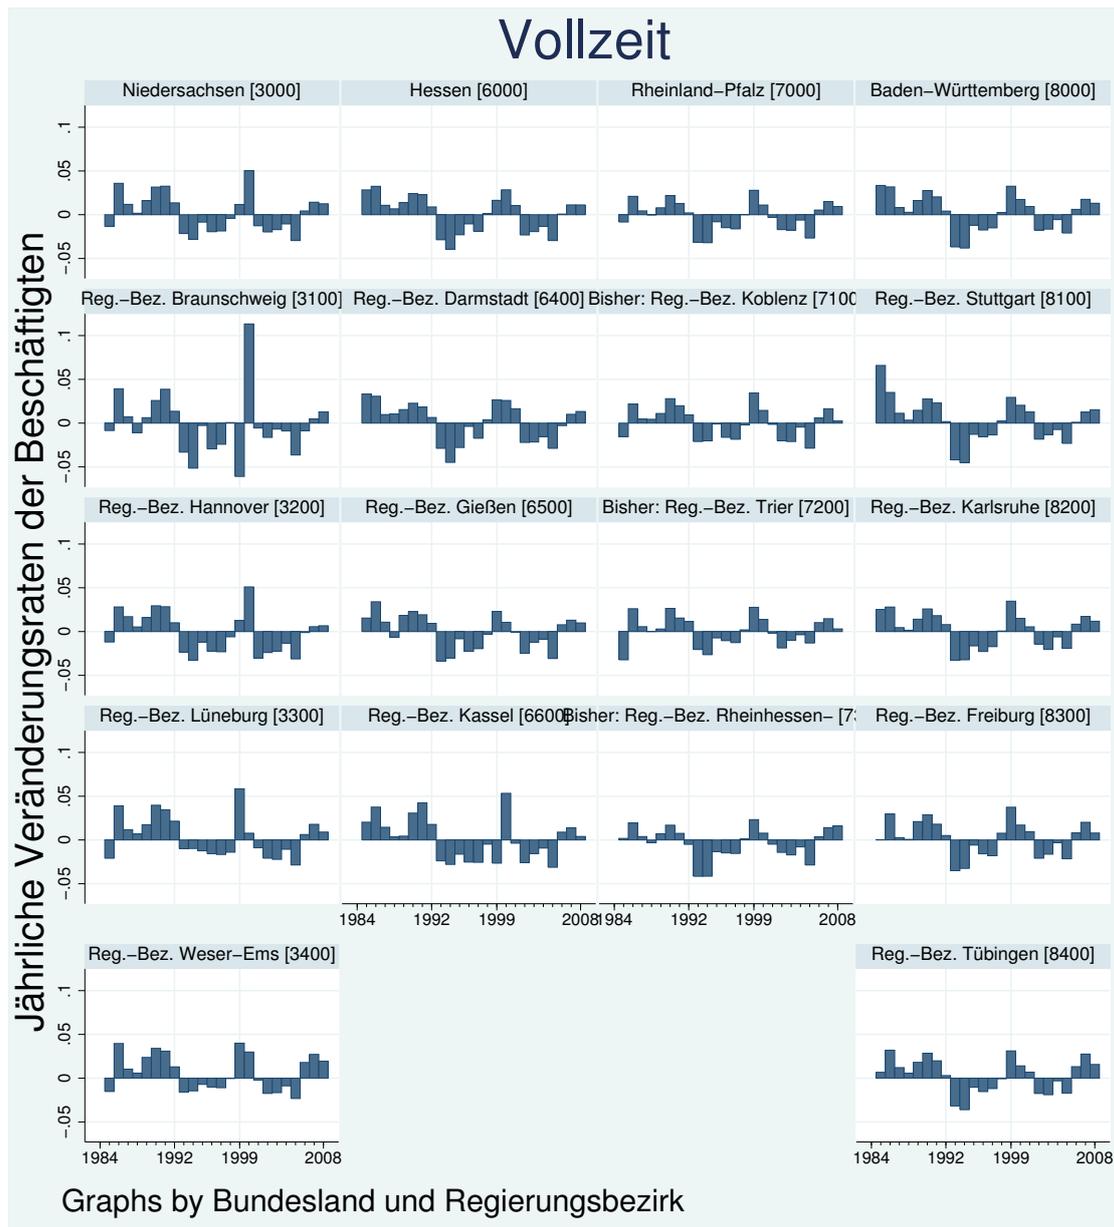


Abbildung A.19.: Jährliche Veränderung der Beschäftigten nach Bundesländern und Regierungsbezirken, A
 Vollzeit (in Prozent)
 Grafik erstellt mit grafik/plot-change-ZR-land-regbez.do

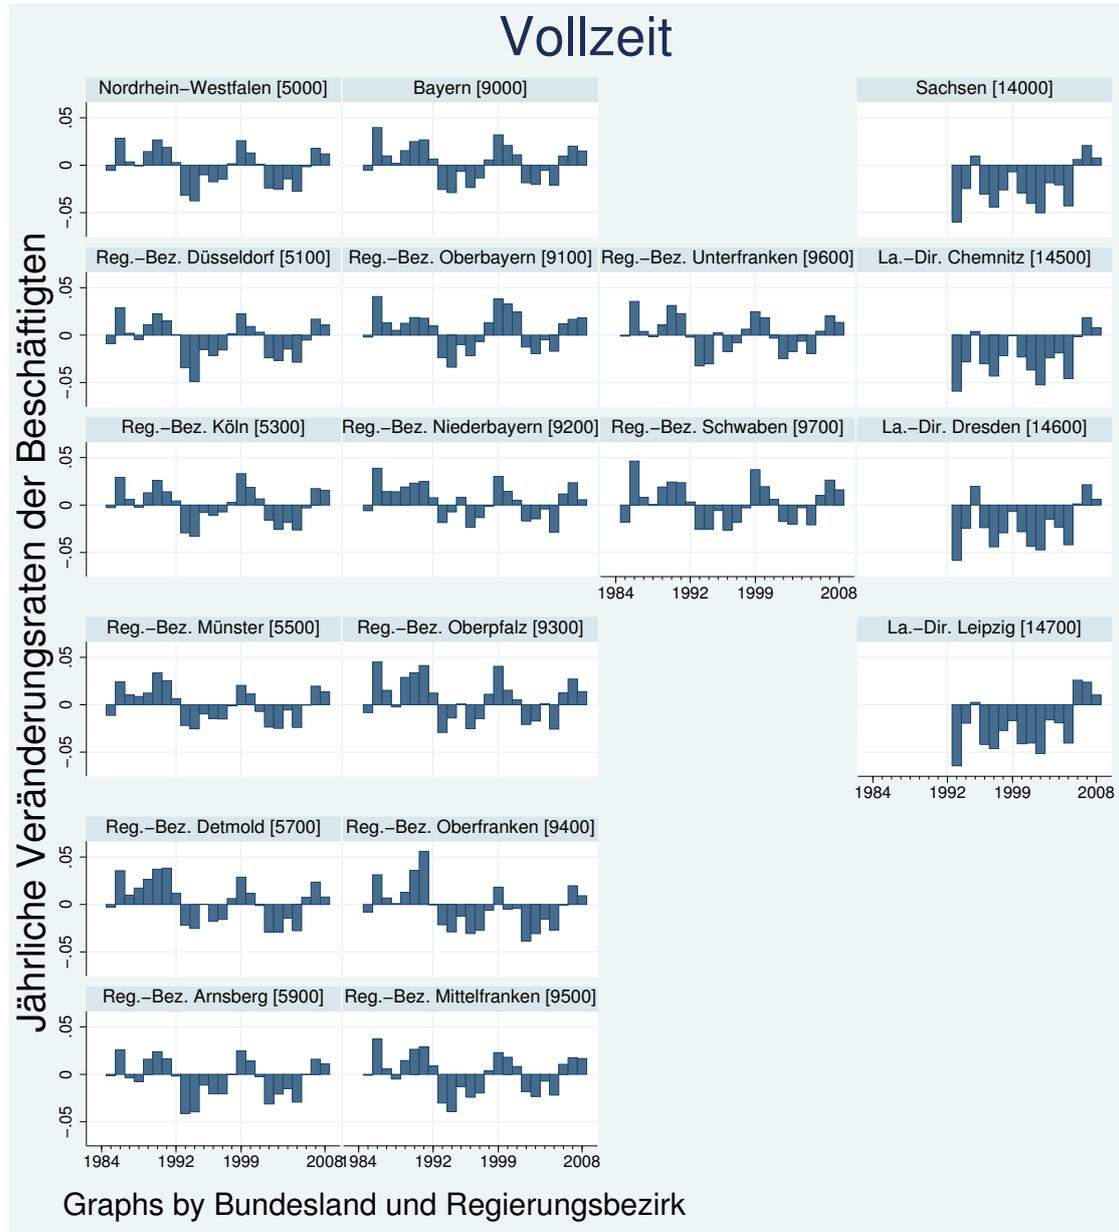


Abbildung A.20.: Jährliche Veränderung der Beschäftigten nach Bundesländern und Regierungsbezirken, B
 Vollzeit (in Prozent)
 Grafik erstellt mit `grafik/plot-change-ZR-land-regbez.do`



Abbildung A.21.: Jährliche Veränderung der Beschäftigten nach Bundesländern und Regierungsbezirken, A
 Vollzeit (in Prozent)
 Grafik erstellt mit `plot-change-ZR-land-regbez.do`

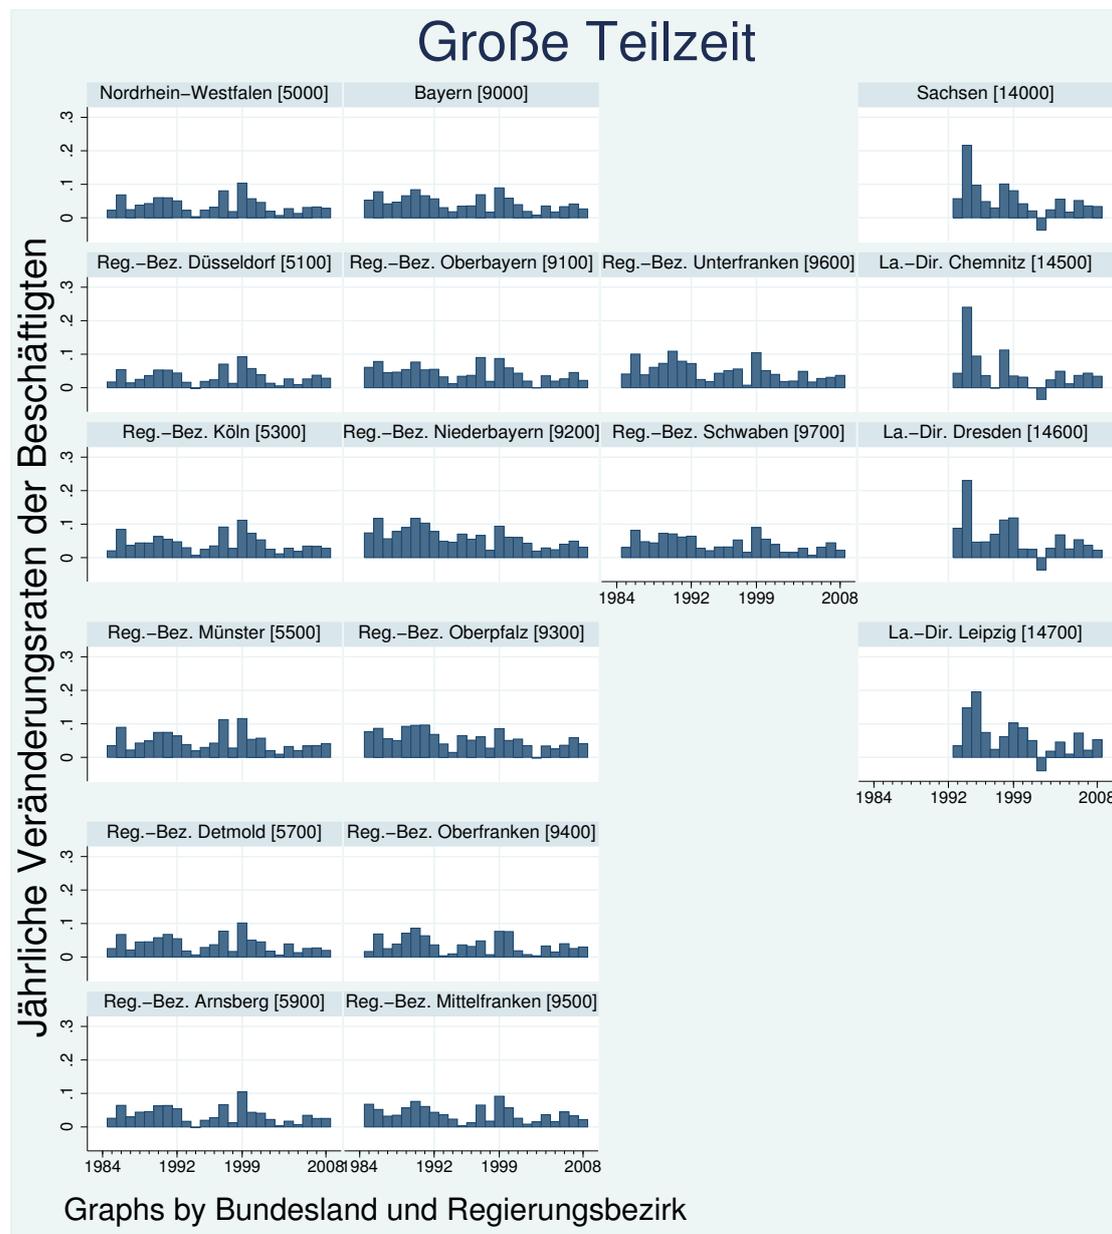


Abbildung A.22.: Jährliche Veränderung der Beschäftigten nach Bundesländern und Regierungsbezirken, B
 Teilzeit (in Prozent)
 Grafik erstellt mit `plot-change-ZR-land-regbez.do`

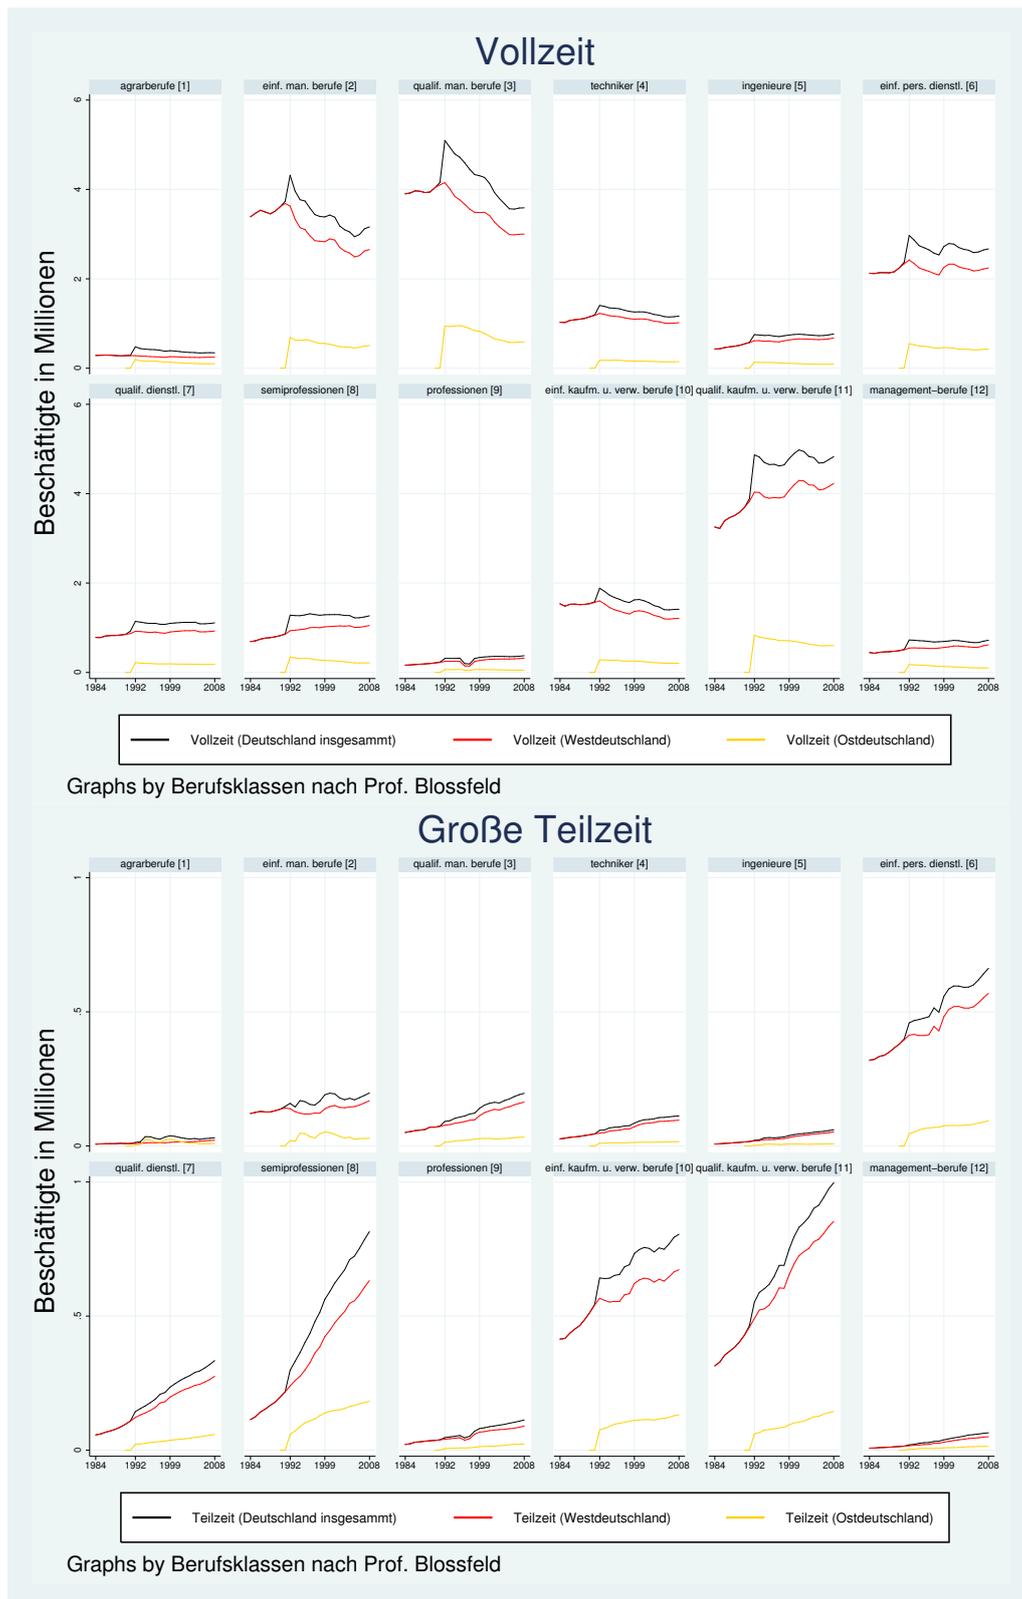


Abbildung A.23.: Anzahl Beschäftigter in West, Ost und Deutschland insgesamt – differenziert nach Blossfeld-Berufsklassen (einheitliche Skala) – Grafik erstellt mit plot-ZR-aow-bb.do

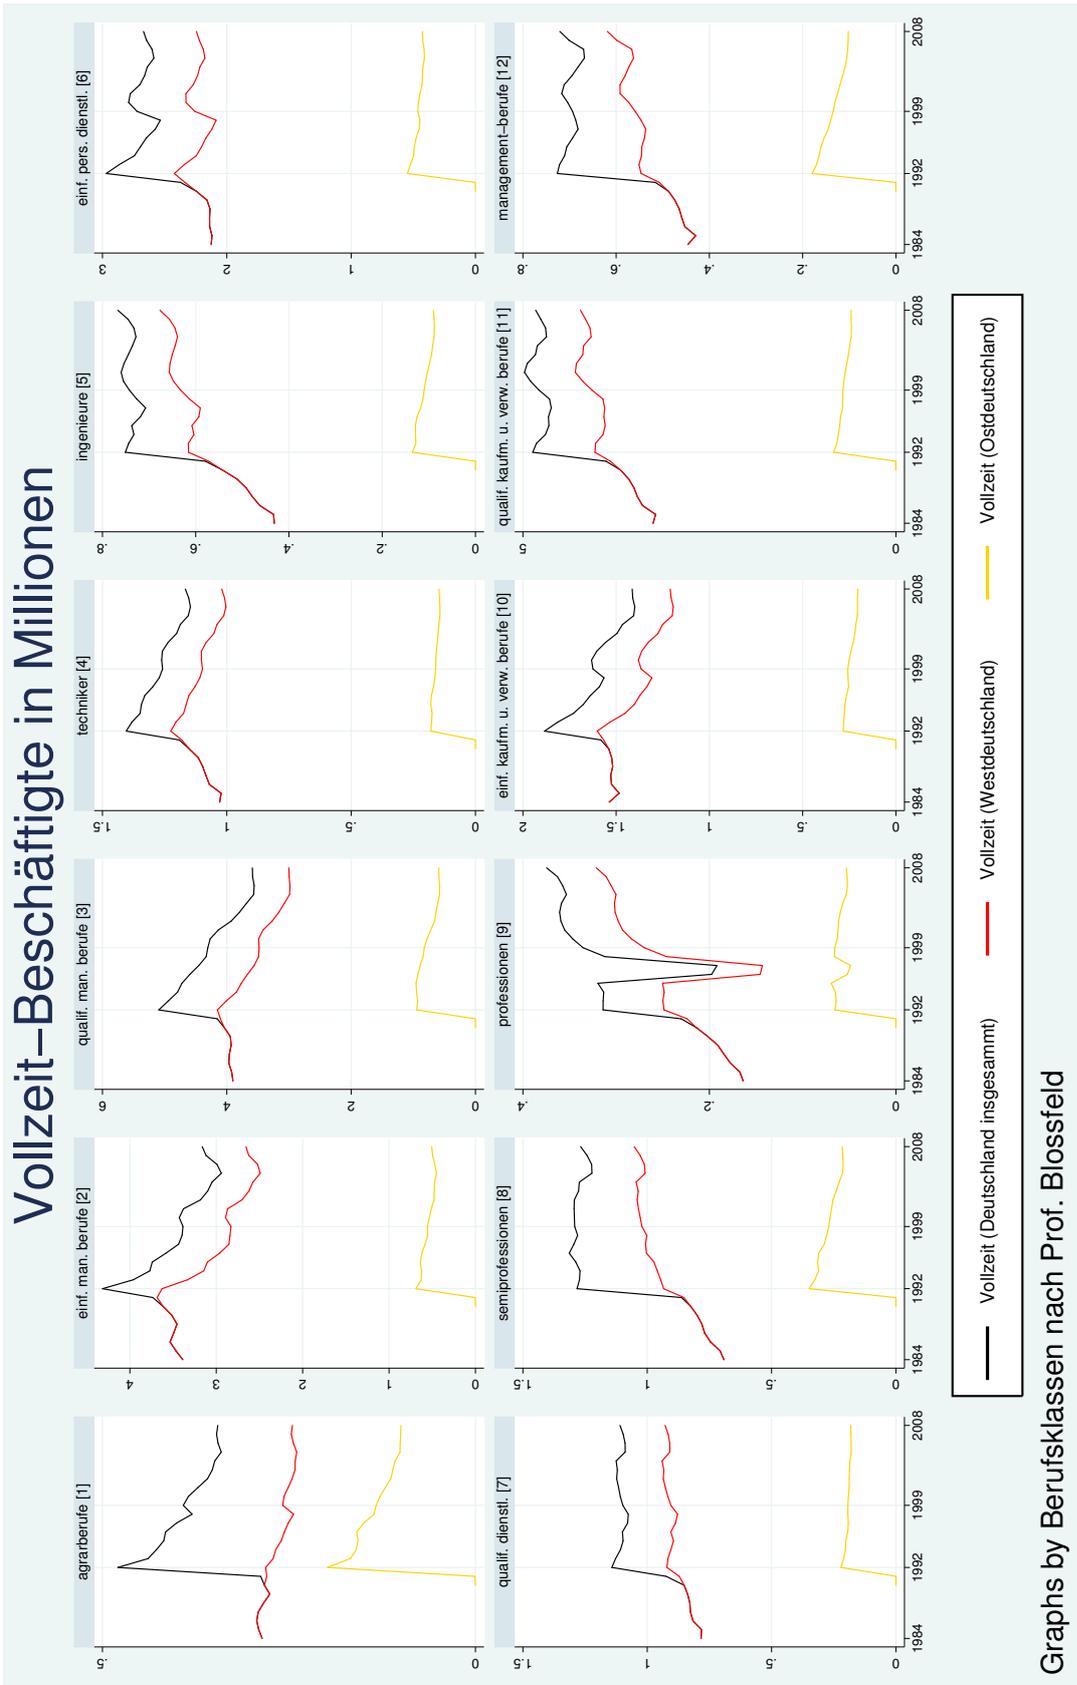


Abbildung A.24.: Anzahl Beschäftigter in West, Ost und Deutschland insgesamt – differenziert nach Blossfeld-Berufsklassen
 Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit `plot-ZR-aooow-bb.do`

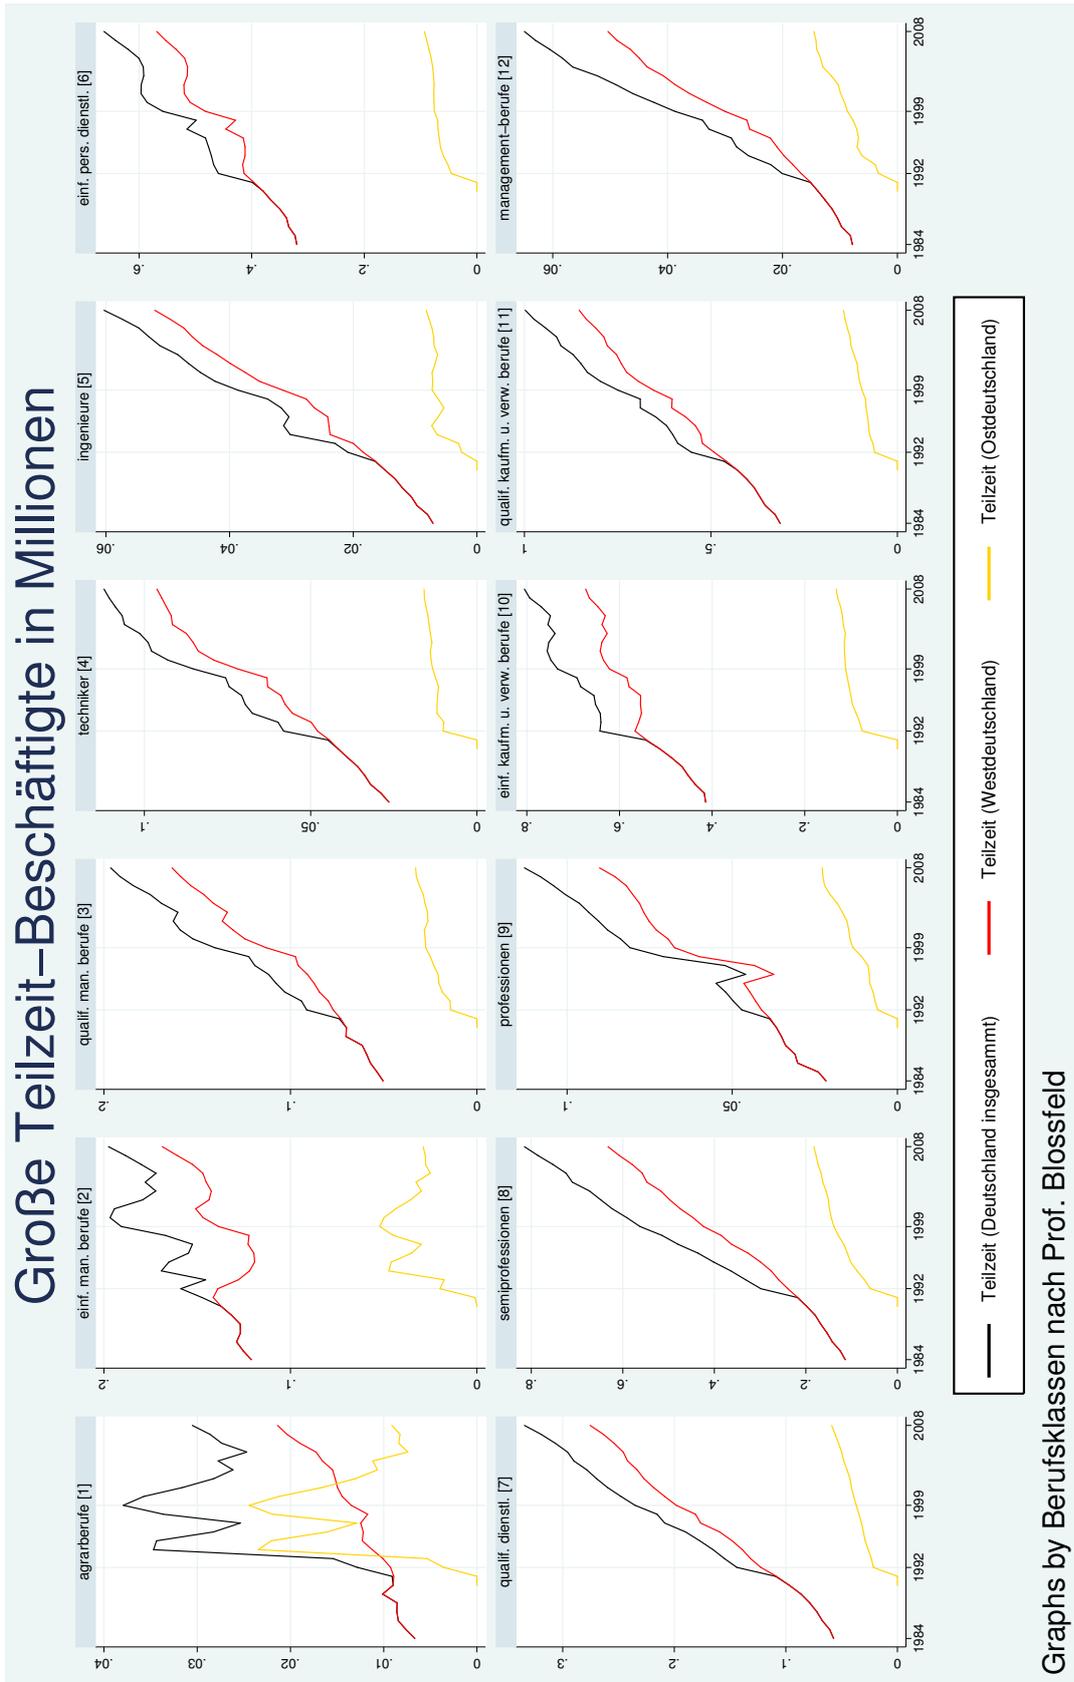
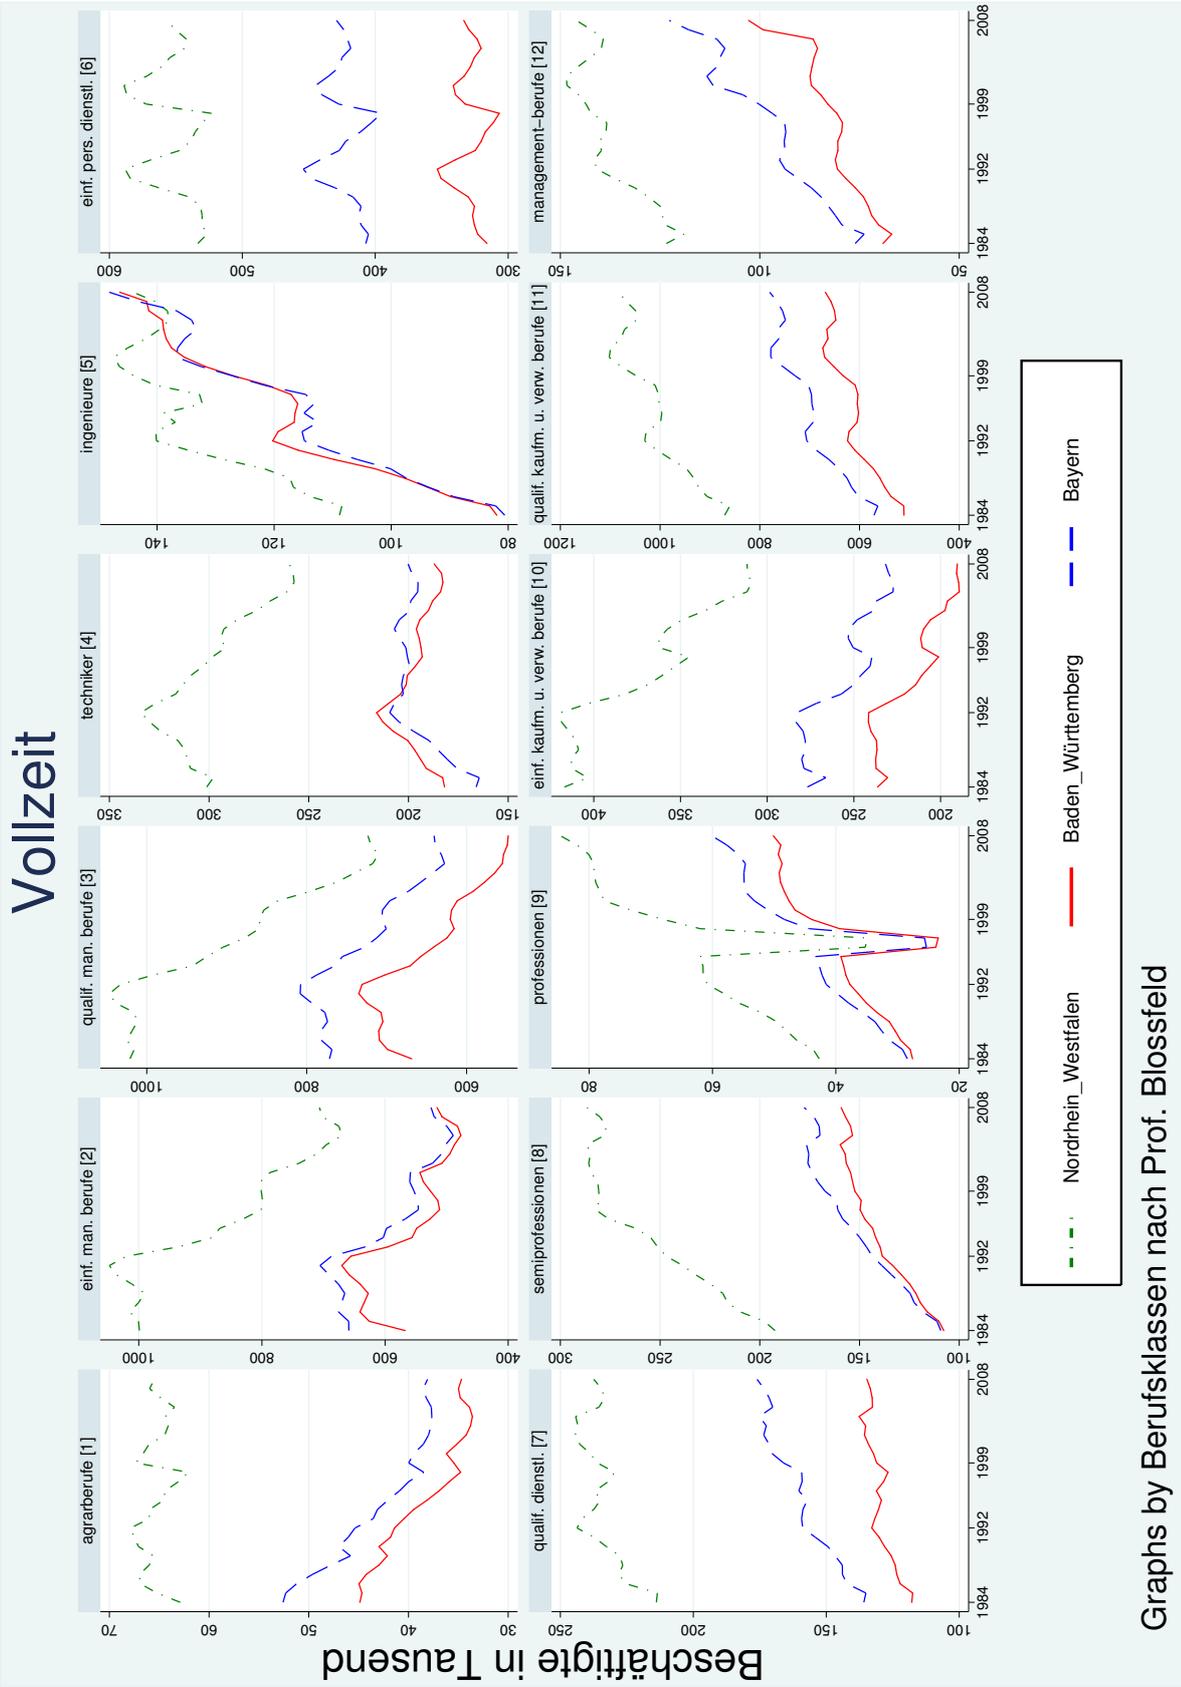
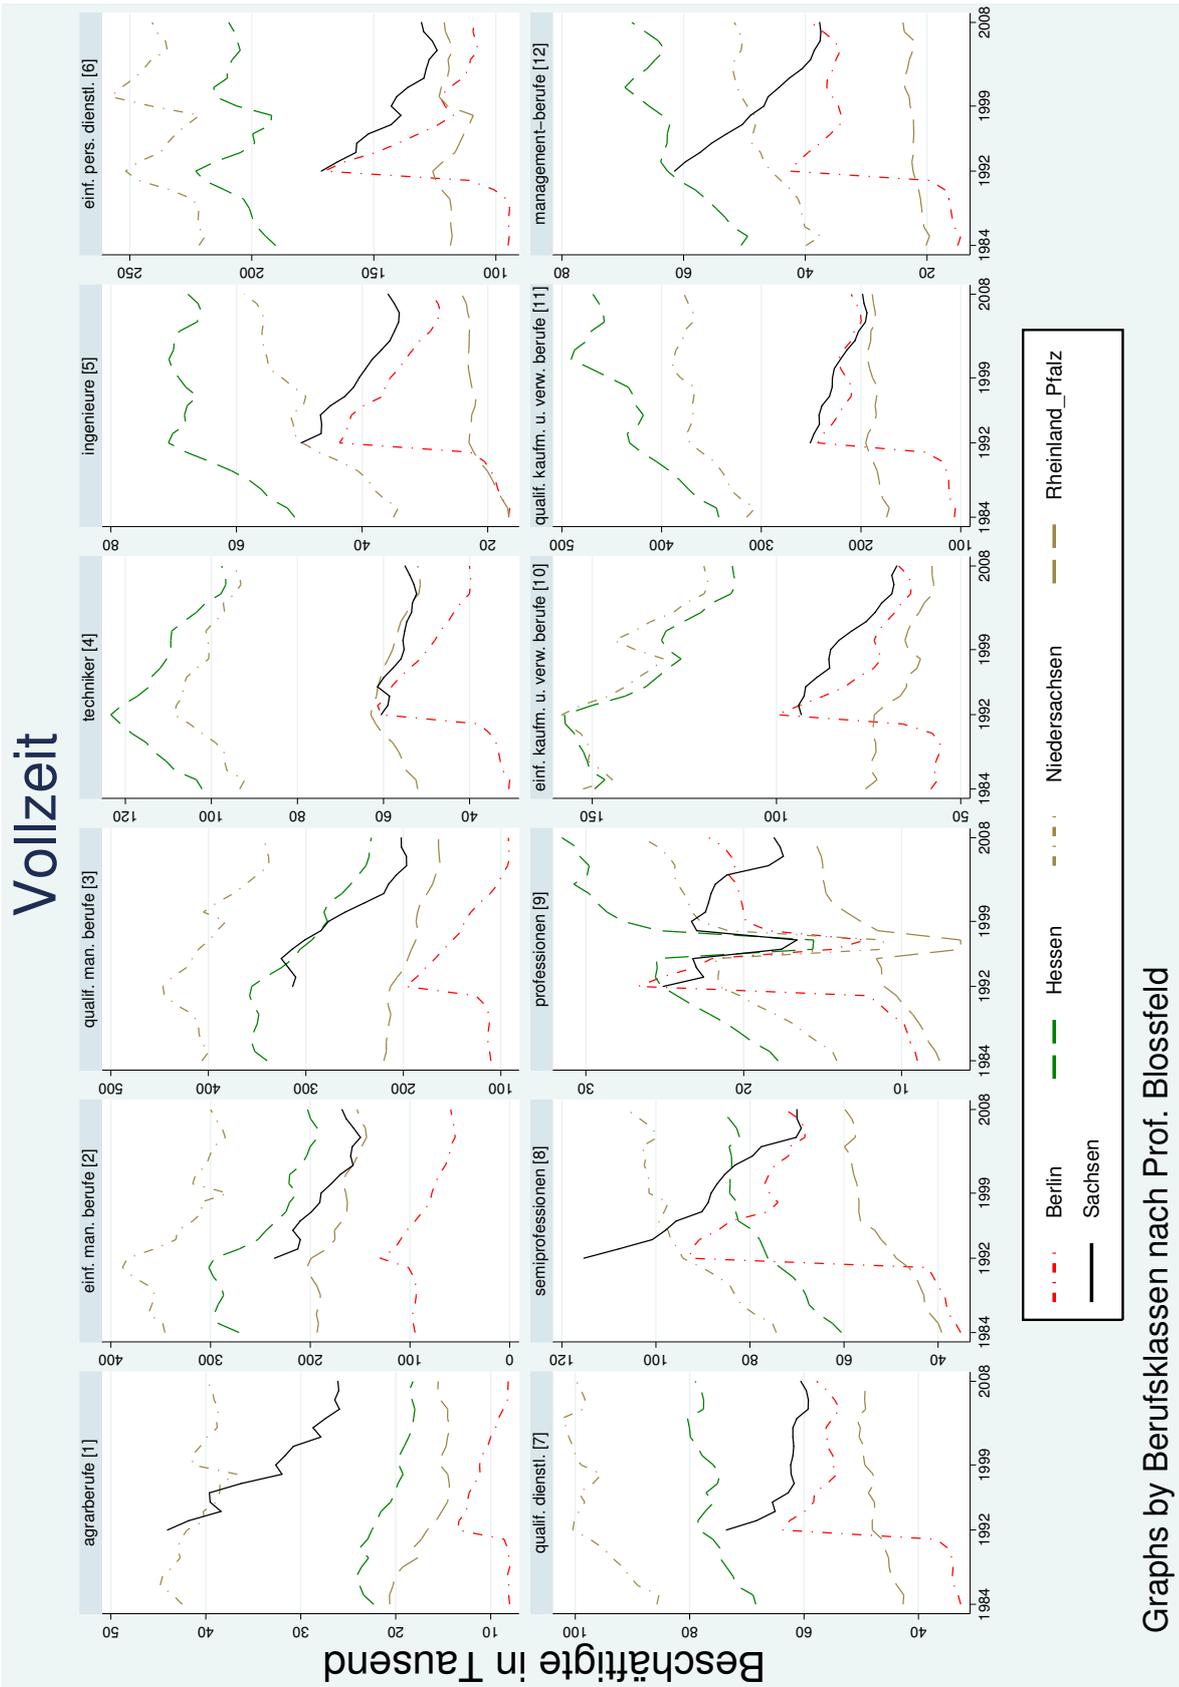


Abbildung A.25.: Anzahl Beschäftigter in West, Ost und Deutschland insgesamt – differenziert nach Blossfeld-Berufsklassen Teilzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoo-w-bb . do



Graphs by Berufsklassen nach Prof. Blossfeld

Abbildung A.26.: Anzahl Beschäftigter in den bevölkerungsreichen Bundesländern – differenziert nach Blossfeld-Berufsklassen Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoland-bb-vz.do



Graphs by Berufsklassen nach Prof. Blossfeld

Abbildung A.27.: Anzahl Beschäftigter in den mittleren Bundesländern – differenziert nach Blossfeld-Berufsklassen
 Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoland-bb-vz.do

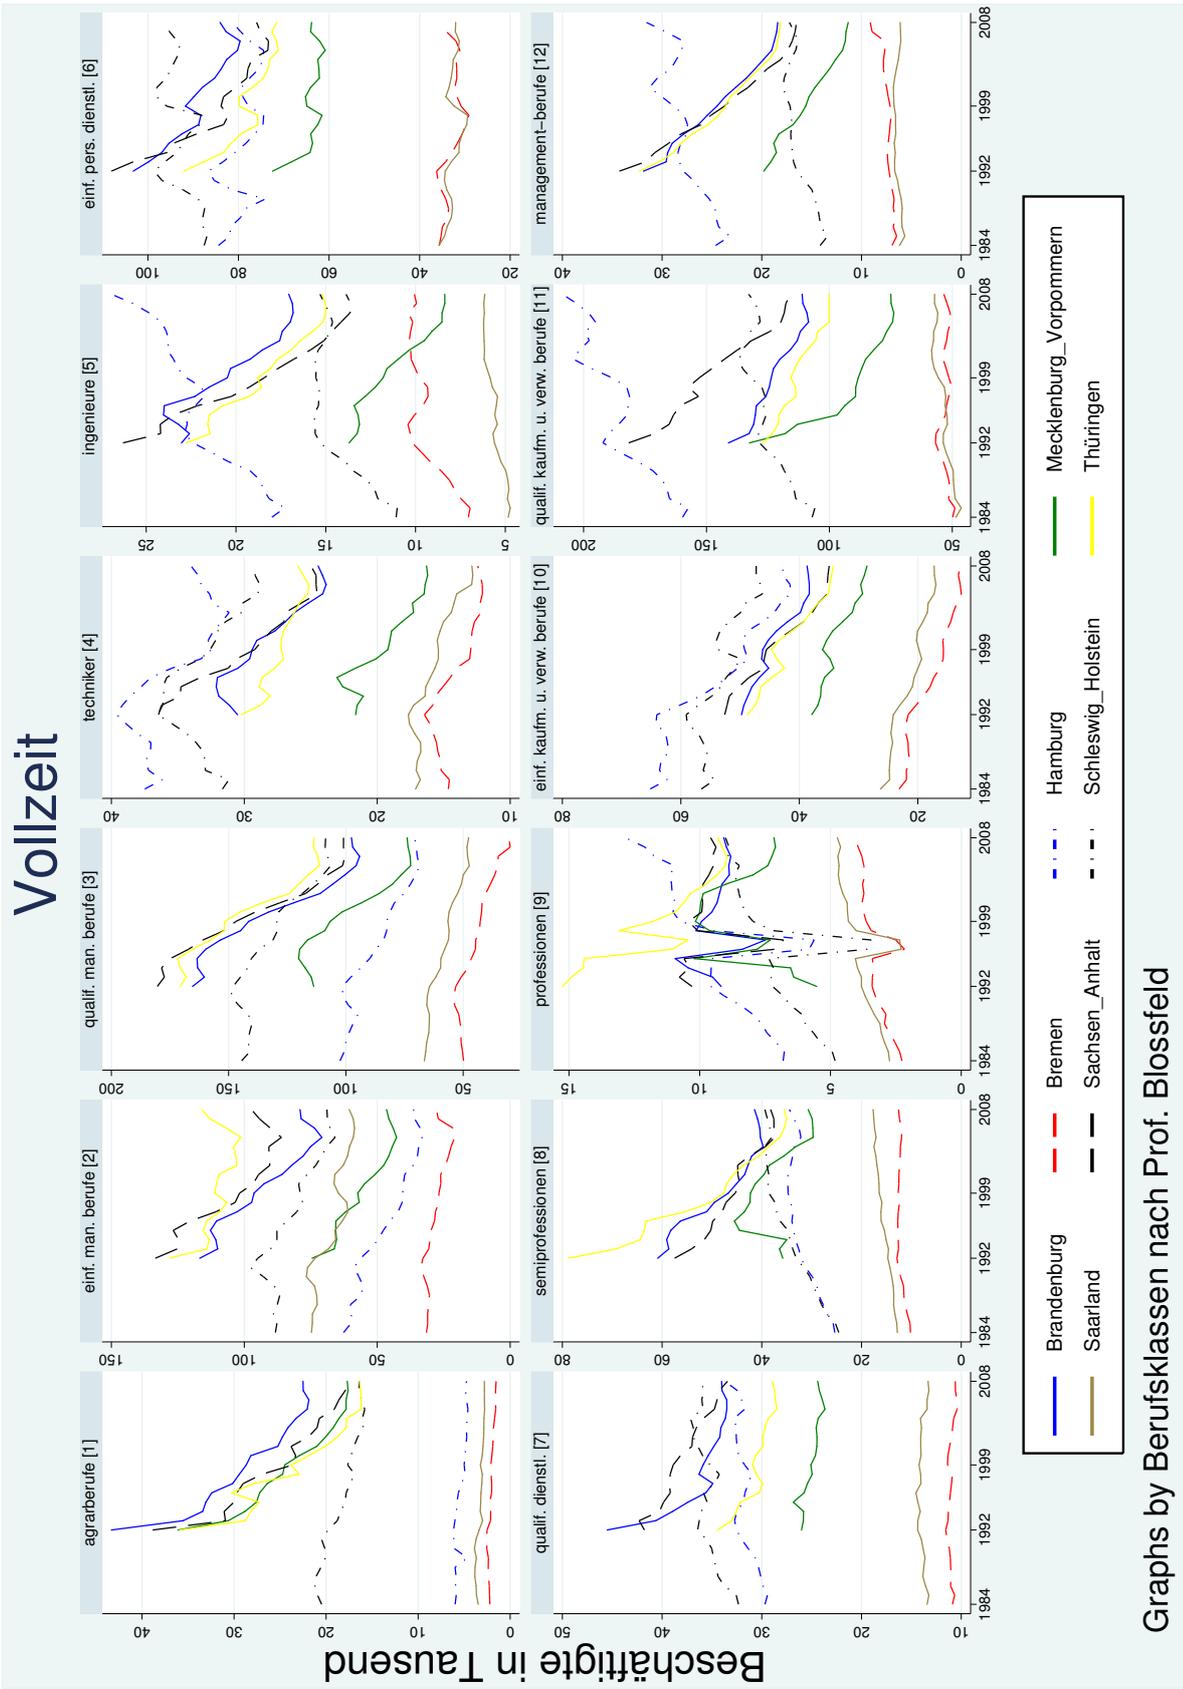


Abbildung A.28.: Anzahl Beschäftigter in den kleinen Bundesländern – differenziert nach Blossfeld-Berufsklassen Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoland-bb-vz.do

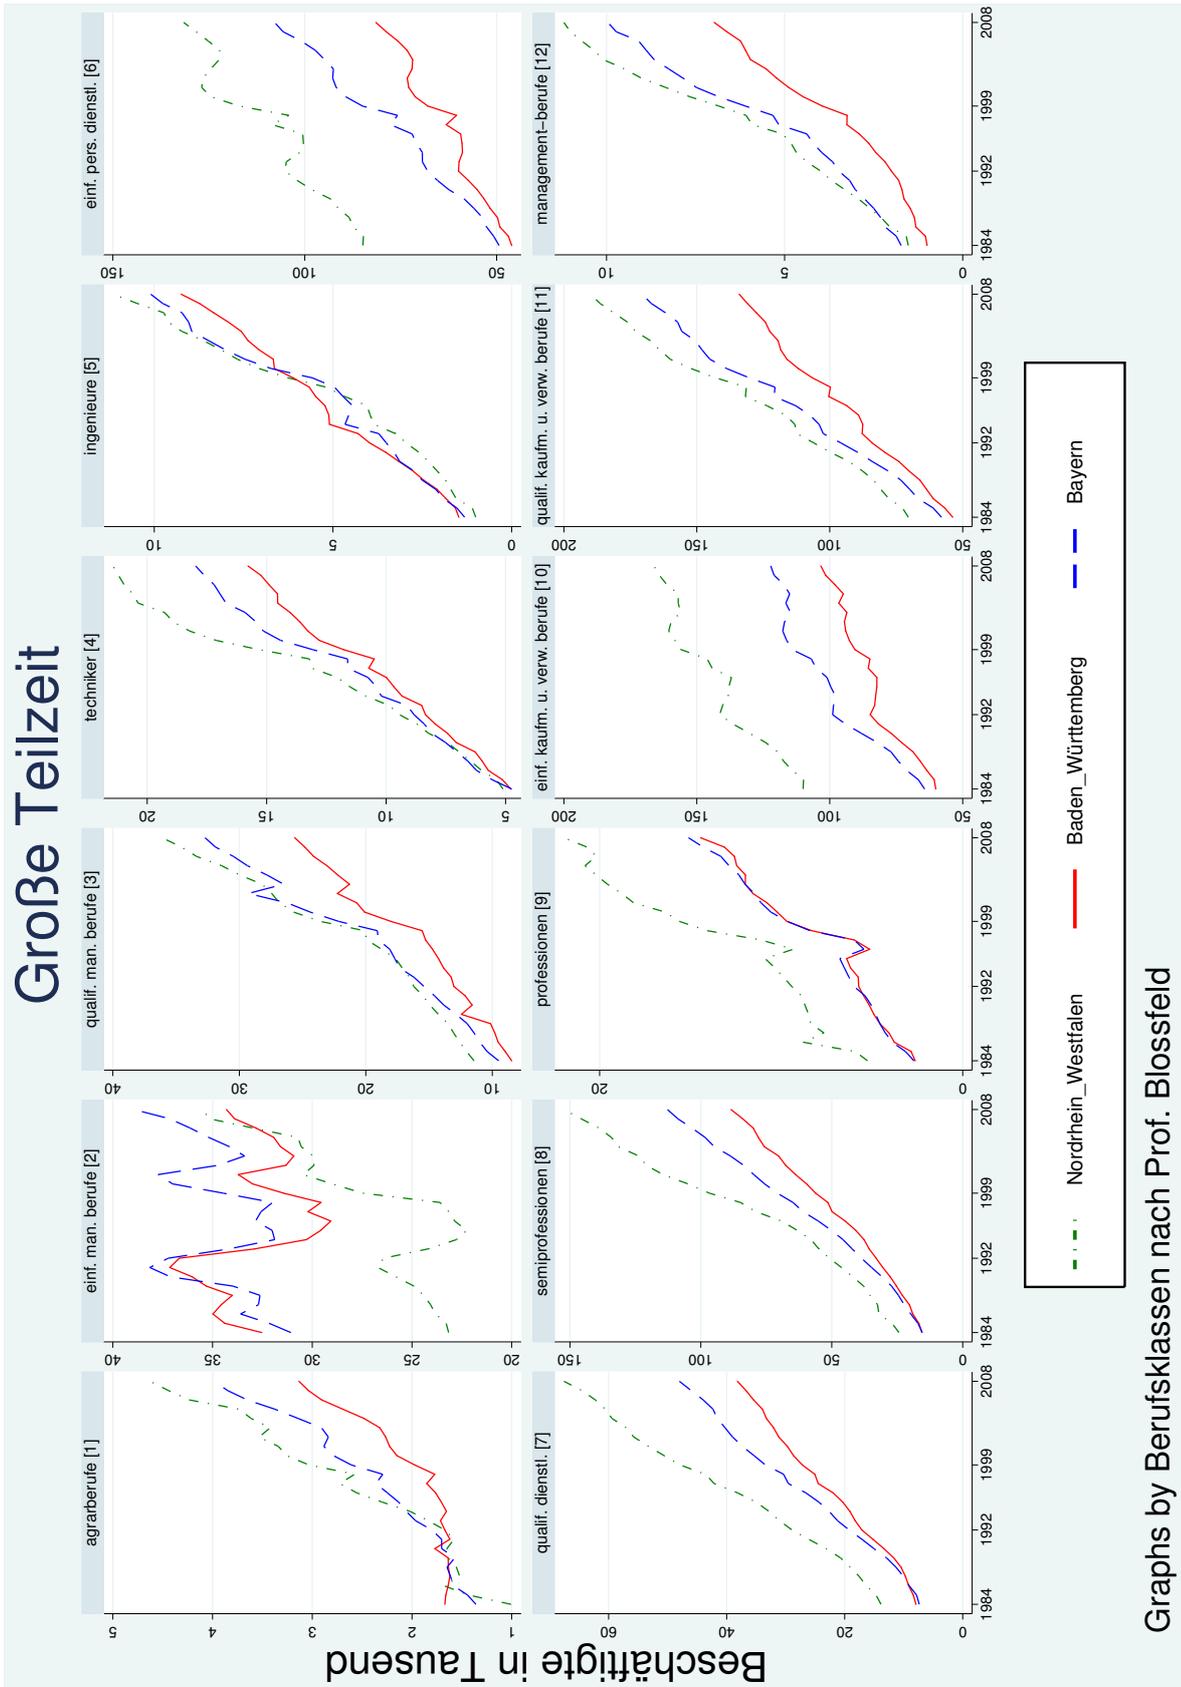
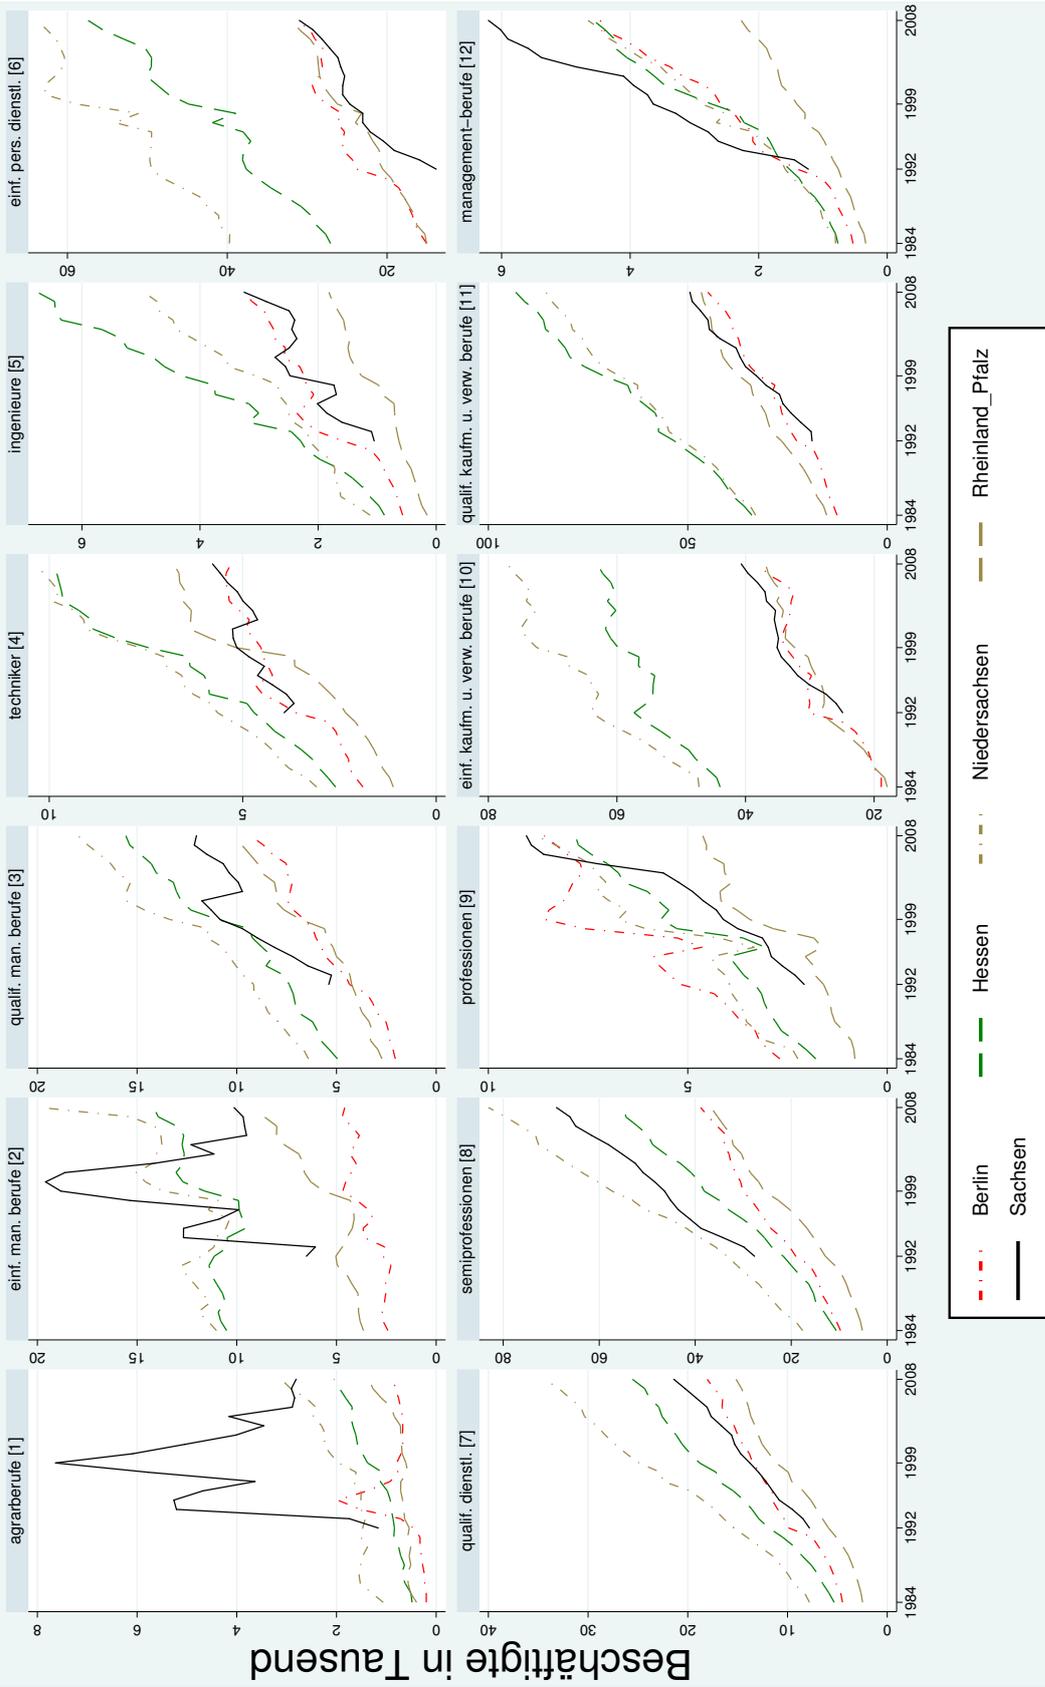


Abbildung A.29.: Anzahl Beschäftigter in den bevölkerungsreichen Bundesländern – differenziert nach Blossfeld-Berufsklassen Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoland-bb-gtz.do

Große Teilzeit



Graphs by Berufsklassen nach Prof. Blossfeld

Abbildung A.30.: Anzahl Beschäftigter in den mittleren Bundesländern – differenziert nach Blossfeld-Berufsklassen Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoland-bb-gtz.do

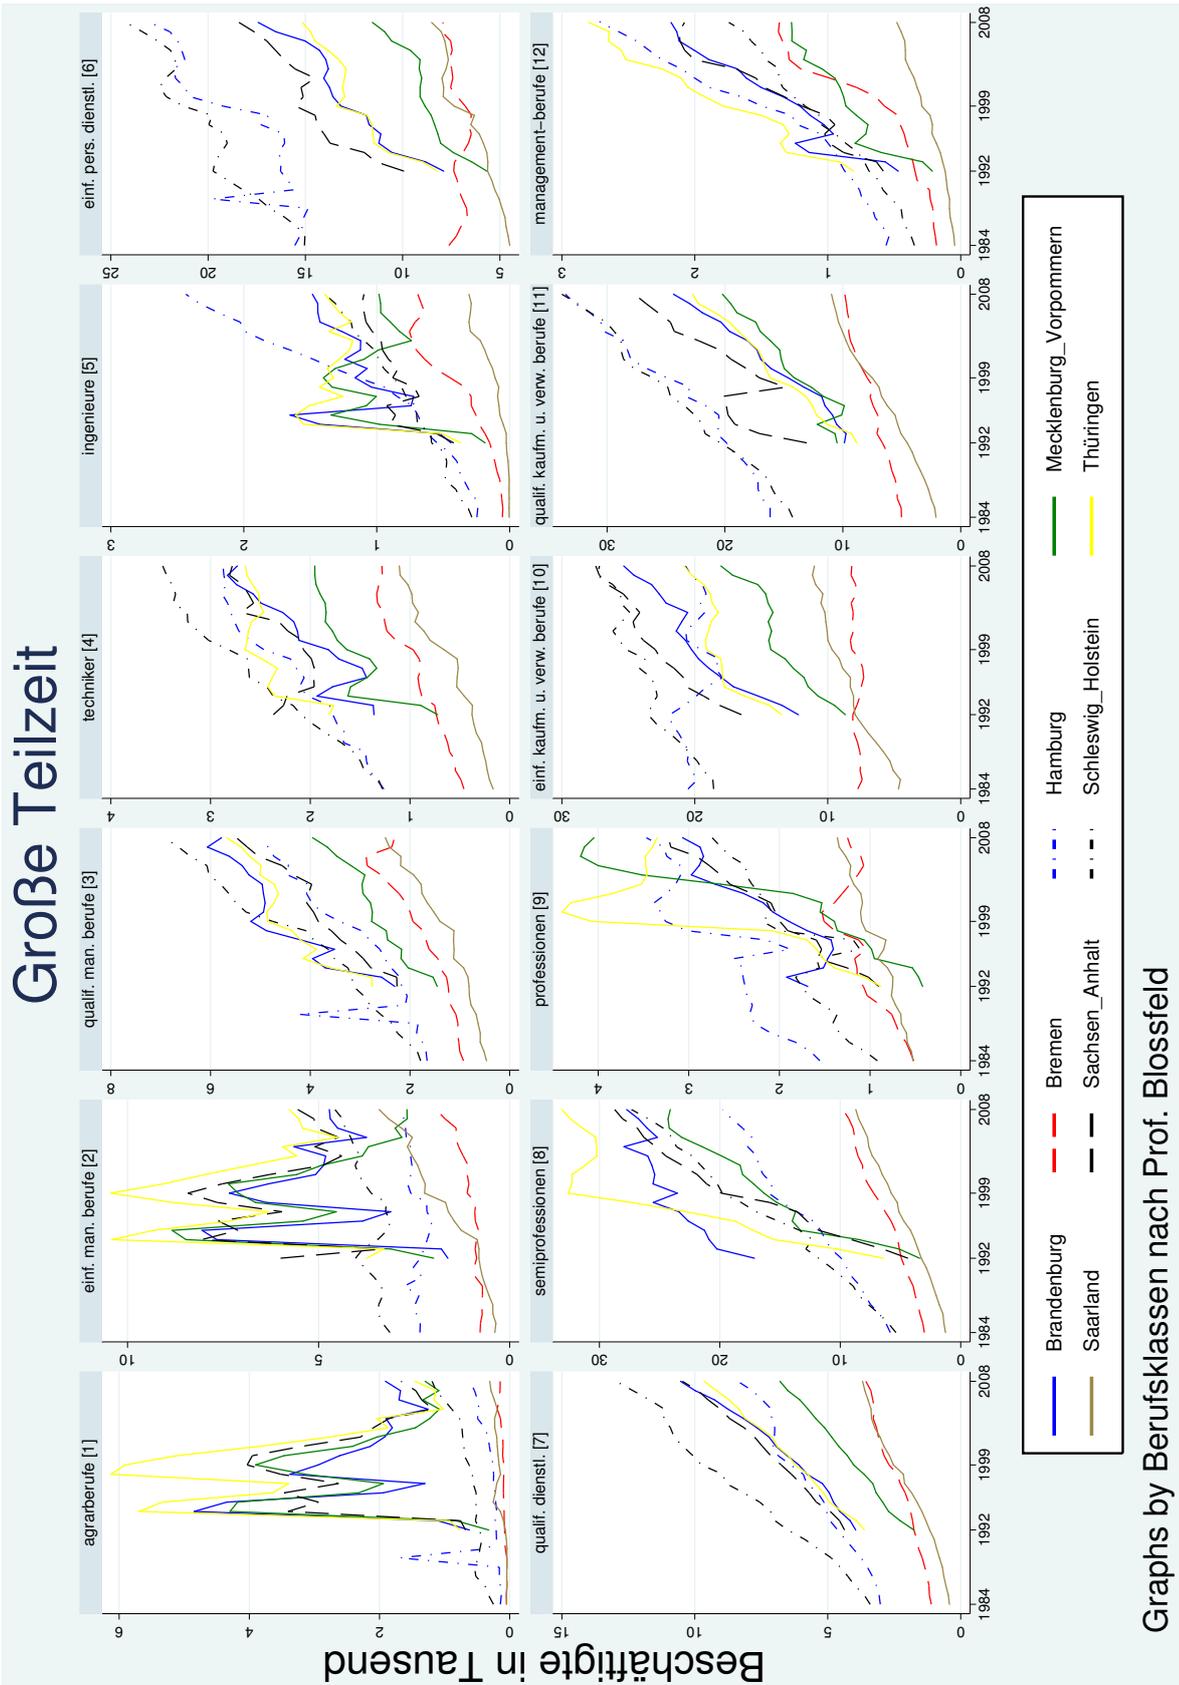


Abbildung A.31.: Anzahl Beschäftigter in den kleinen Bundesländern – differenziert nach Blossfeld-Berufsklassen Vollzeit (individuelle Skalen je Beruf) – Grafik erstellt mit plot-ZR-aoland-bb-gtz.do

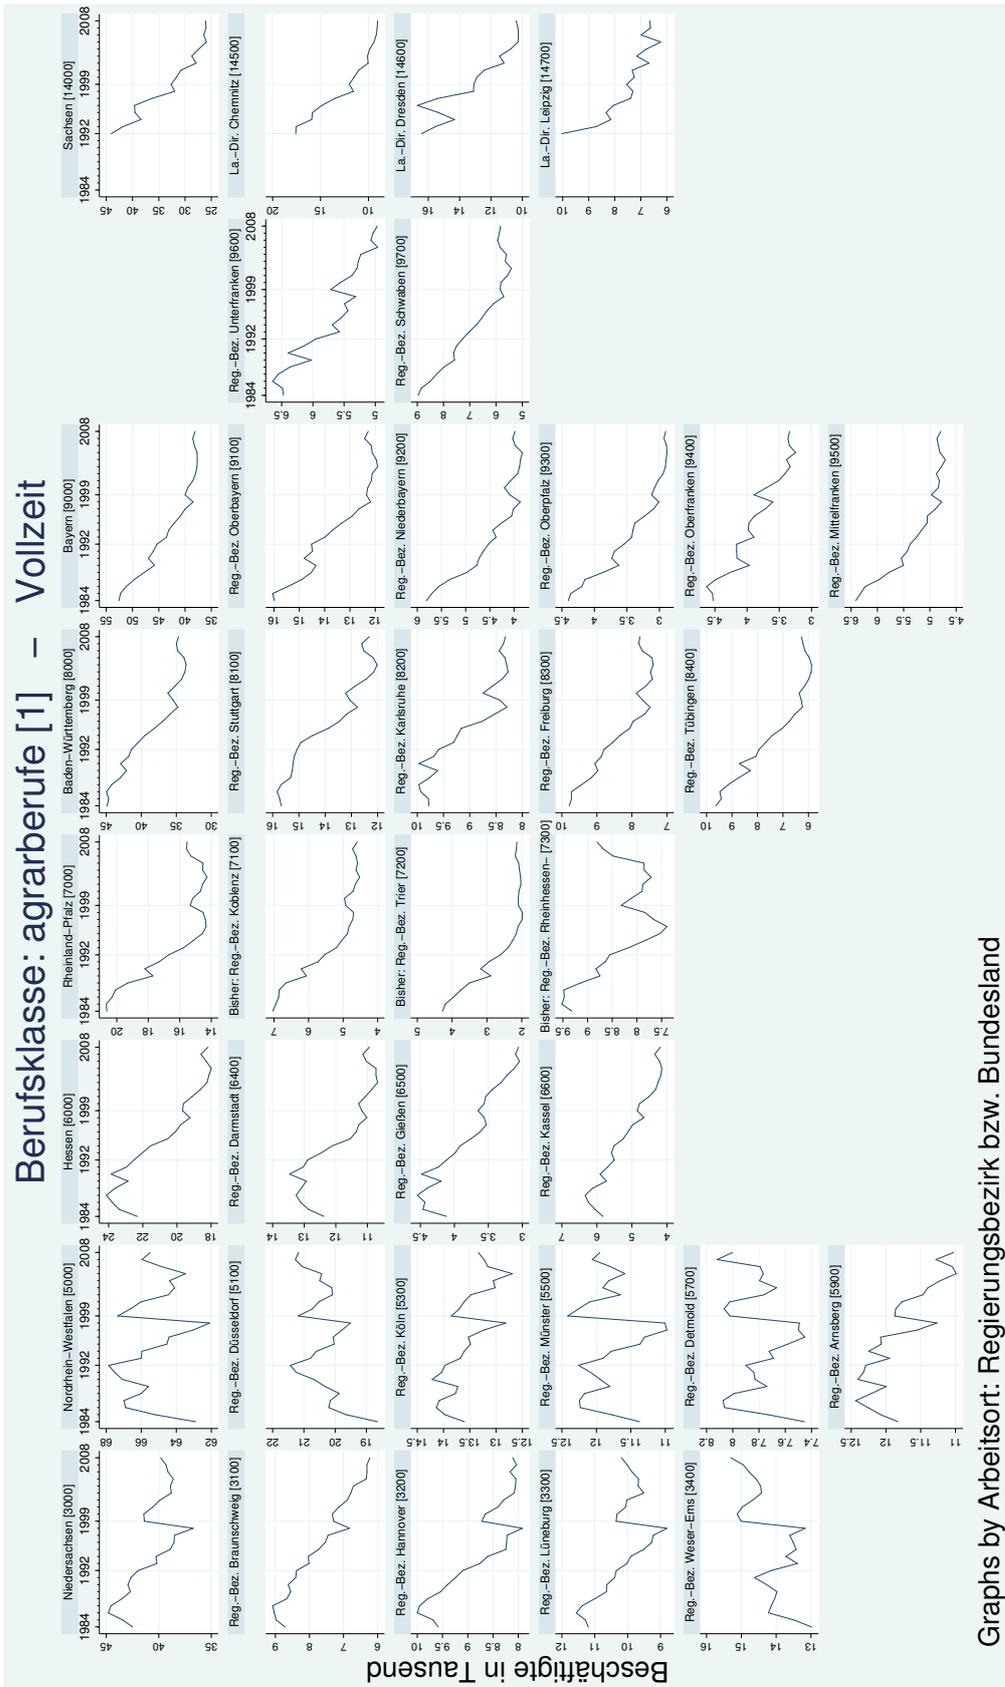


Abbildung A.32.: Anzahl Vollzeitbeschäftigte: Agrarberufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoLand-regbez-bb-vz.do`

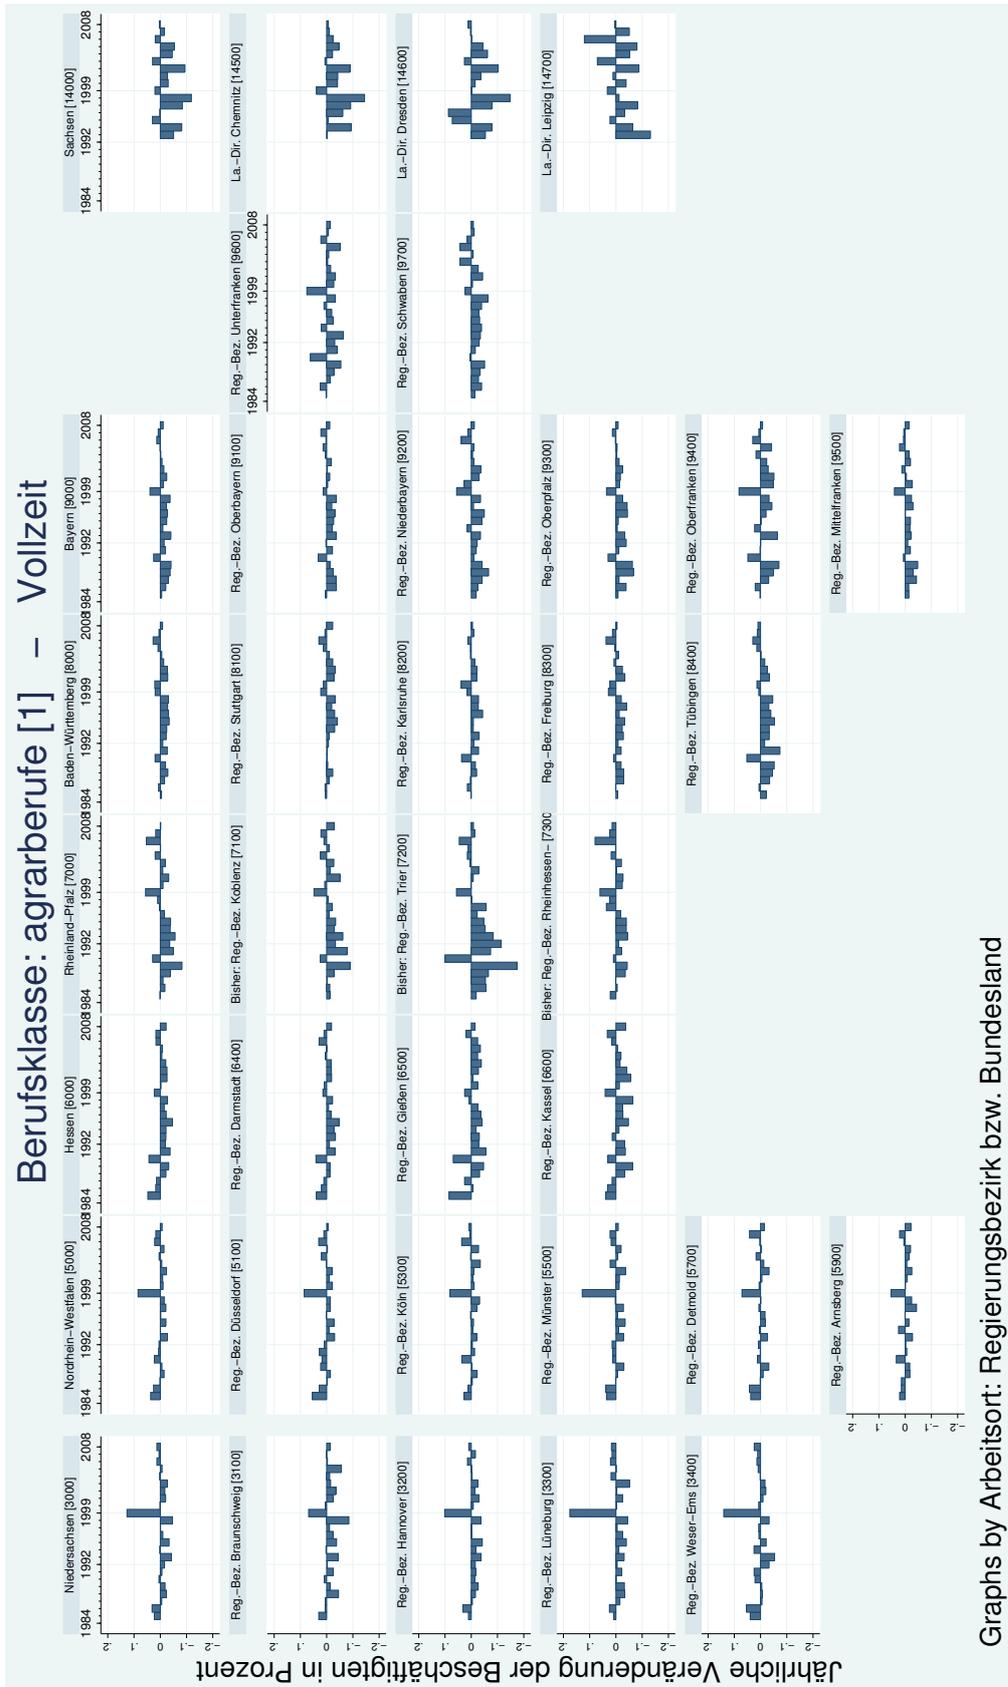
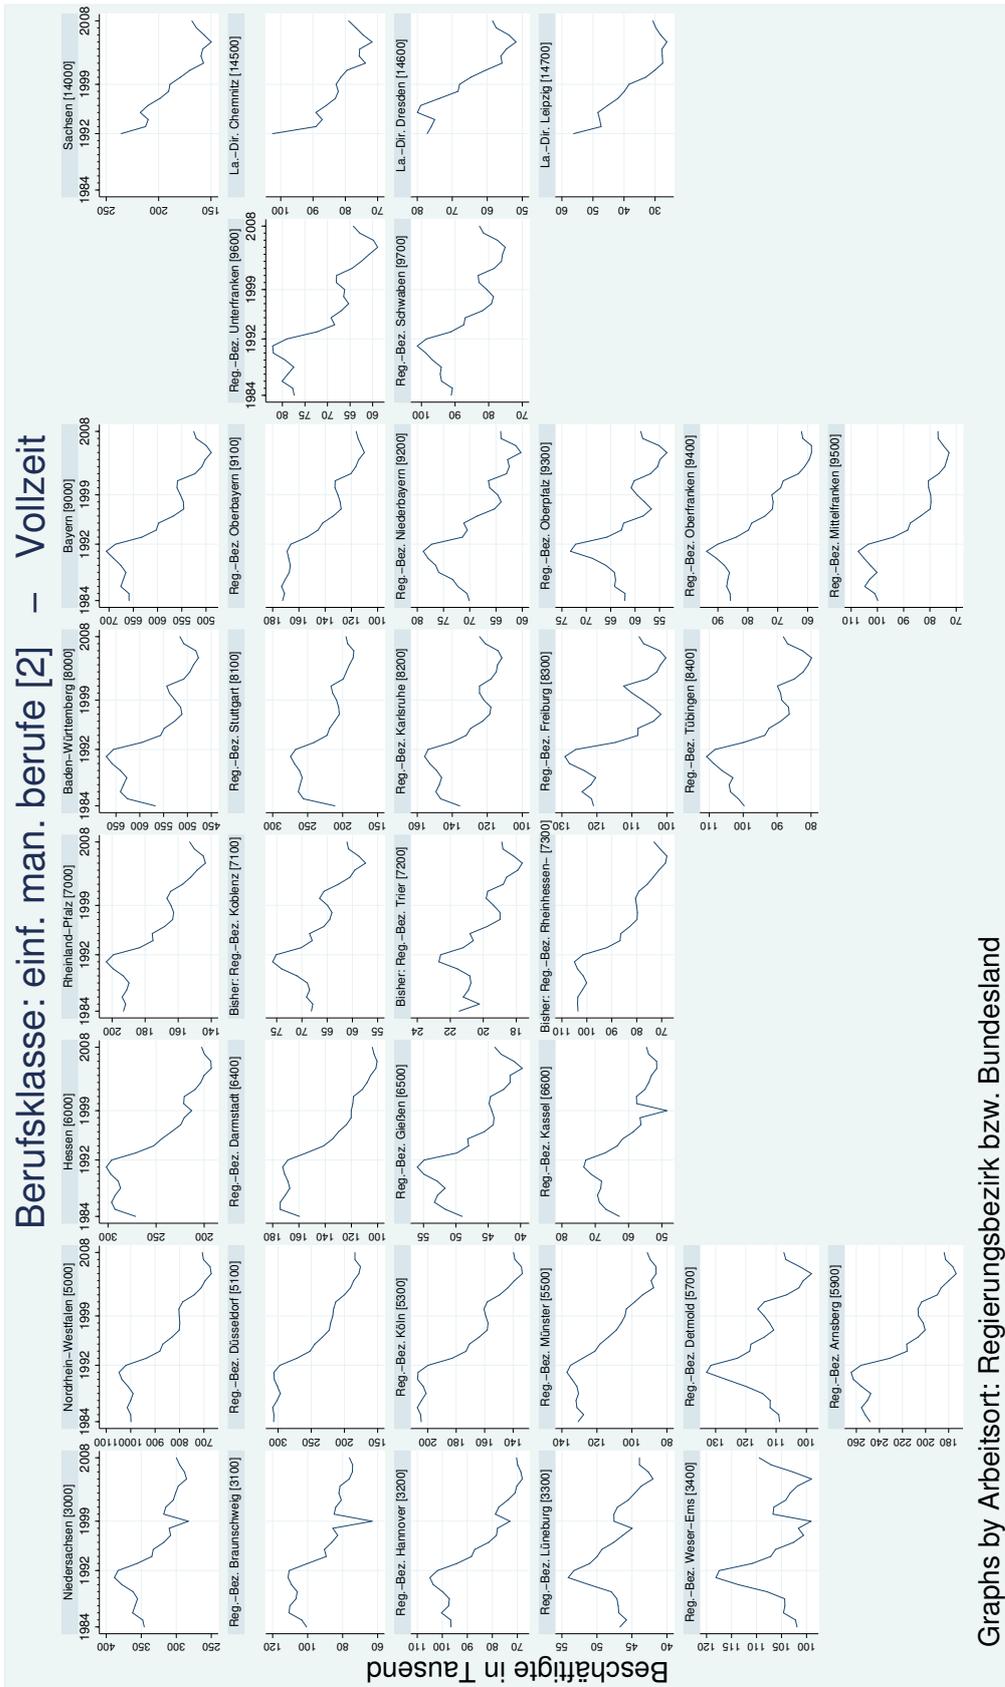


Abbildung A.33.: Jährliche Veränderung der Beschäftigung – Vollzeit: Agrarberufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.34.: Anzahl Vollzeitbeschäftigte: Einfache manuelle Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-vz.do

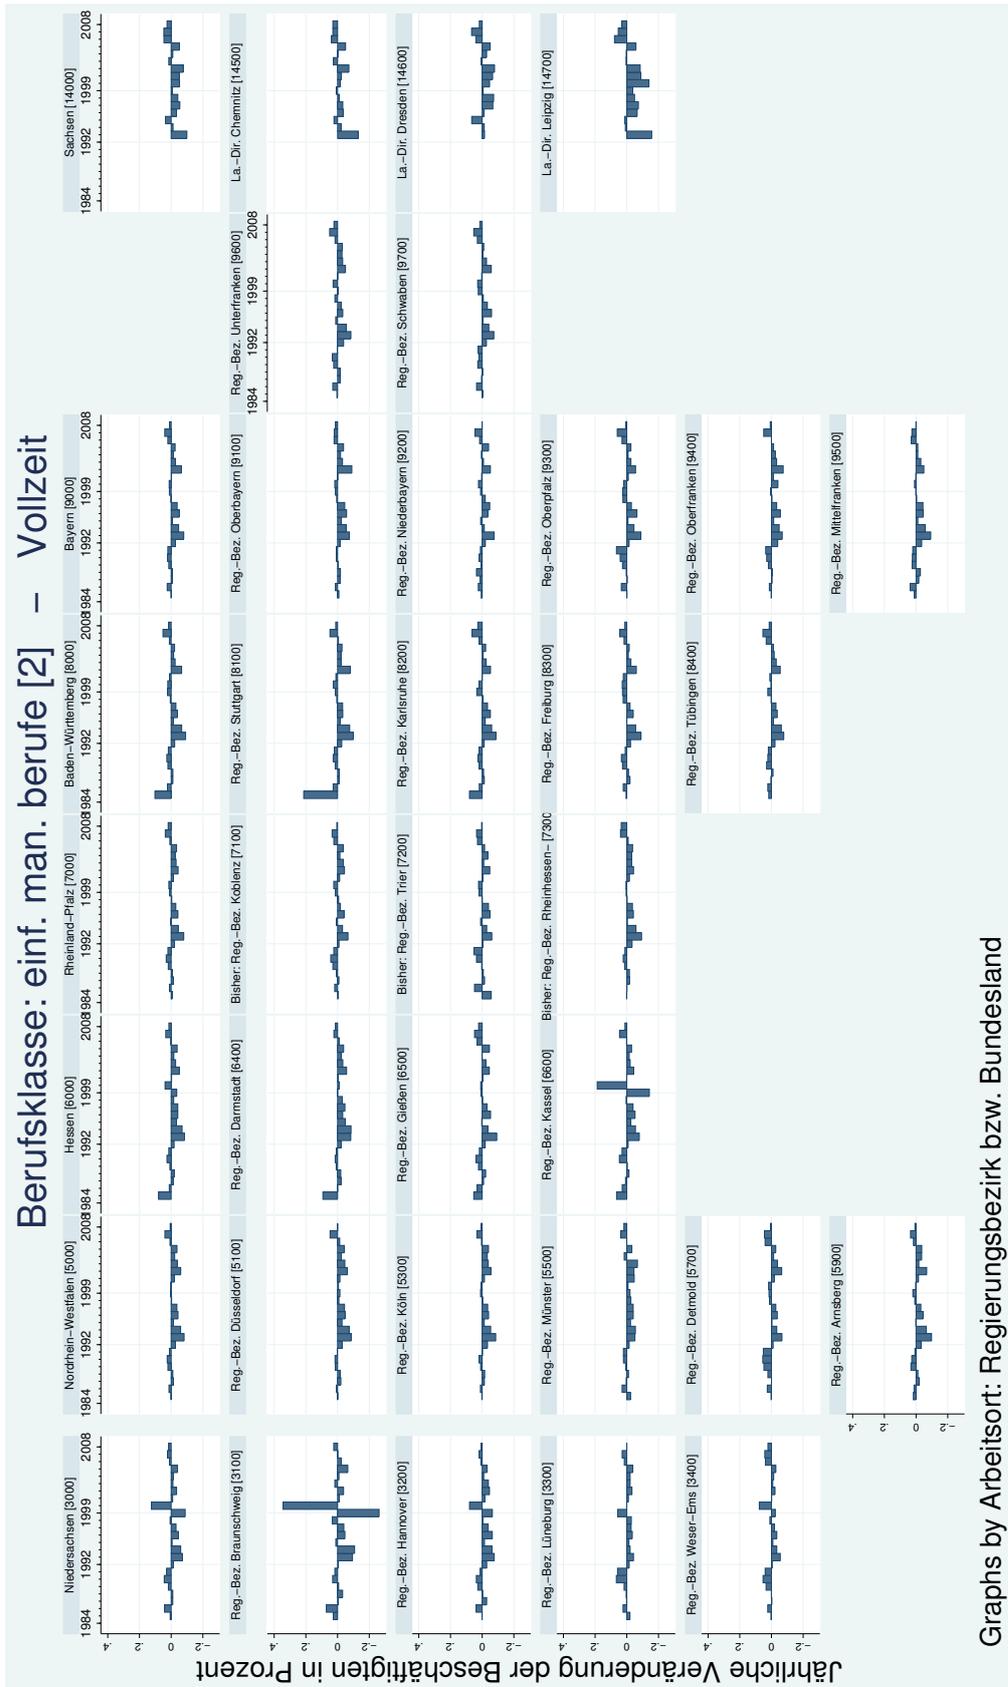


Abbildung A.35.: Jährliche Veränderung der Beschäftigung – Vollzeit : Einfache manuelle Berufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do

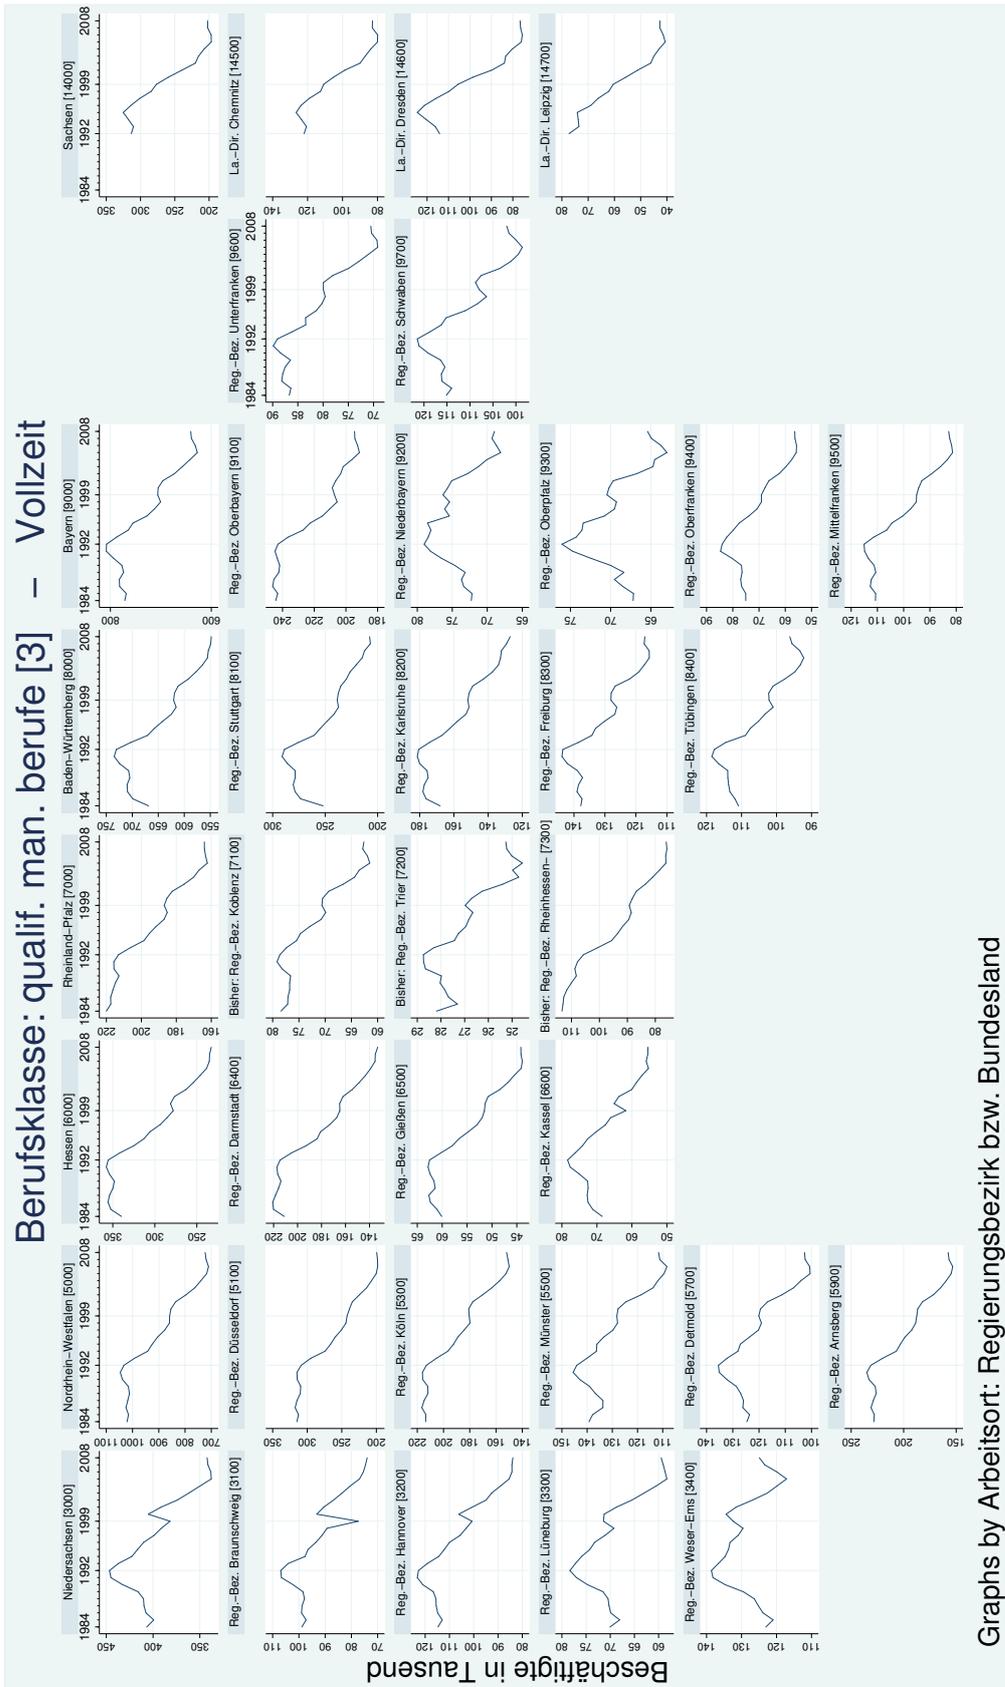


Abbildung A.36.: Anzahl Vollzeitbeschäftigte: Qualifizierte manuelle Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoLand-regbez-bb-vz.do`

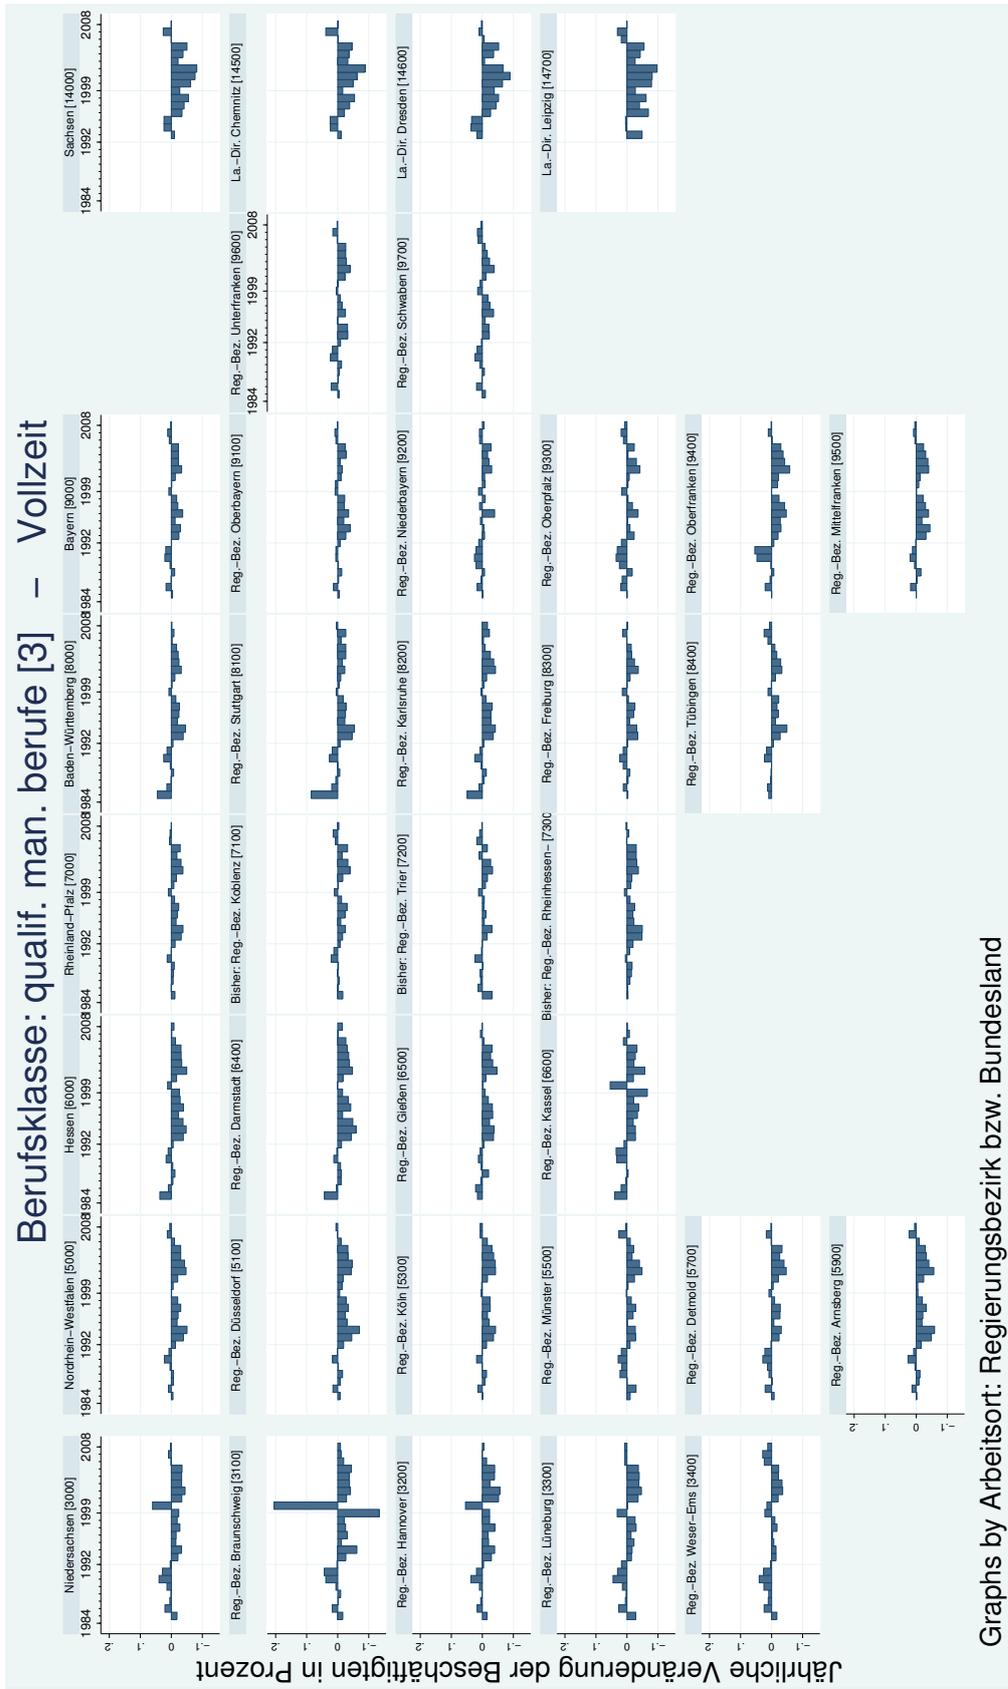
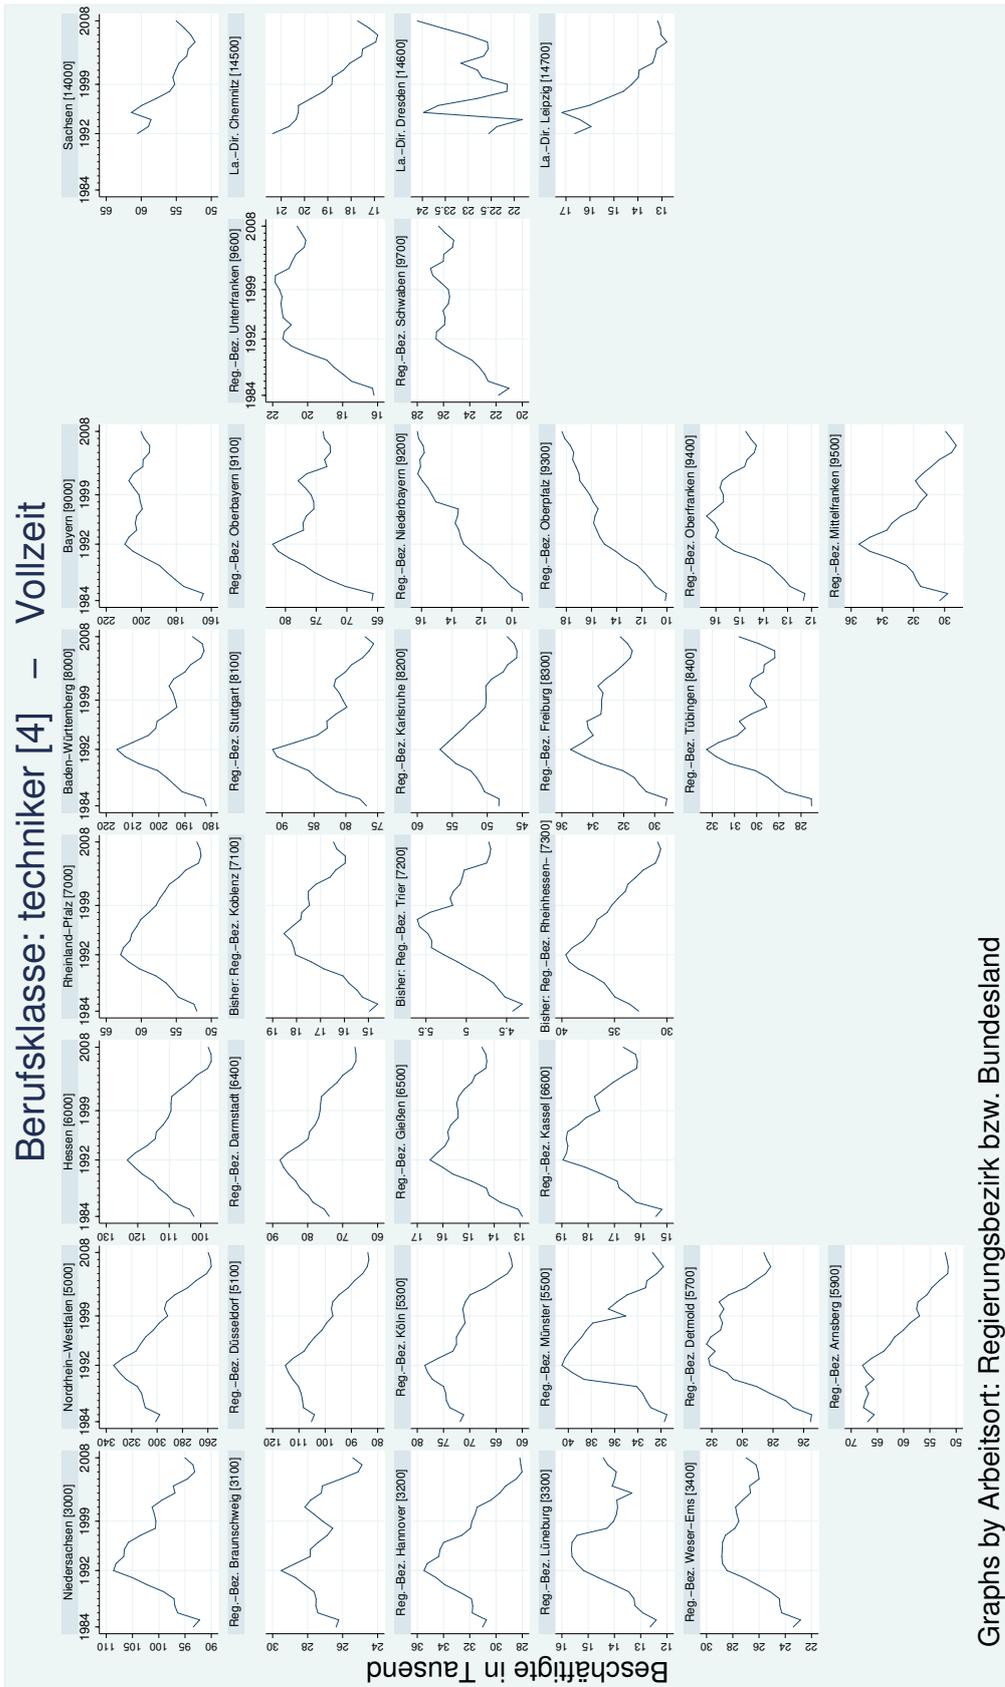
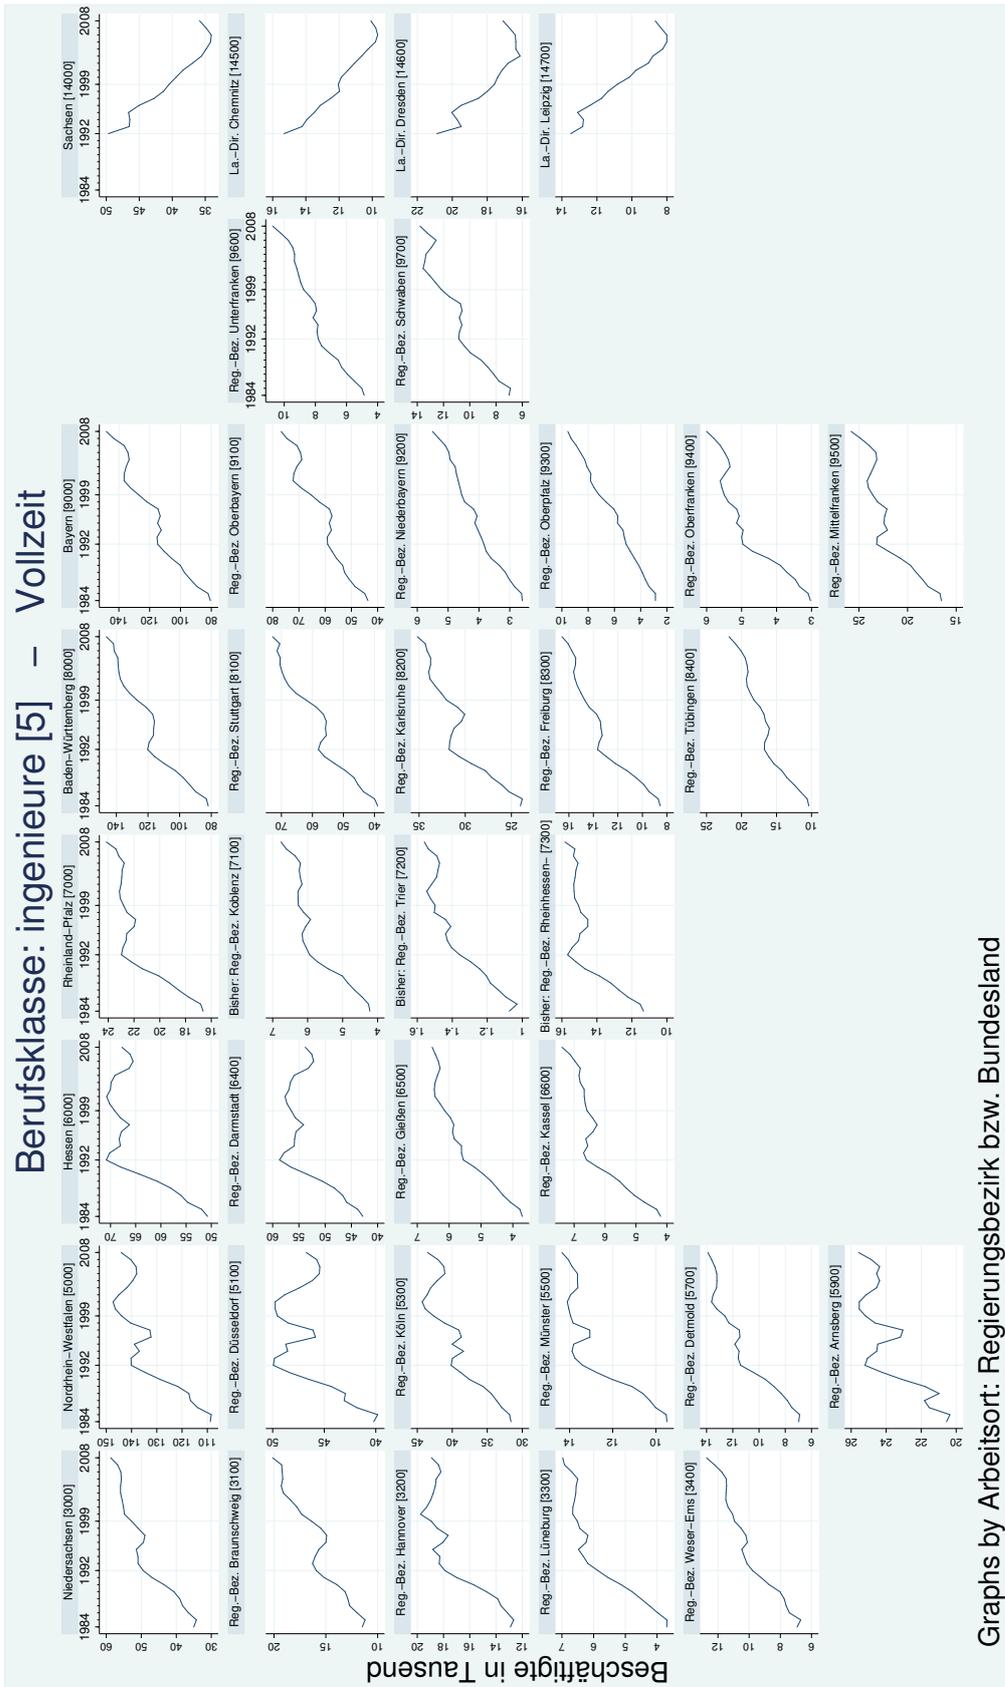


Abbildung A.37.: Jährliche Veränderung der Beschäftigung – Vollzeit: Qualifizierte manuelle Berufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.38.: Anzahl Vollzeitbeschäftigte: Techniker je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoland-regbez-bb-vz.do



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.40.: Anzahl Vollzeitbeschäftigte: Ingenieure je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aoIand-regbez-bb-vz.do`

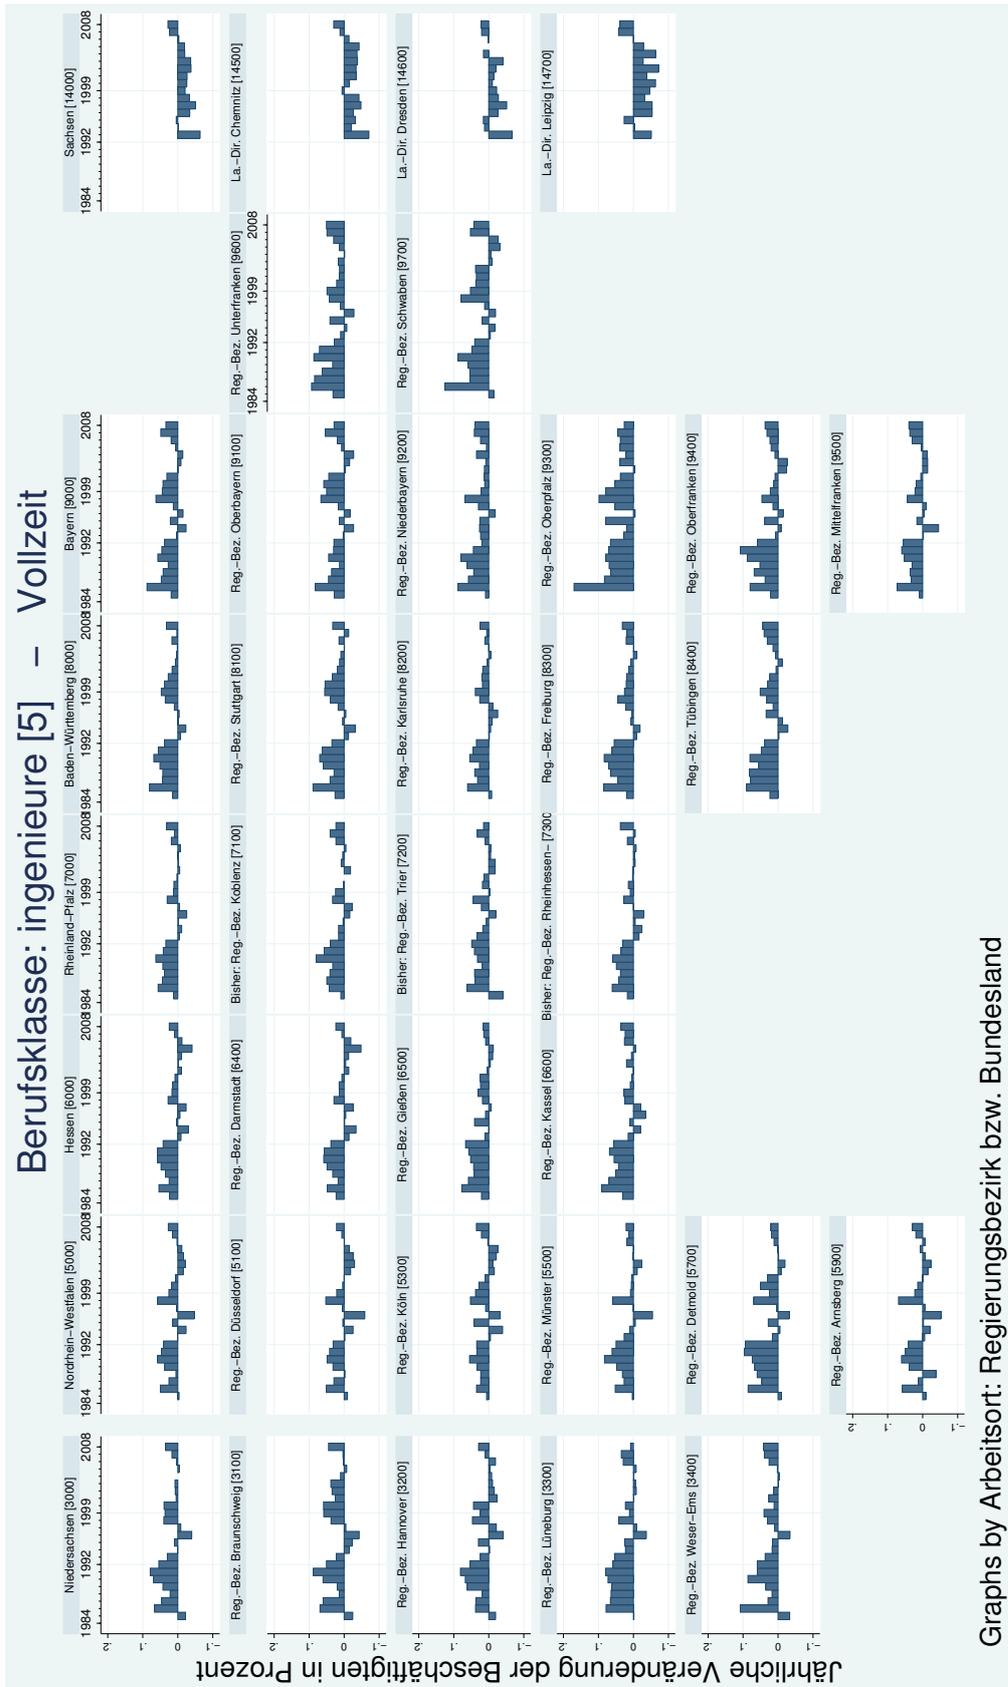


Abbildung A.41.: Jährliche Veränderung der Beschäftigung – Vollzeit: Ingenieure je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do

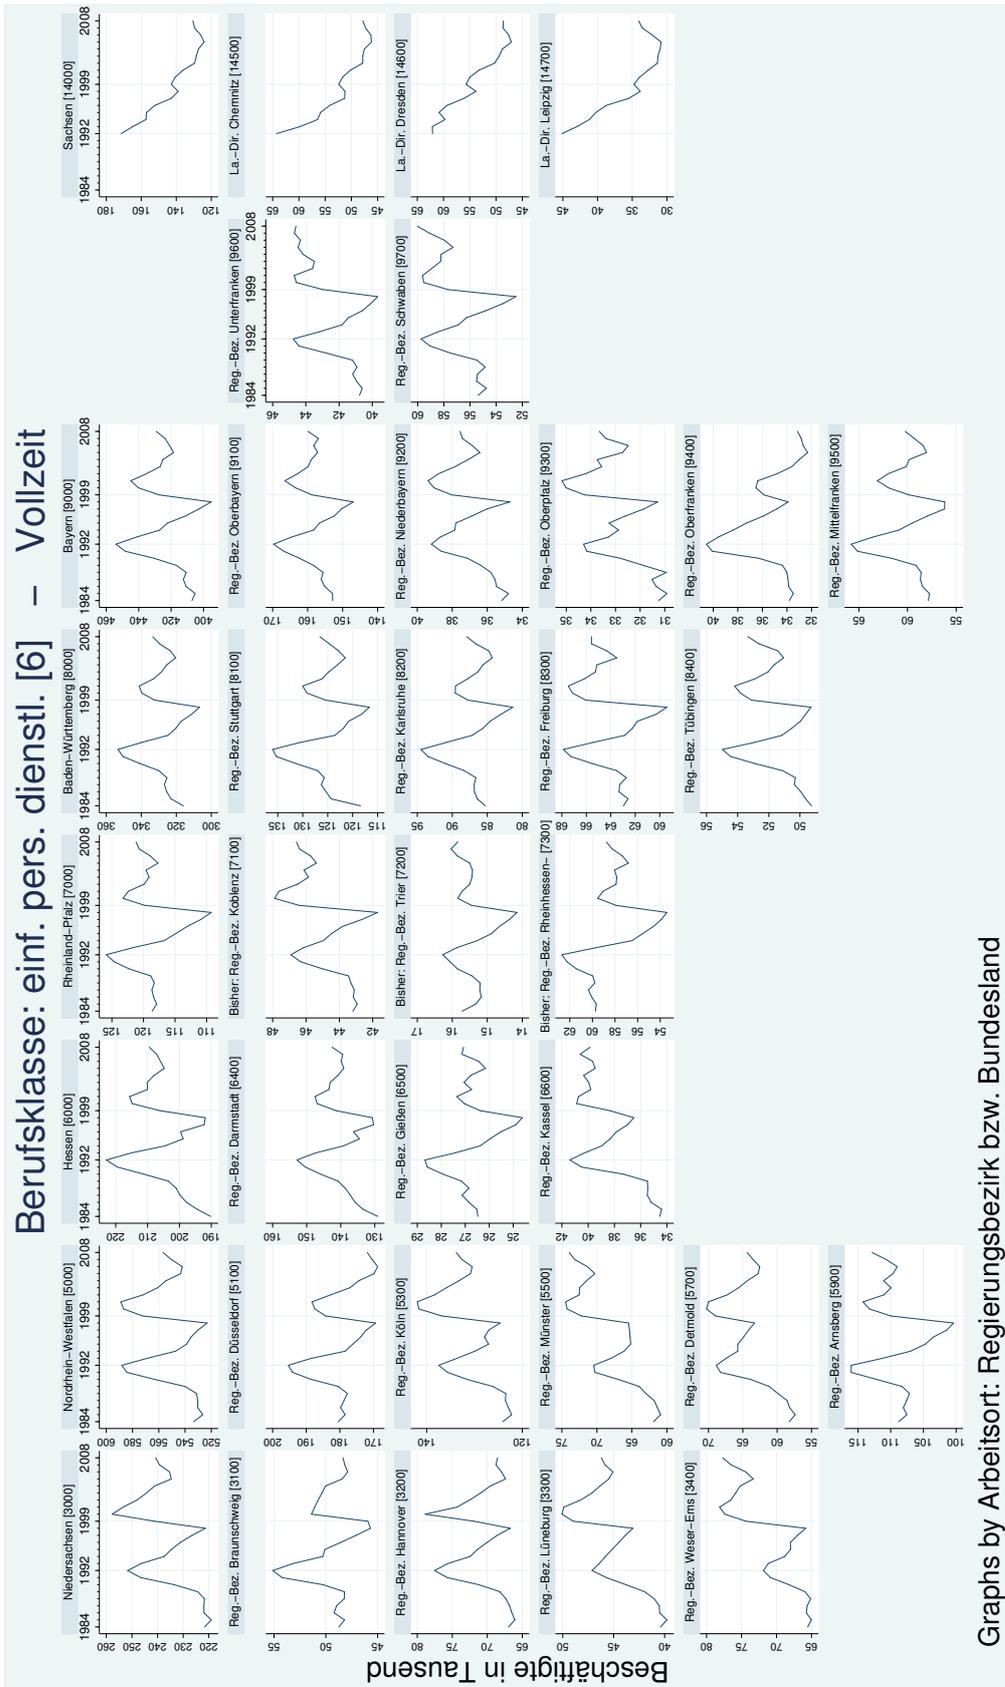


Abbildung A.42.: Anzahl Vollzeitbeschäftigte: Einfache pers. Dienstl. je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoLand-regbez-bb-vz.do`

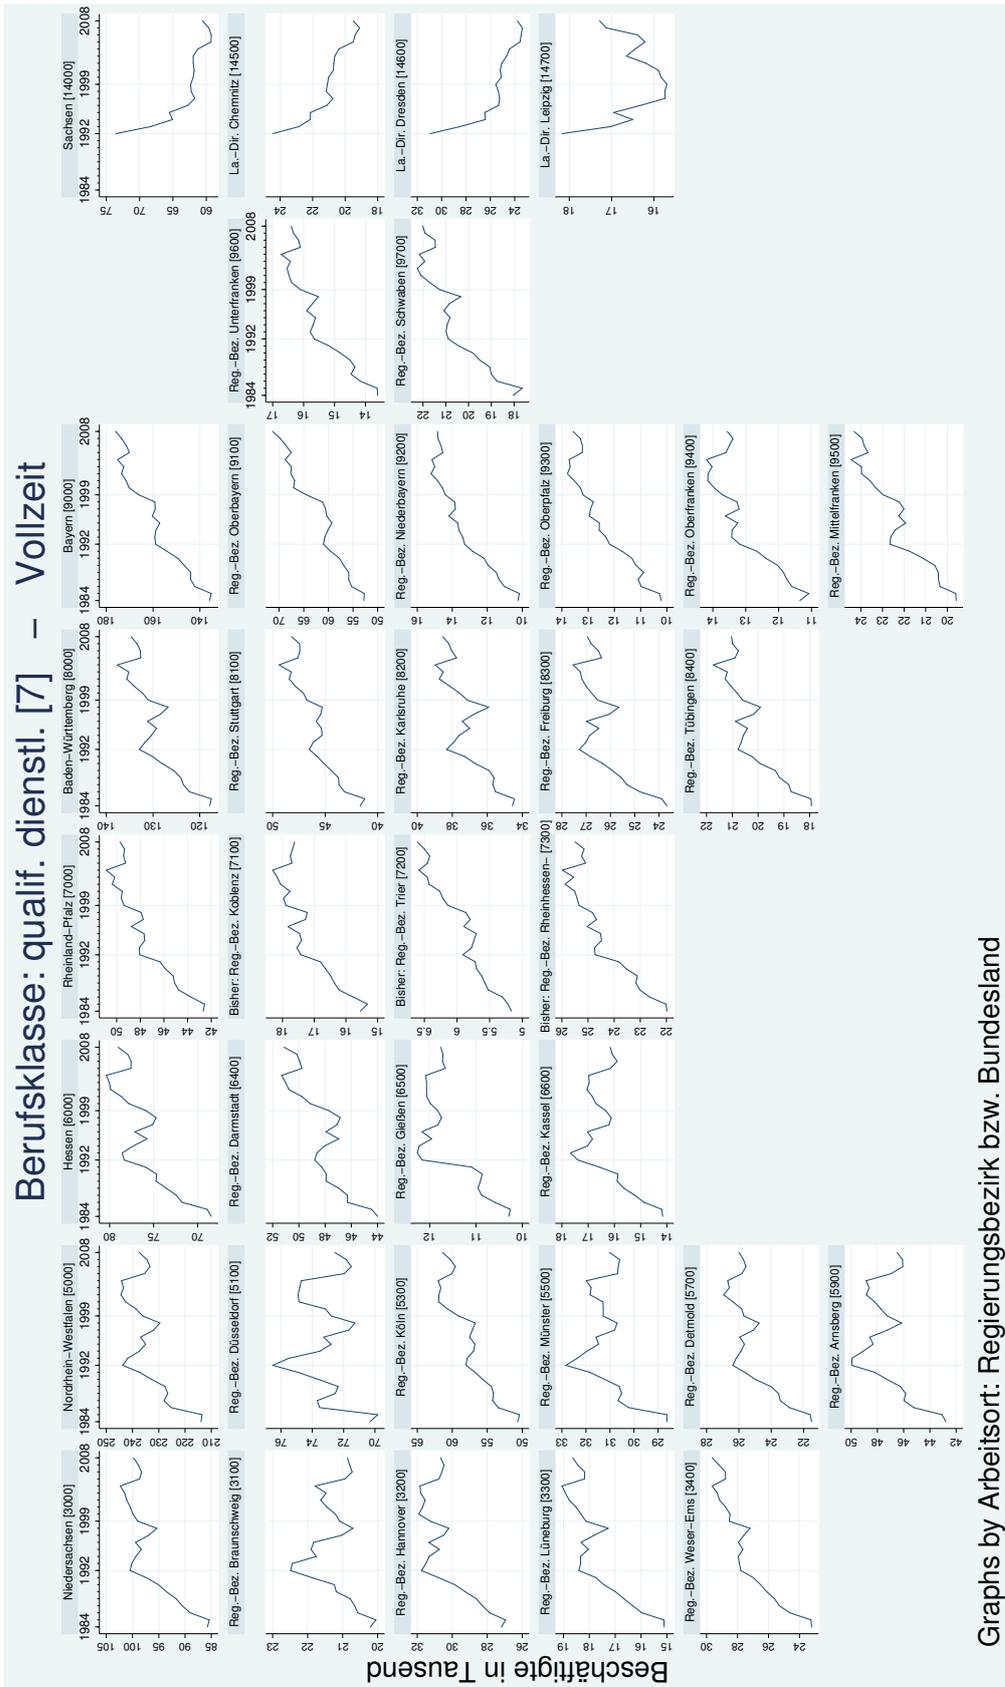


Abbildung A.44.: Anzahl Vollzeitbeschäftigte: Qualifizierte Dienstl. je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoLand-regbez-bb-vz.do

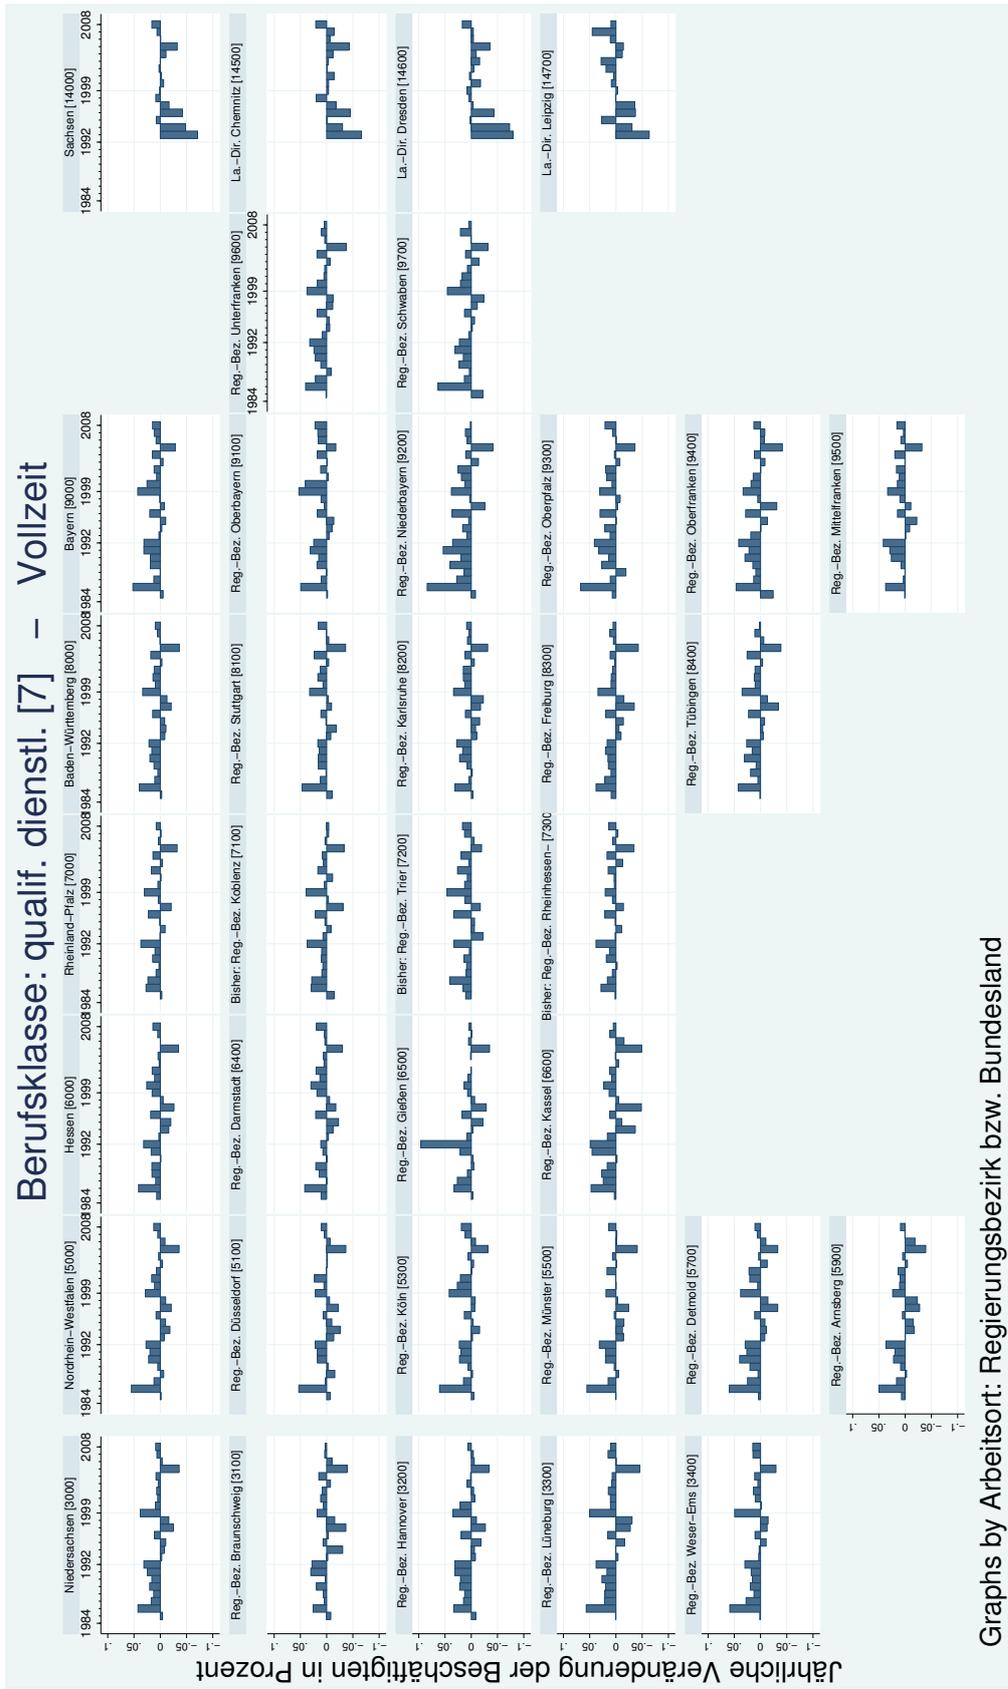
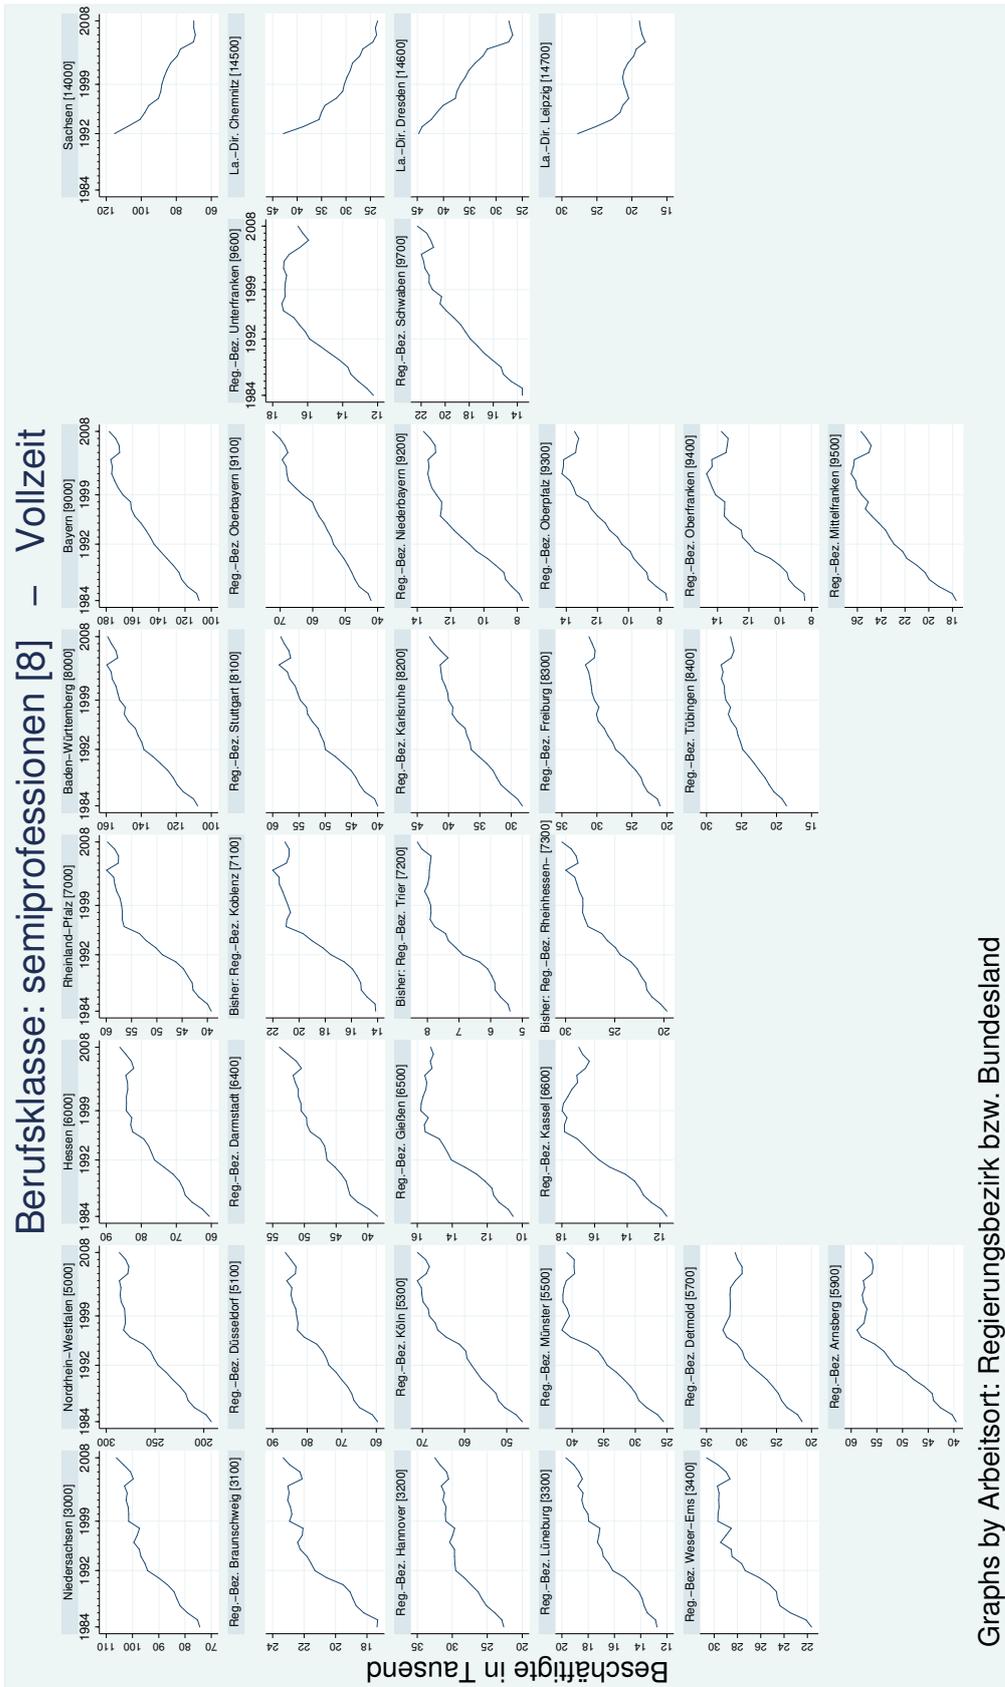


Abbildung A.45.: Jährliche Veränderung der Beschäftigung – Vollzeit: Qualifizierte Dienstl. je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.46.: Anzahl Vollzeitbeschäftigte: Semiprofessionen je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-vz.do

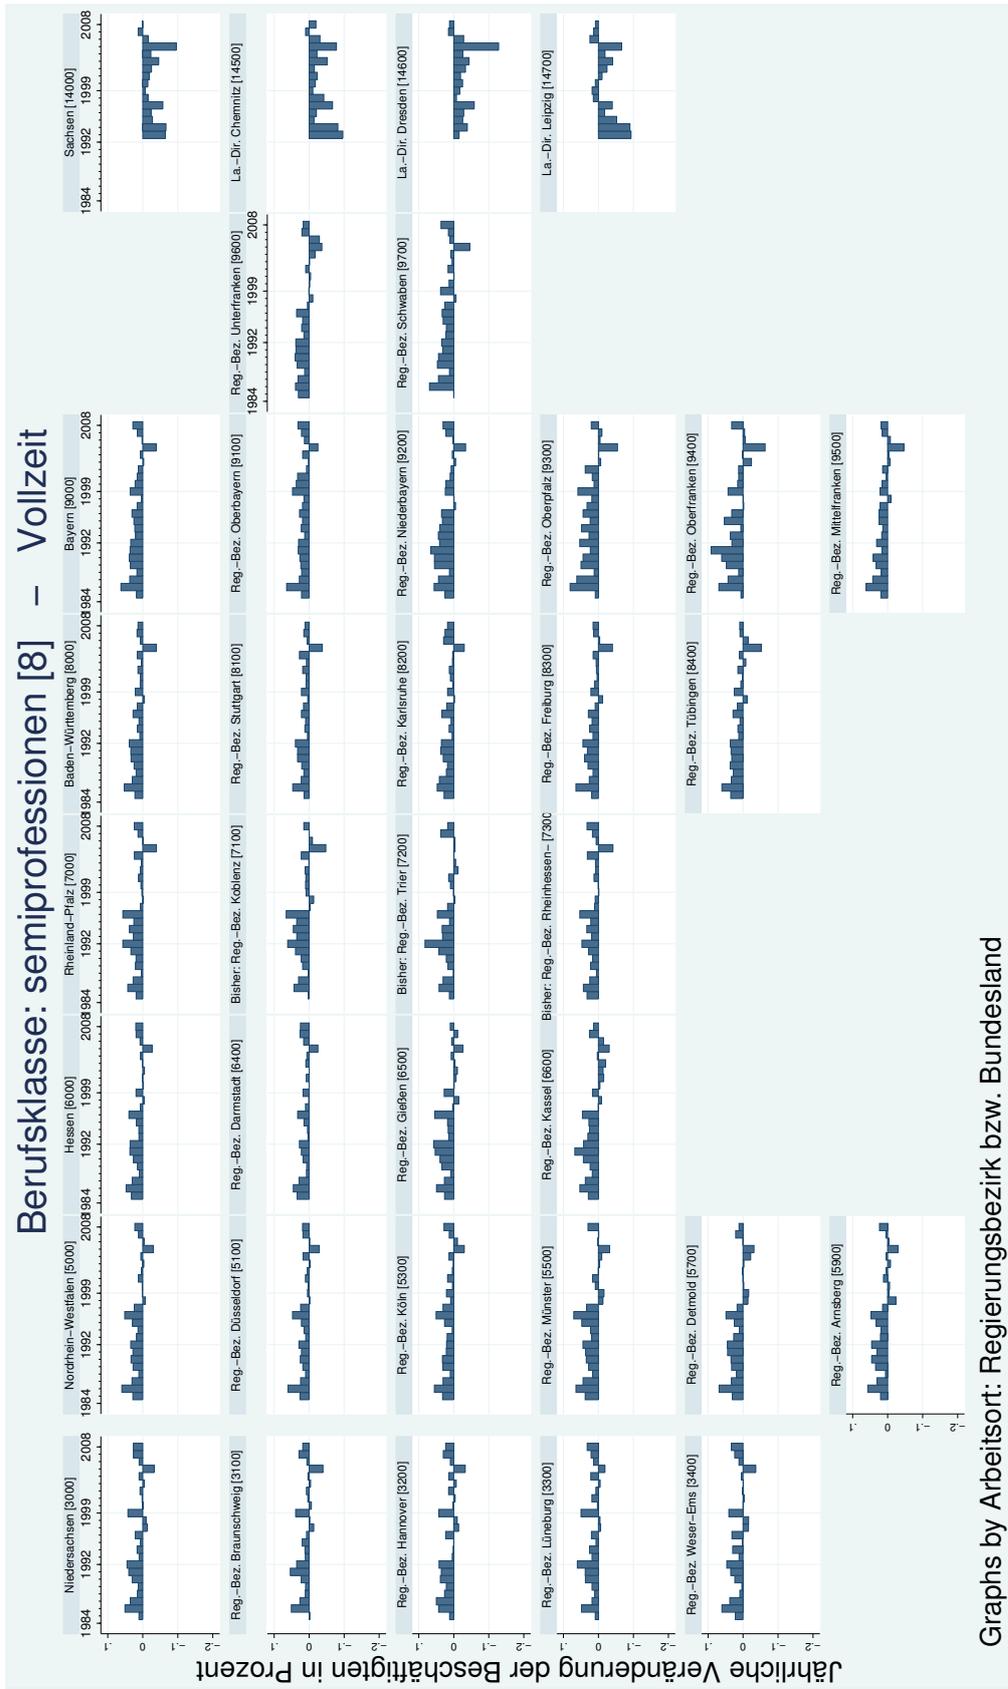


Abbildung A.47.: Jährliche Veränderung der Beschäftigung – Vollzeit: Semiprofessionen je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do

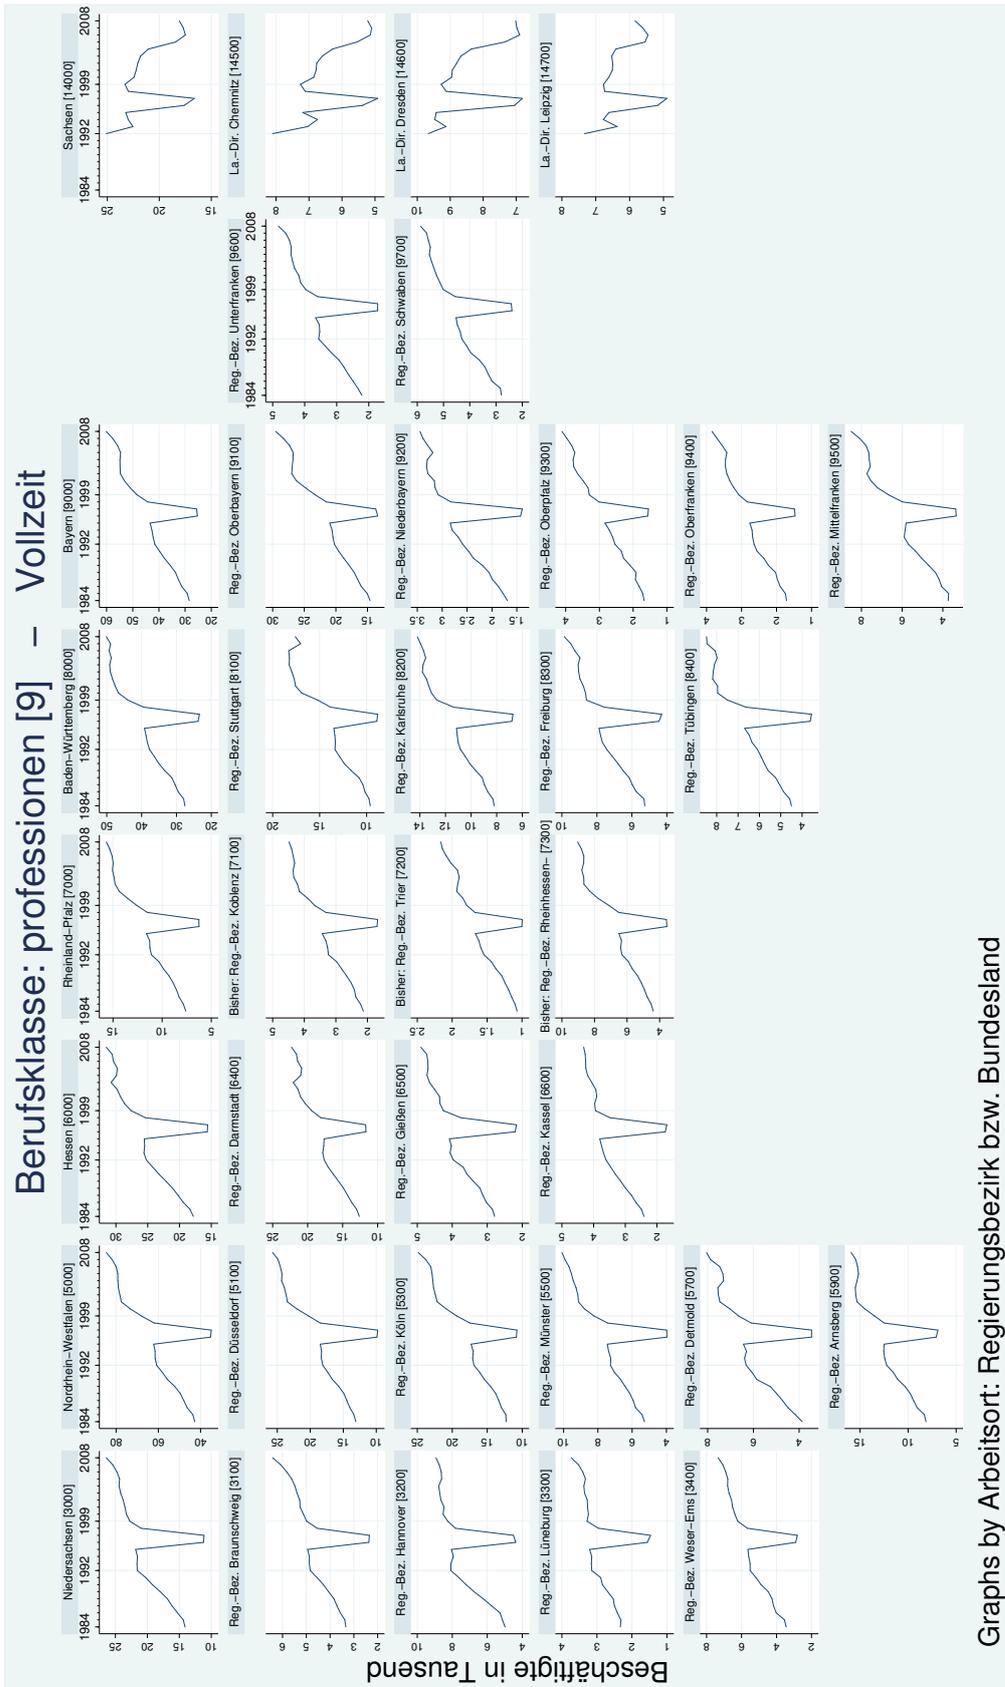


Abbildung A.48.: Anzahl Vollzeitbeschäftigte: Professionen je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aoLand-regbez-bb-vz.do`

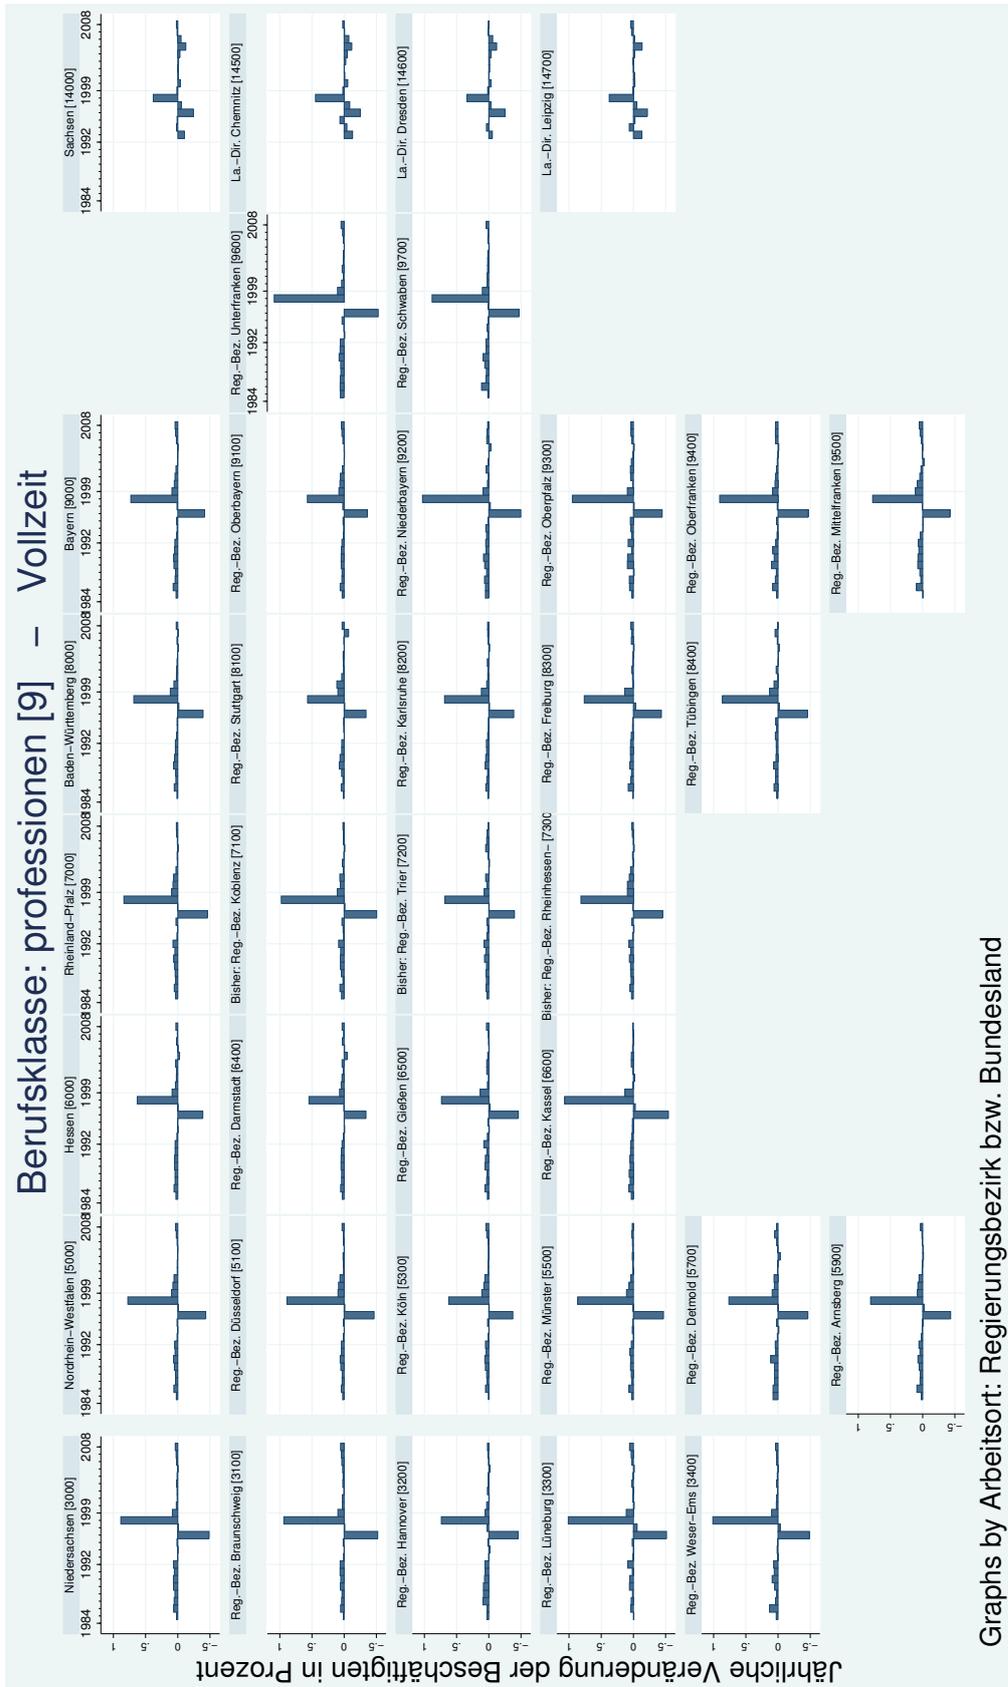


Abbildung A.49.: Jährliche Veränderung der Beschäftigung – Vollzeit: Professionen je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do

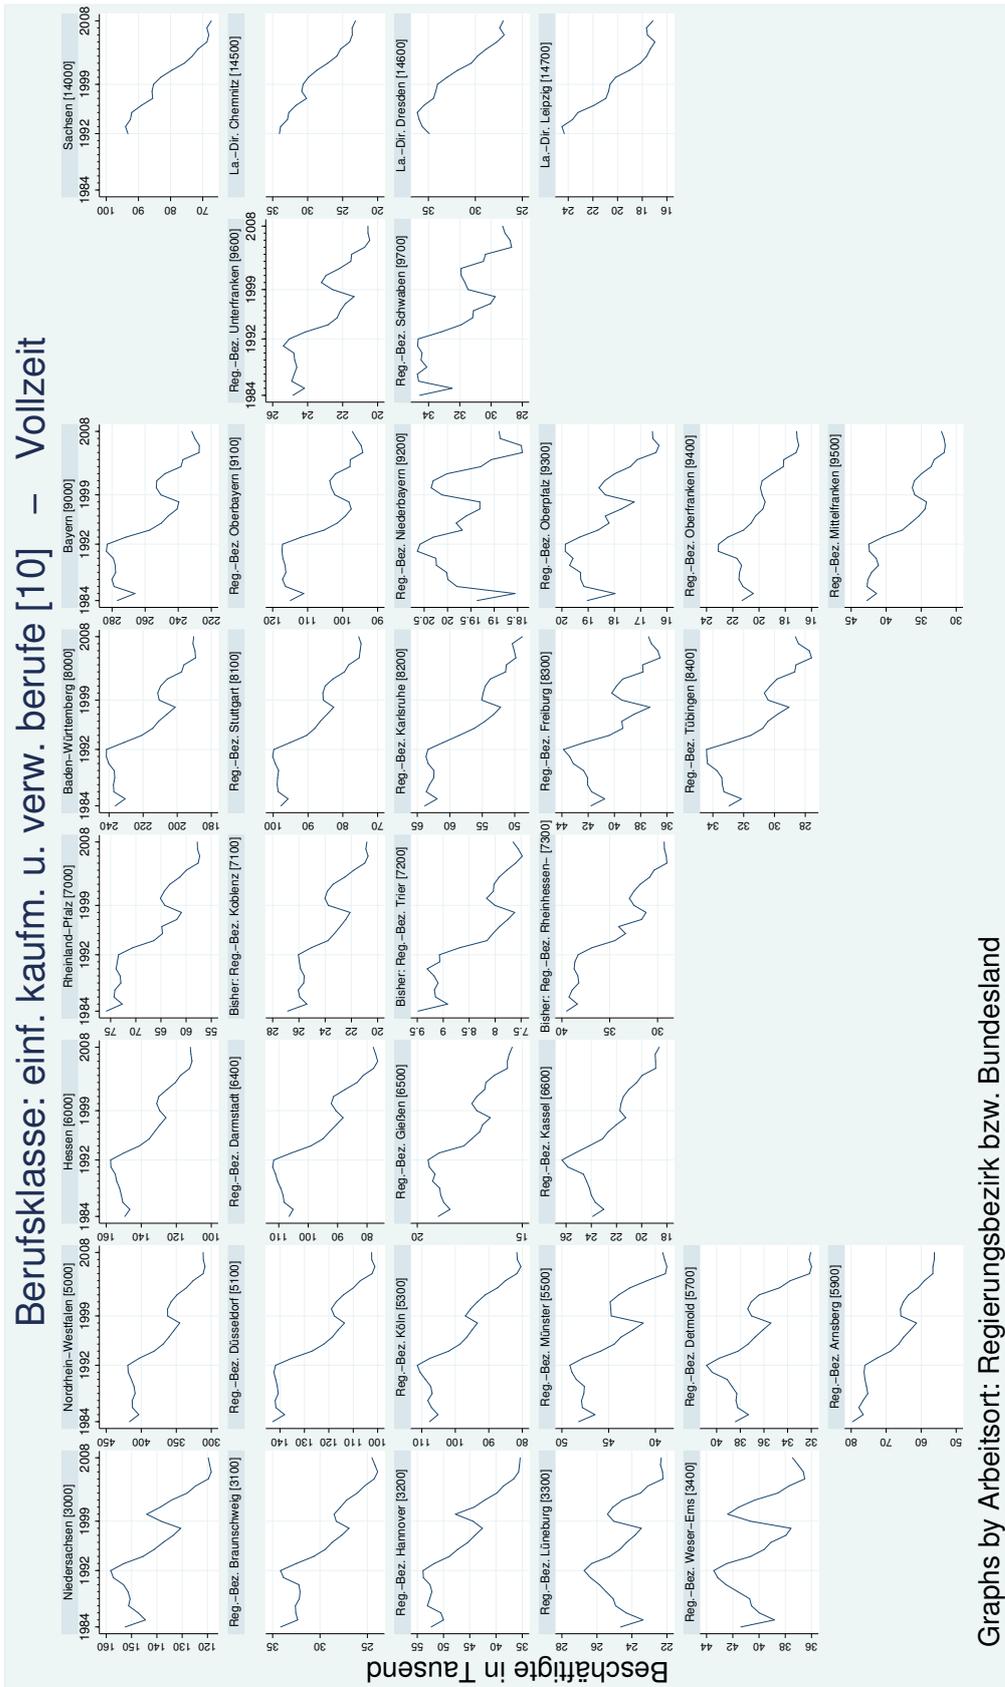


Abbildung A.50.: Anzahl Vollzeitbeschäftigte: Einf. kaufm. u. verw. Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoIand-regbez-bb-vz.do`

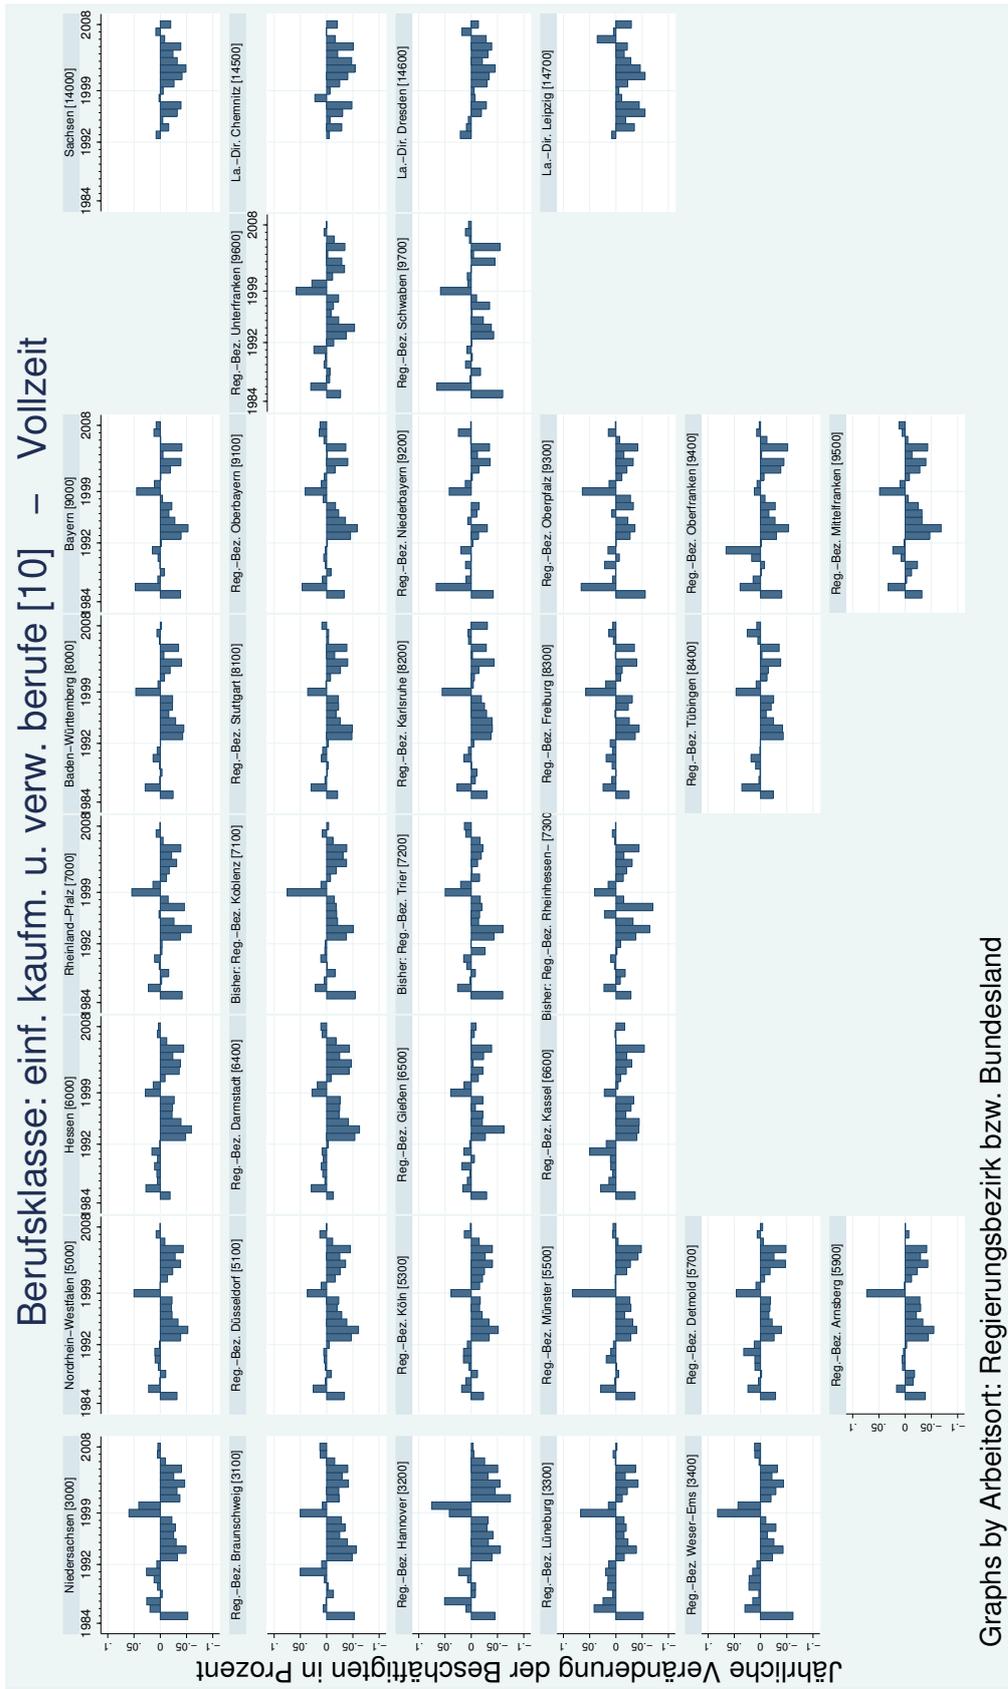
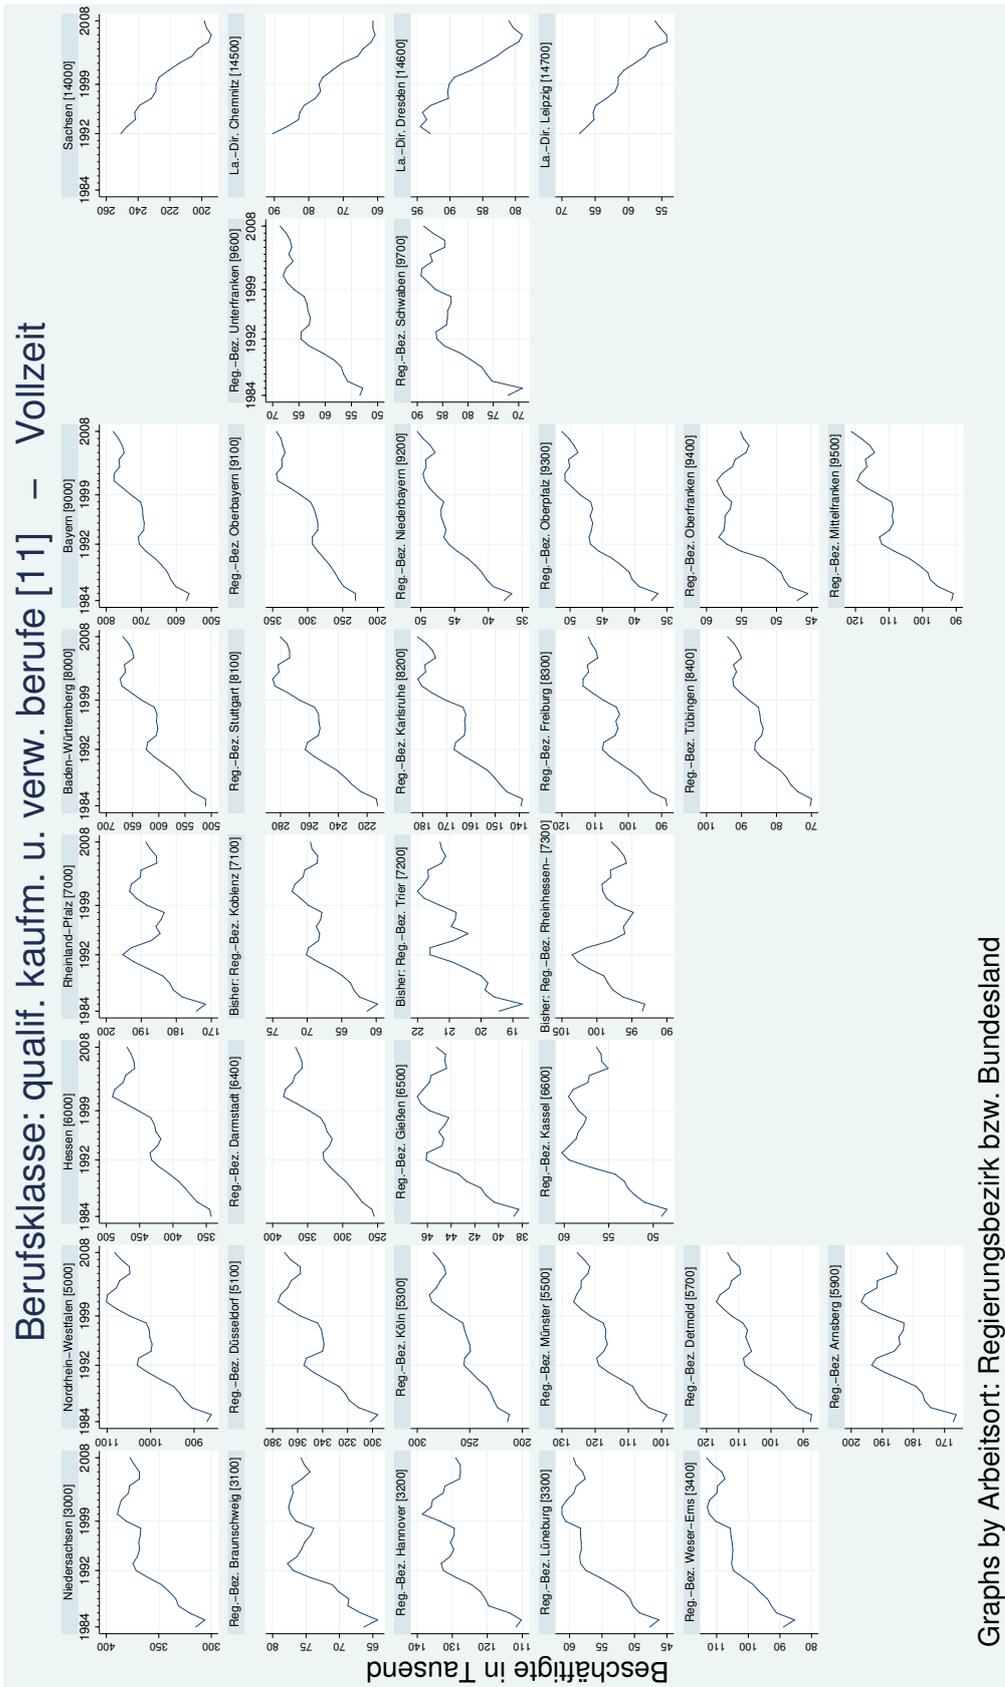


Abbildung A.51.: Jährliche Veränderung der Beschäftigung – Vollzeit: Einf. kaufm. u. verw. Berufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.52.: Anzahl Vollzeitbeschäftigte: Quali. kaufm. u. verw. Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-vz.do

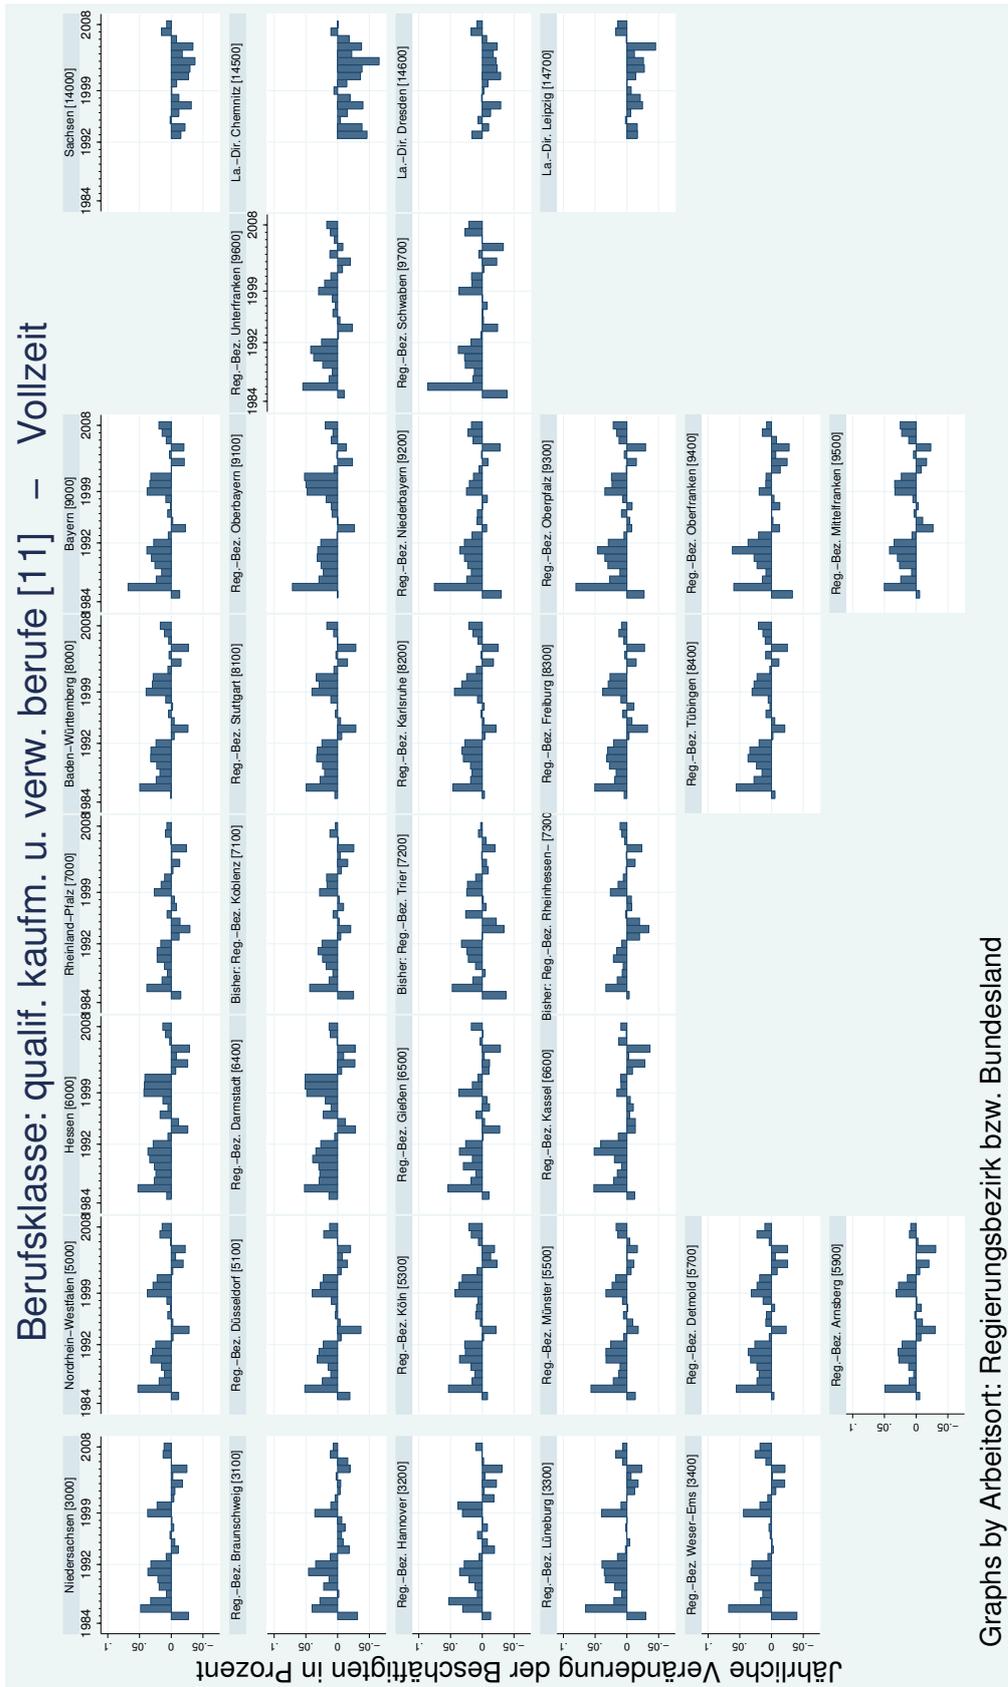


Abbildung A.53.: Jährliche Veränderung der Beschäftigung – Vollzeit: Quali. kaufm. u. verw. Berufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do

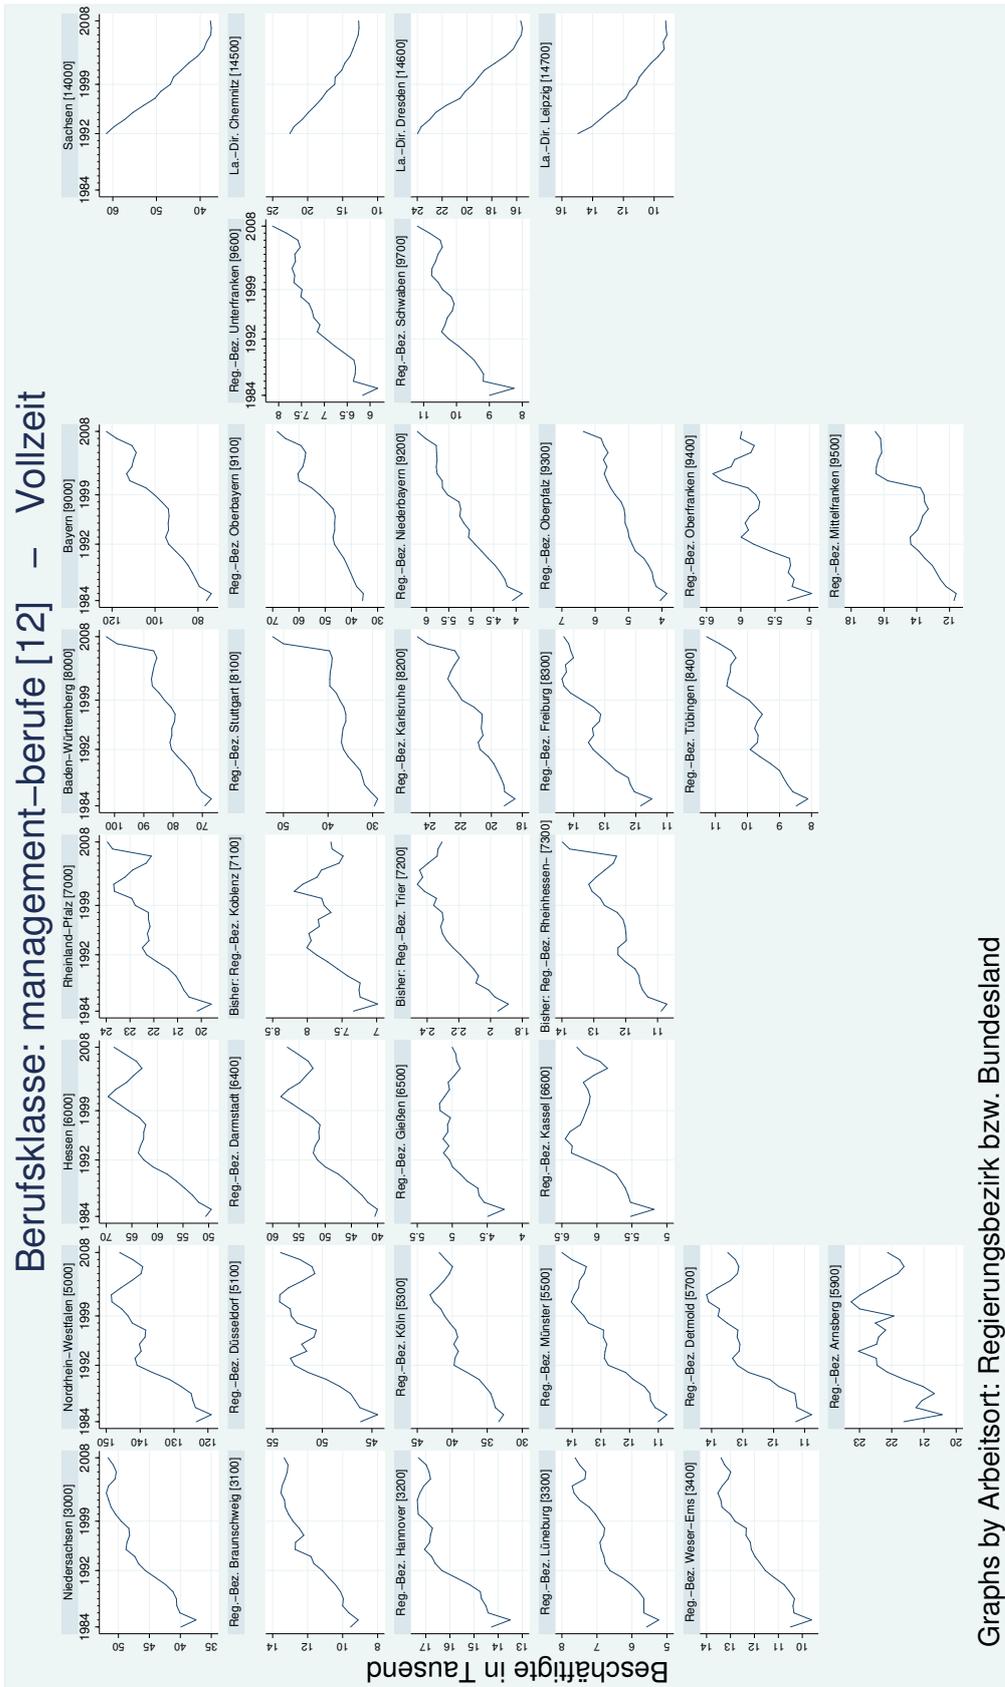


Abbildung A.54.: Anzahl Vollzeitbeschäftigte: Management Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-vz.do

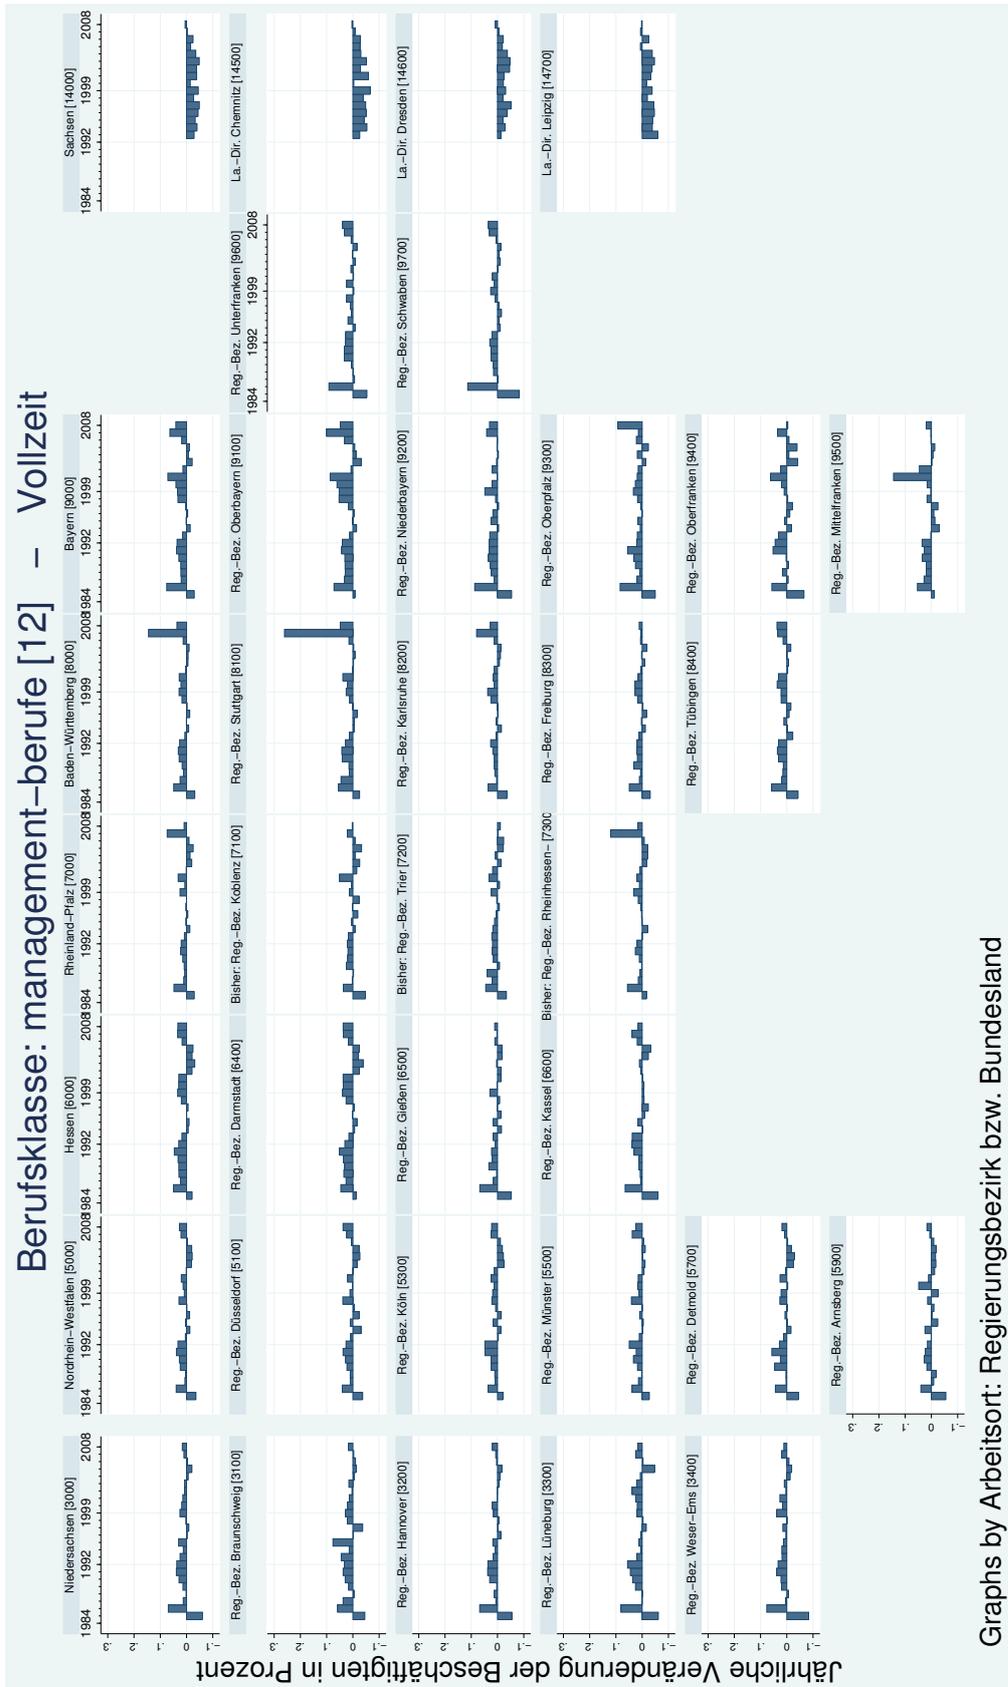


Abbildung A.55.: Jährliche Veränderung der Beschäftigung – Vollzeit: Management Berufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-vz.do

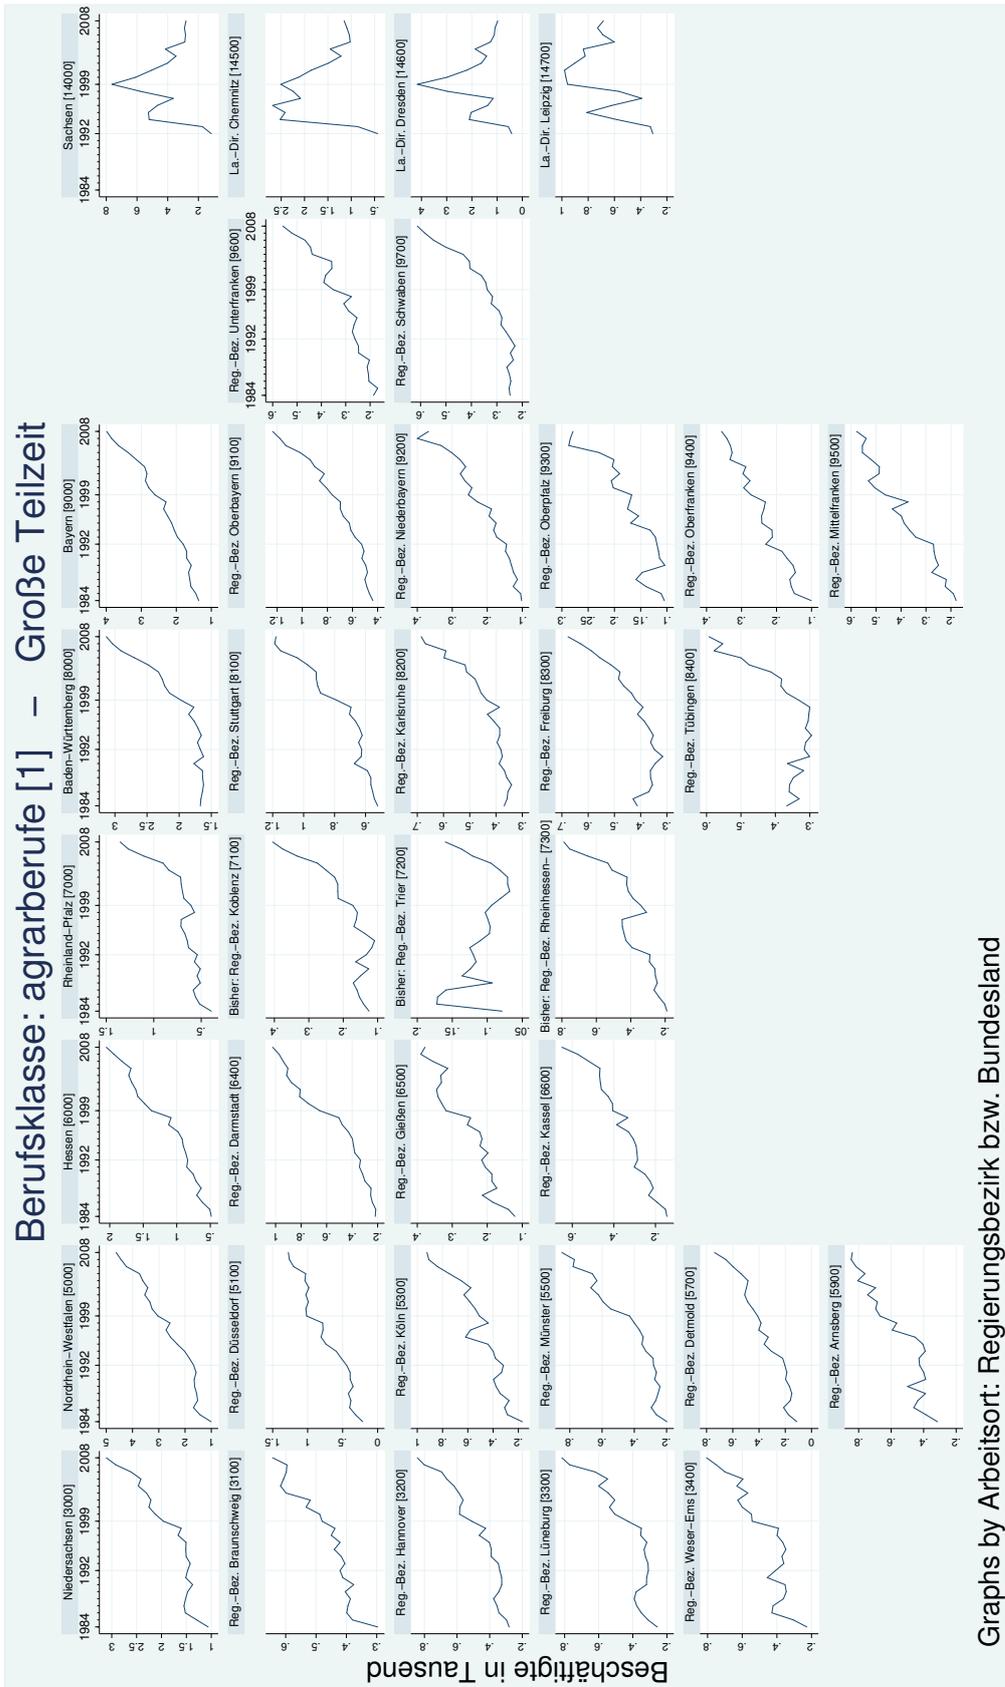
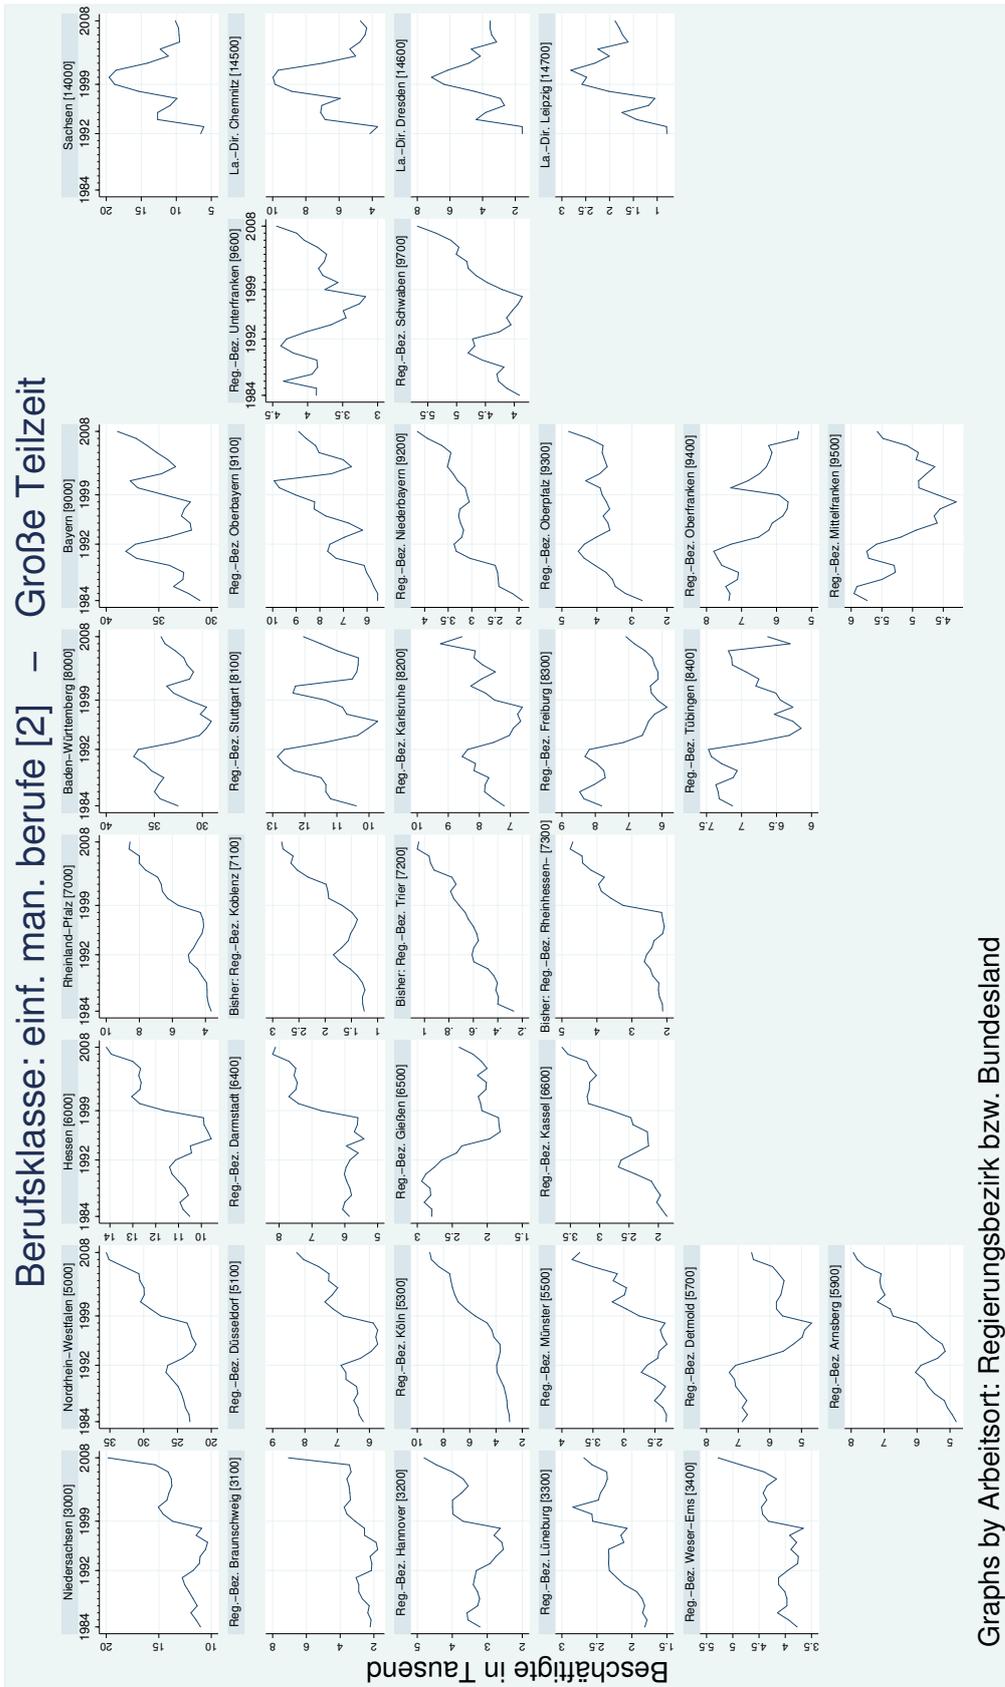


Abbildung A.56.: Anzahl Teilzeitbeschäftigte: Agrarberufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoLand-regbez-bb-gtz.do



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.58.: Anzahl Teilzeitbeschäftigte: Einfache manuelle Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoIand-regbez-bb-gtz.do`

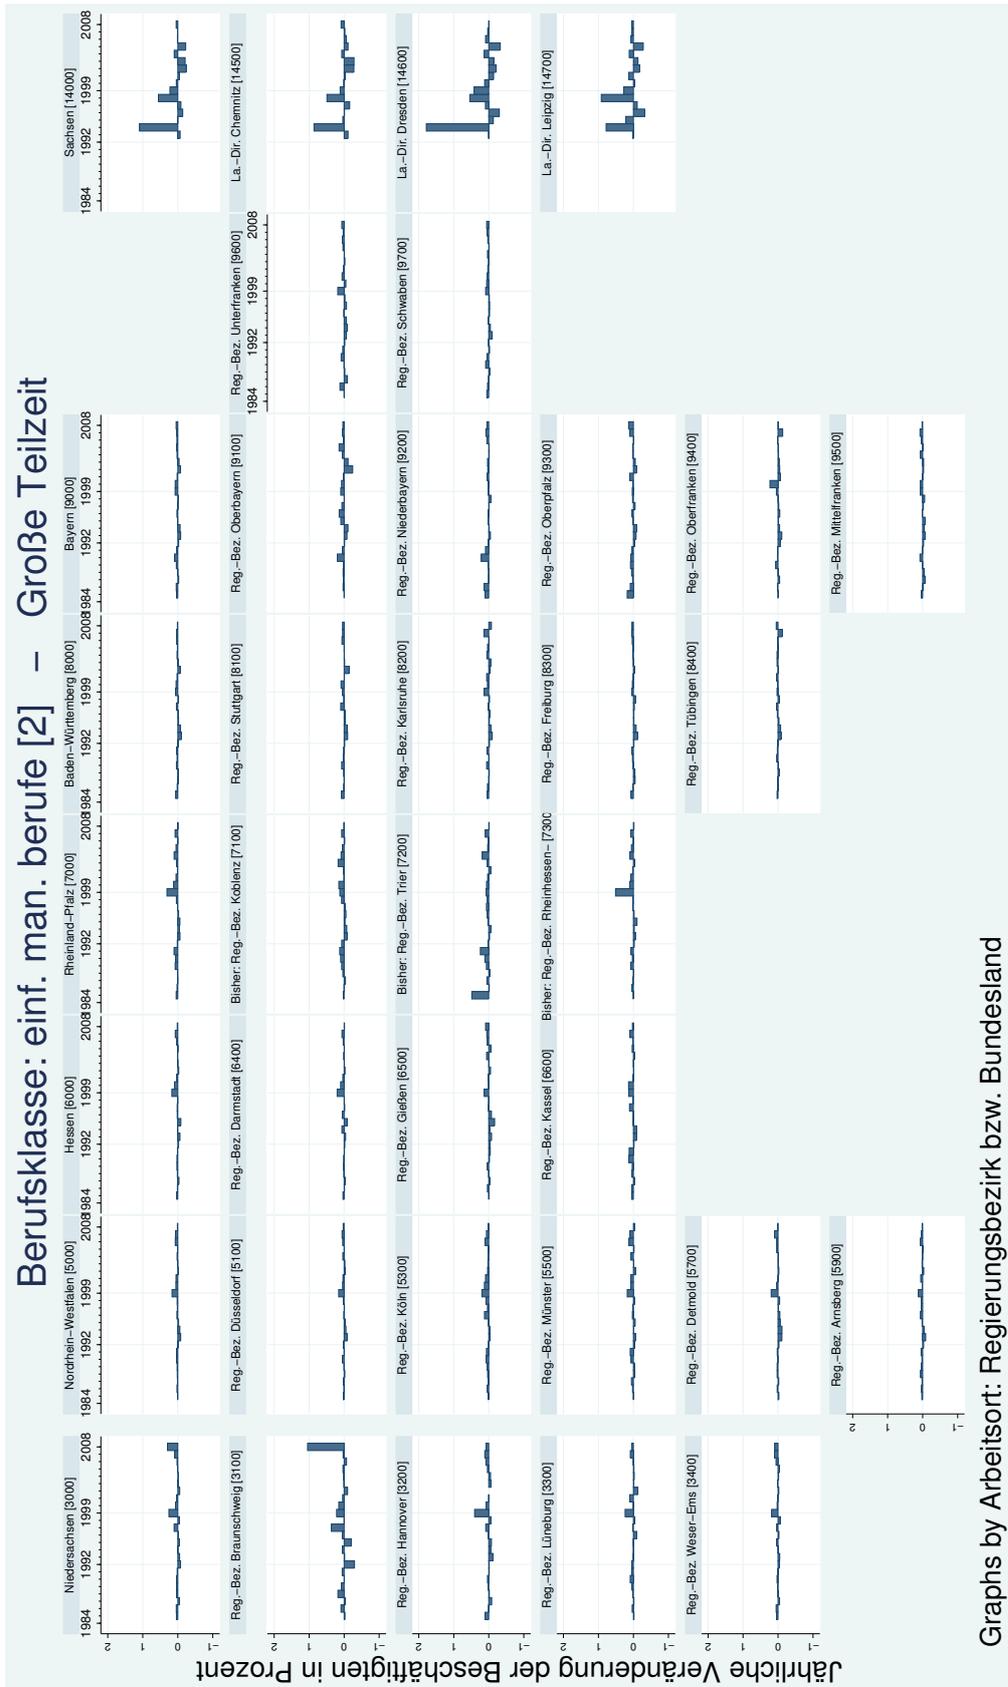


Abbildung A.59.: Jährliche Veränderung der Beschäftigung – Teilzeit : Einfache manuelle Berufe je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

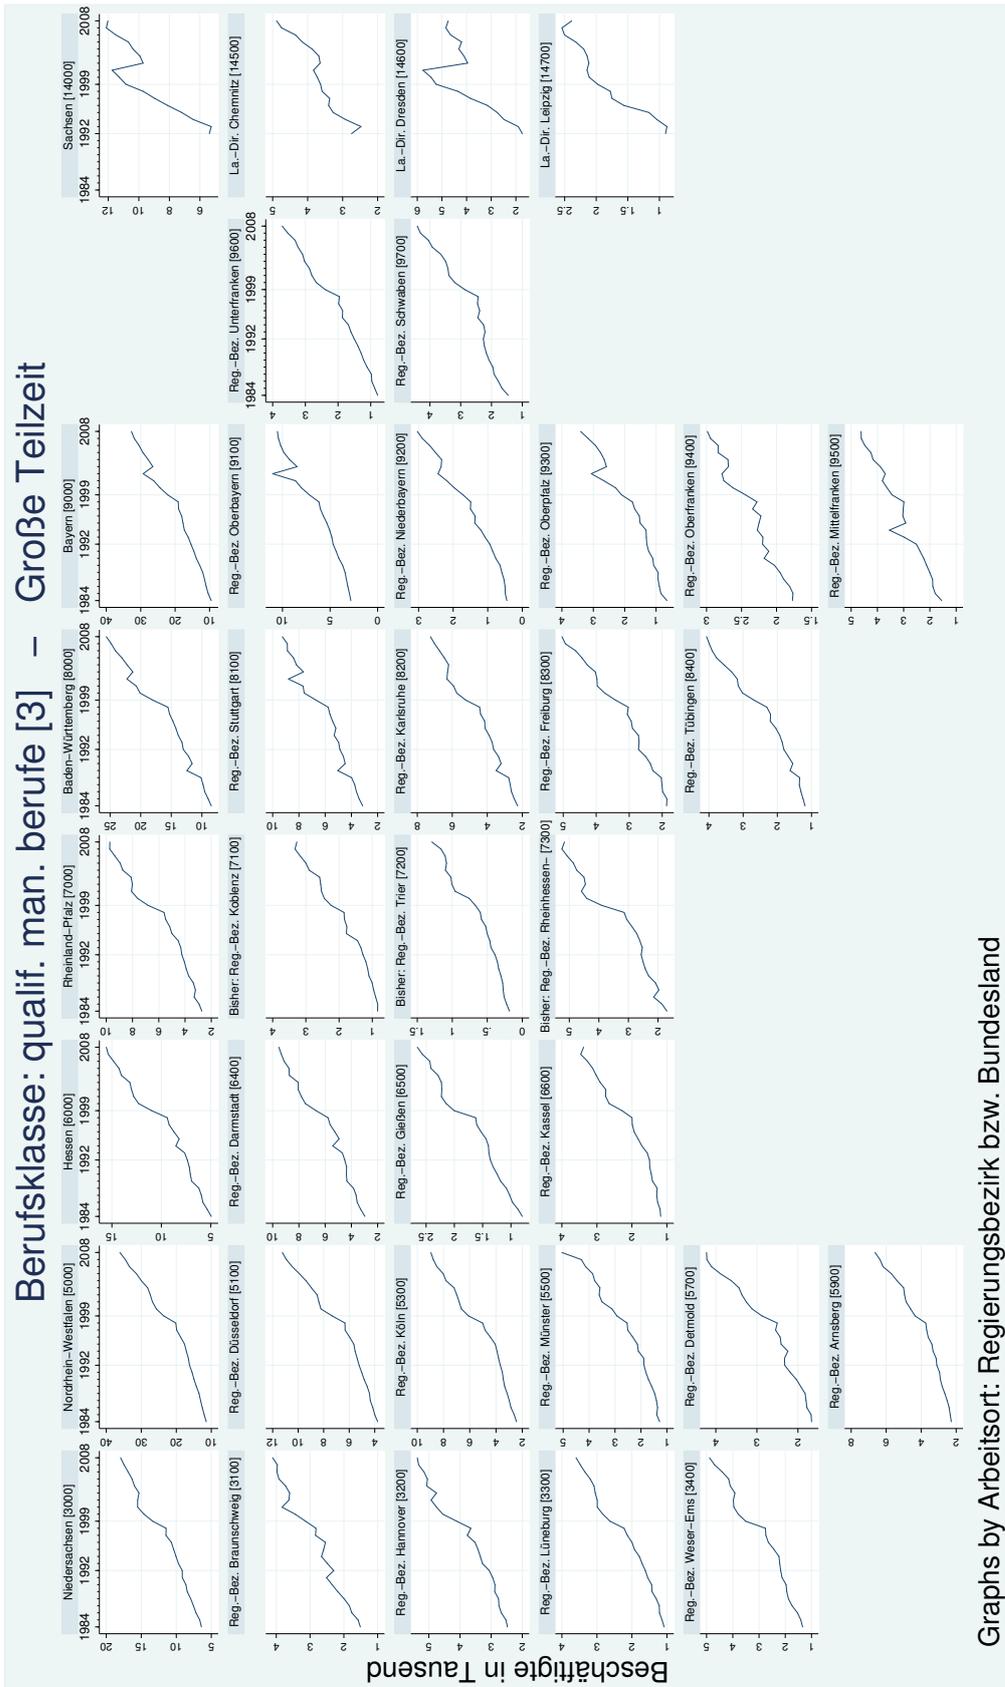


Abbildung A.60.: Anzahl Teilzeitbeschäftigte: Qualifizierte manuelle Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoIand-regbez-bb-gtz.do`

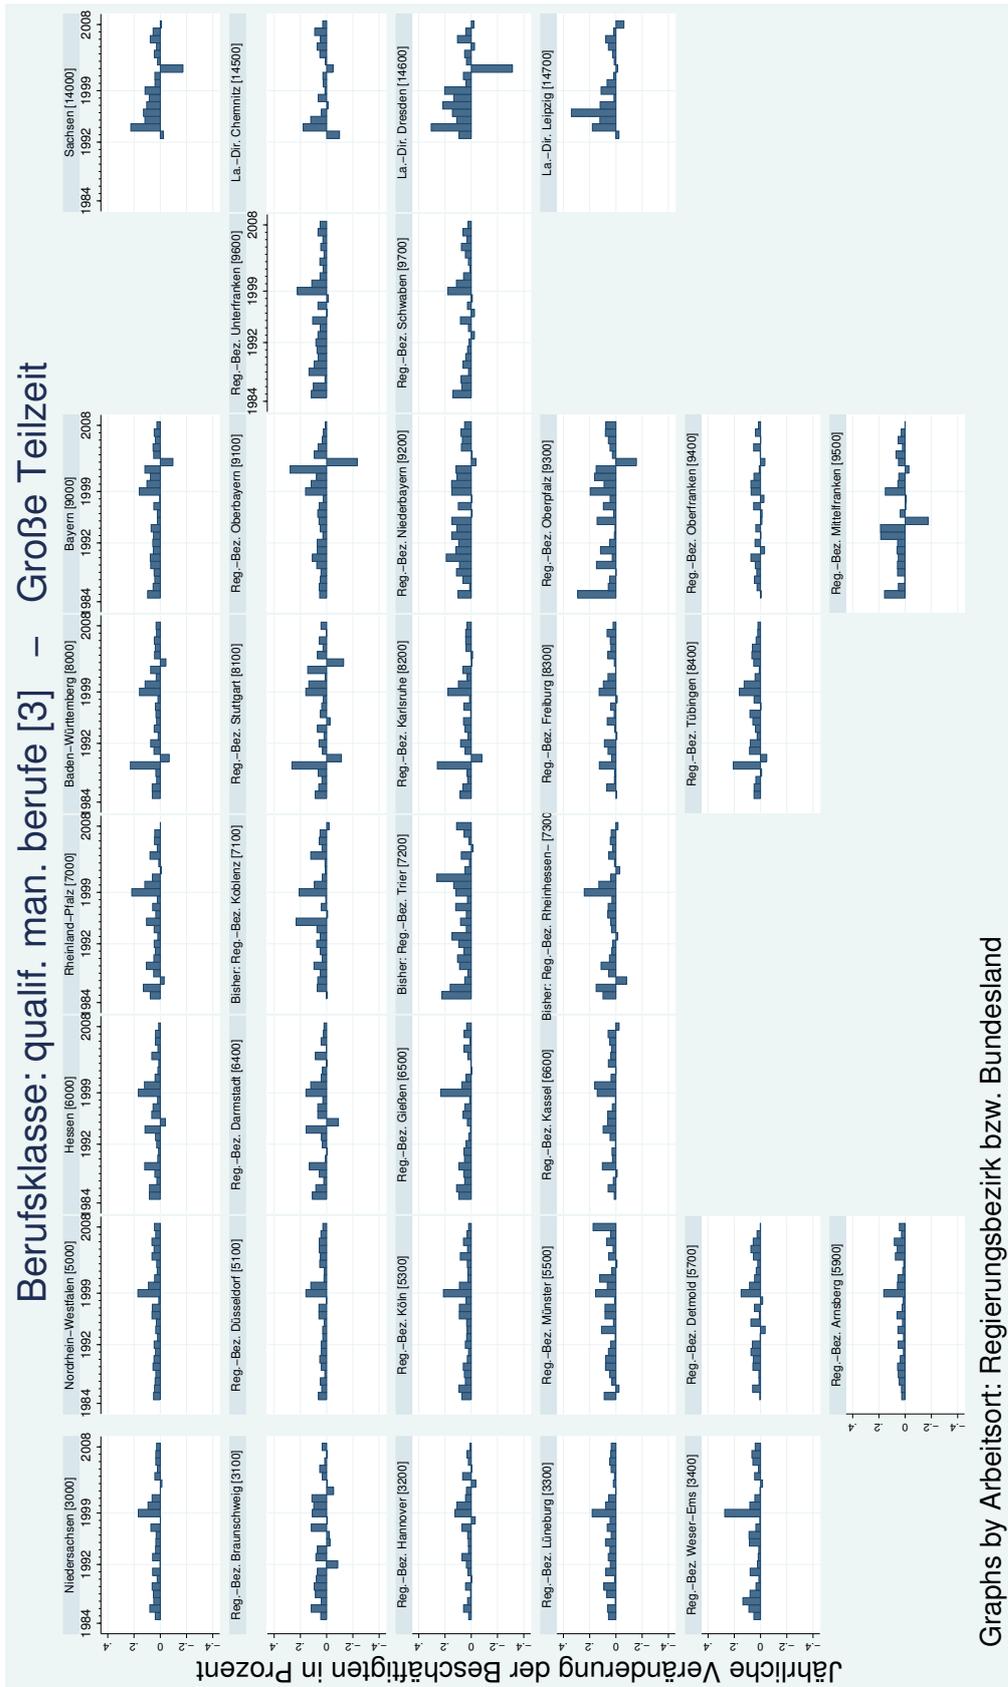


Abbildung A.61.: Jährliche Veränderung der Beschäftigung – Teilzeit: Qualifizierte manuelle Berufe je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-gtz.do

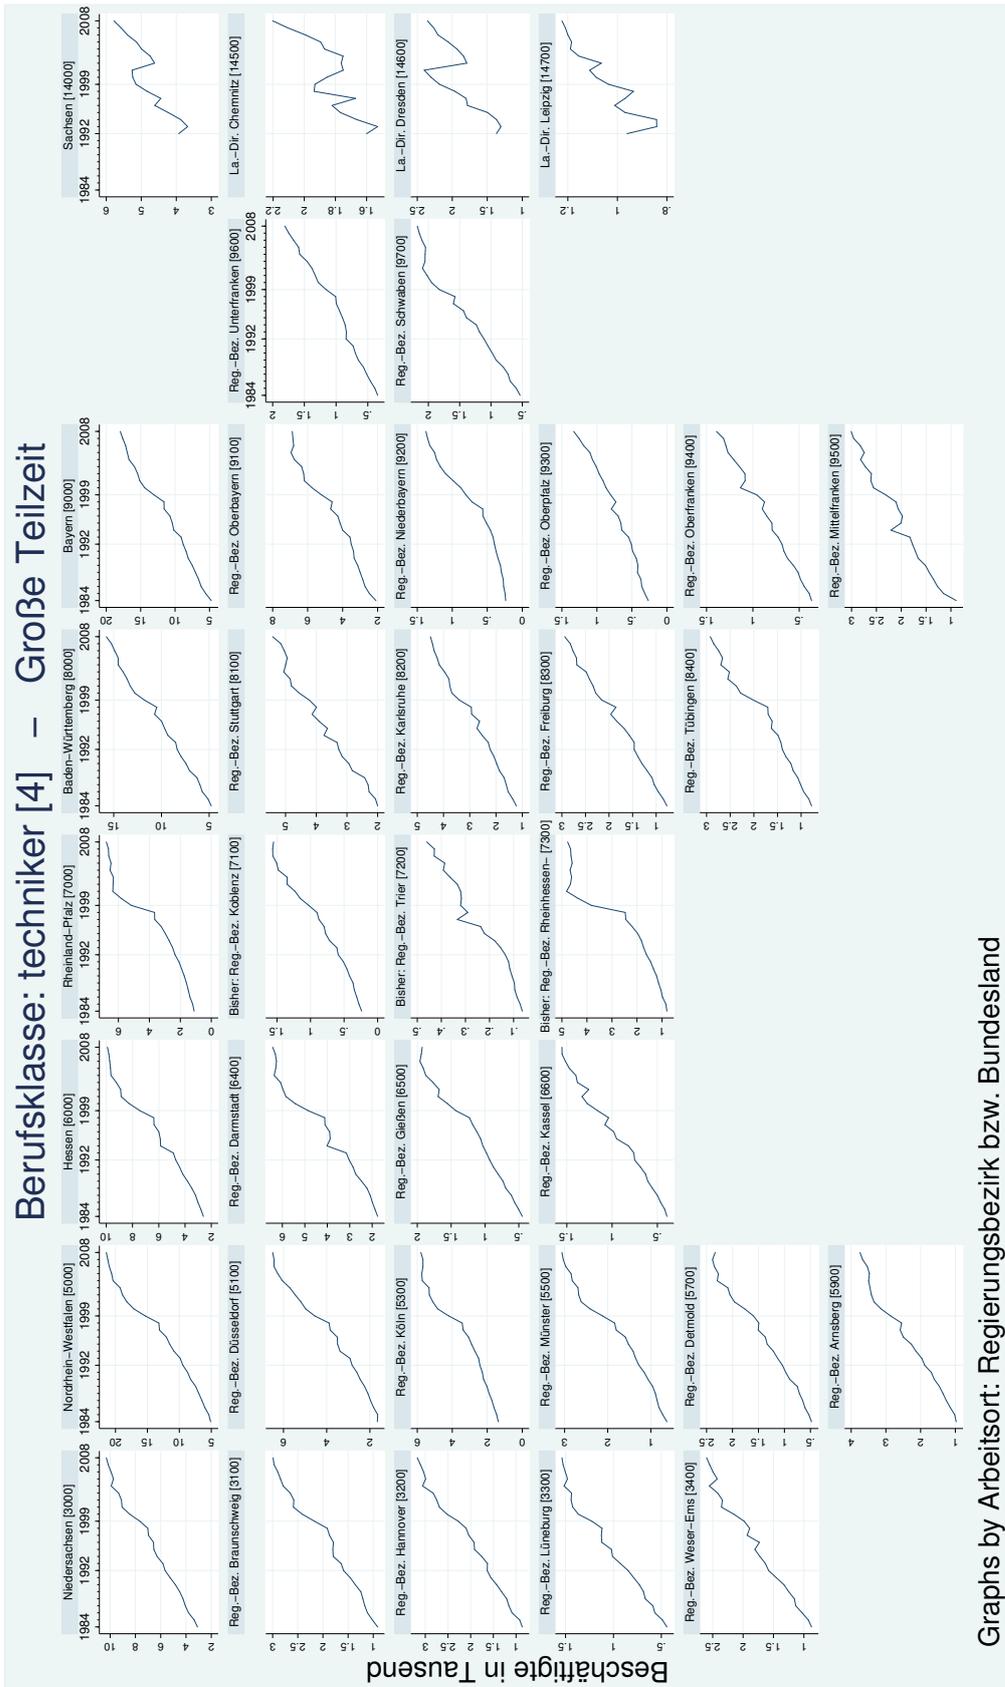


Abbildung A.62.: Anzahl Teilzeitbeschäftigte: Techniker je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-gtz.do

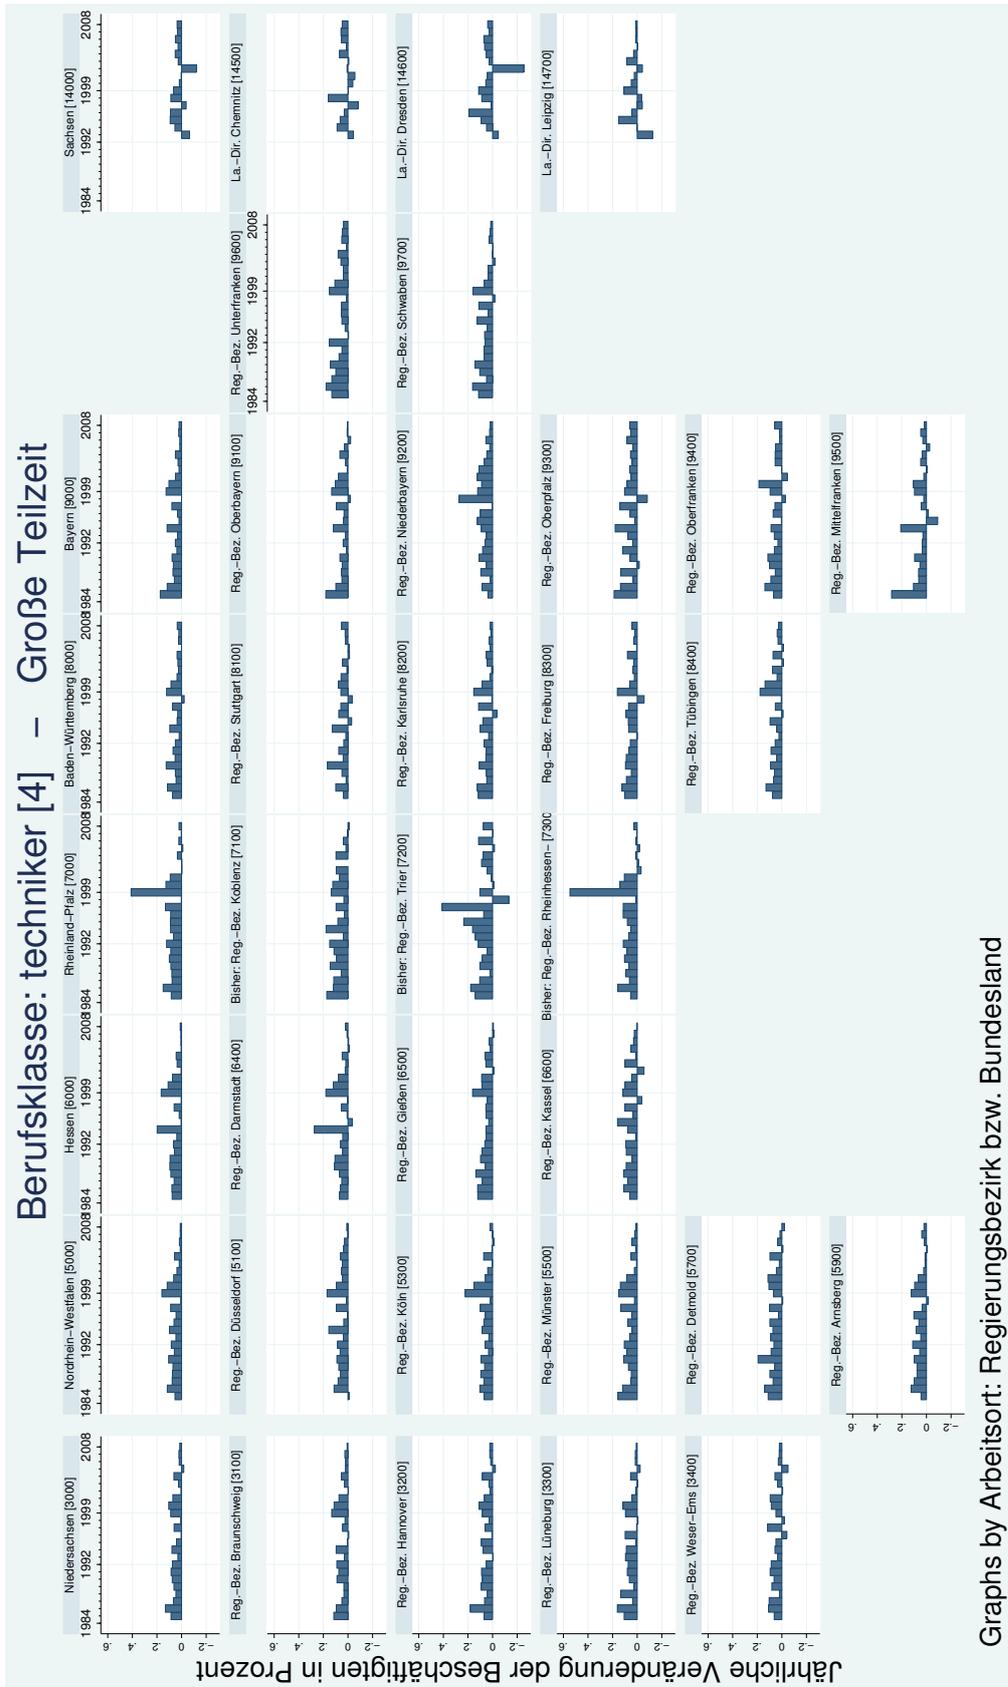
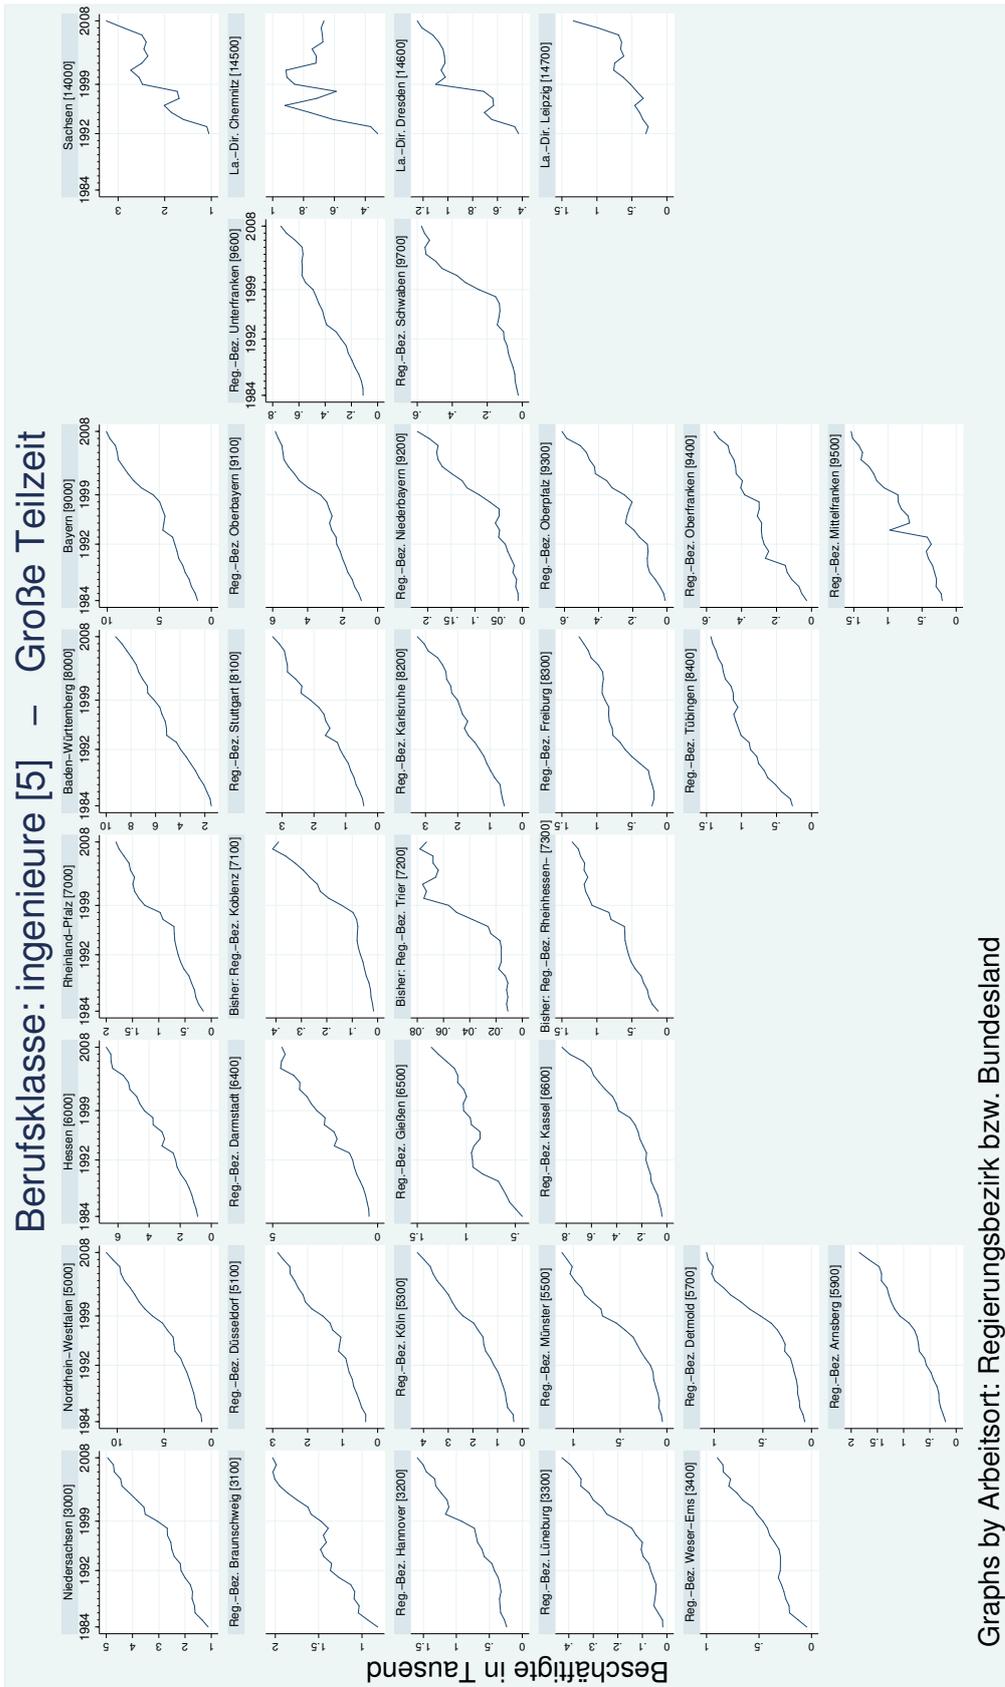


Abbildung A.63.: Jährliche Veränderung der Beschäftigung – Teilzeit: Techniker je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.64.: Anzahl Teilzeitbeschäftigte: Ingenieure je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoLand-regbez-bb-gtz.do

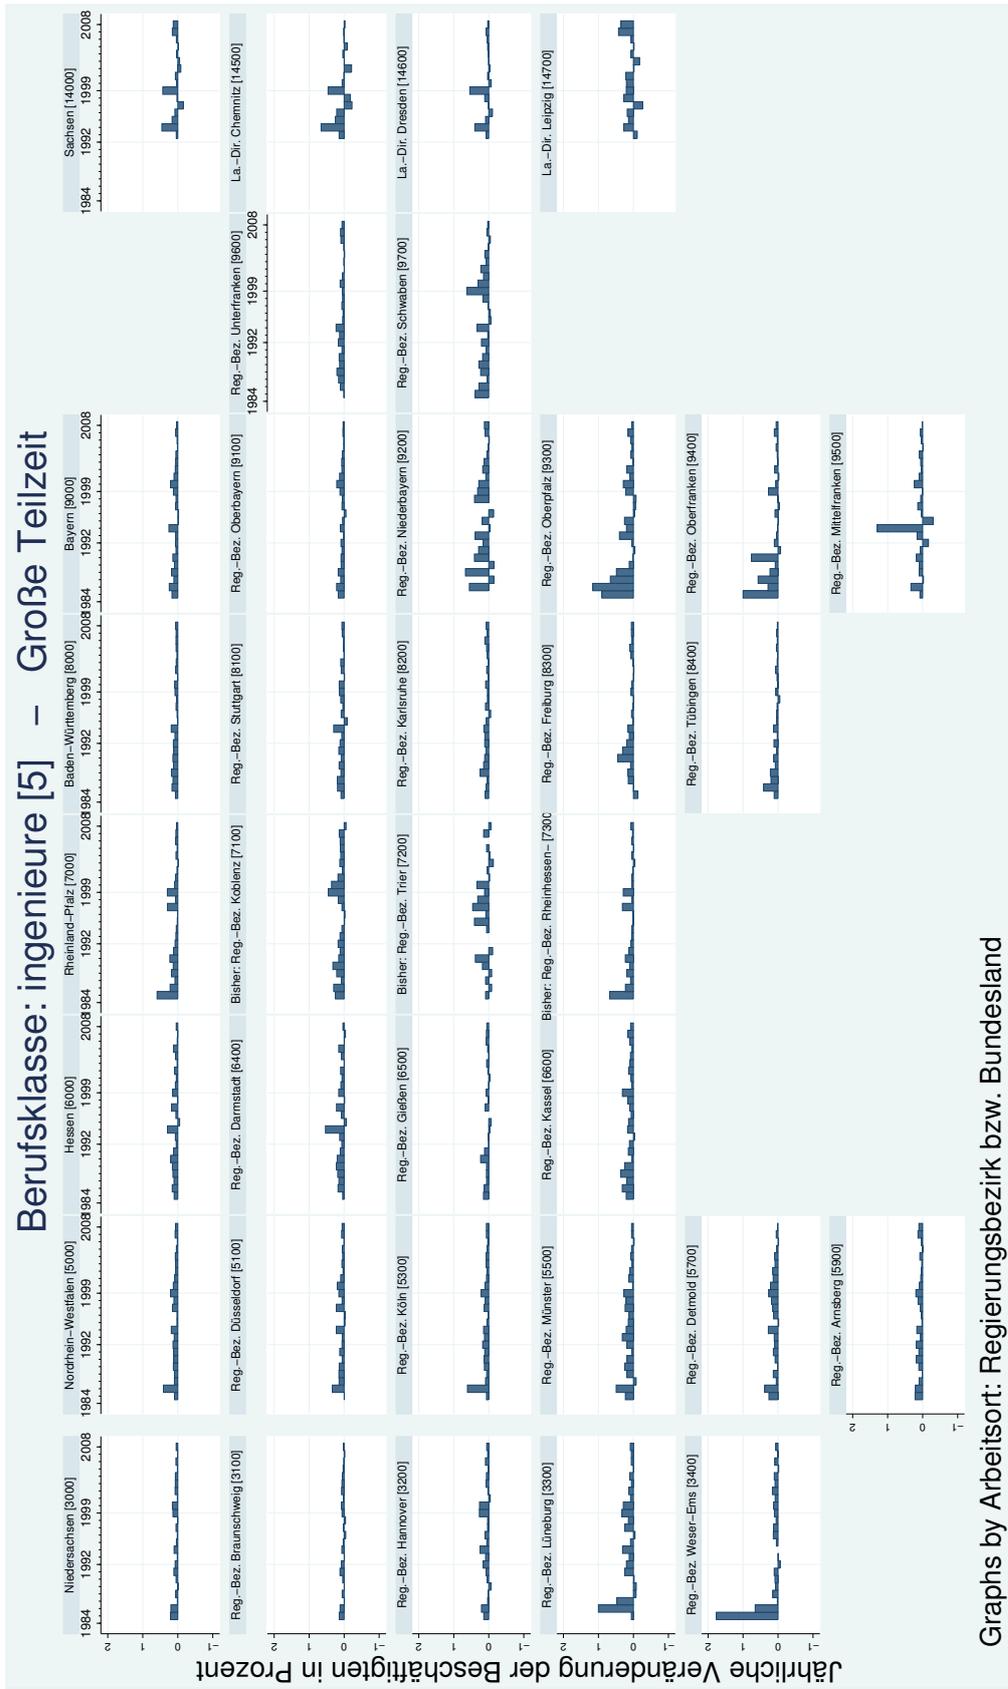


Abbildung A.65.: Jährliche Veränderung der Beschäftigung – Teilzeit: Ingenieure je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

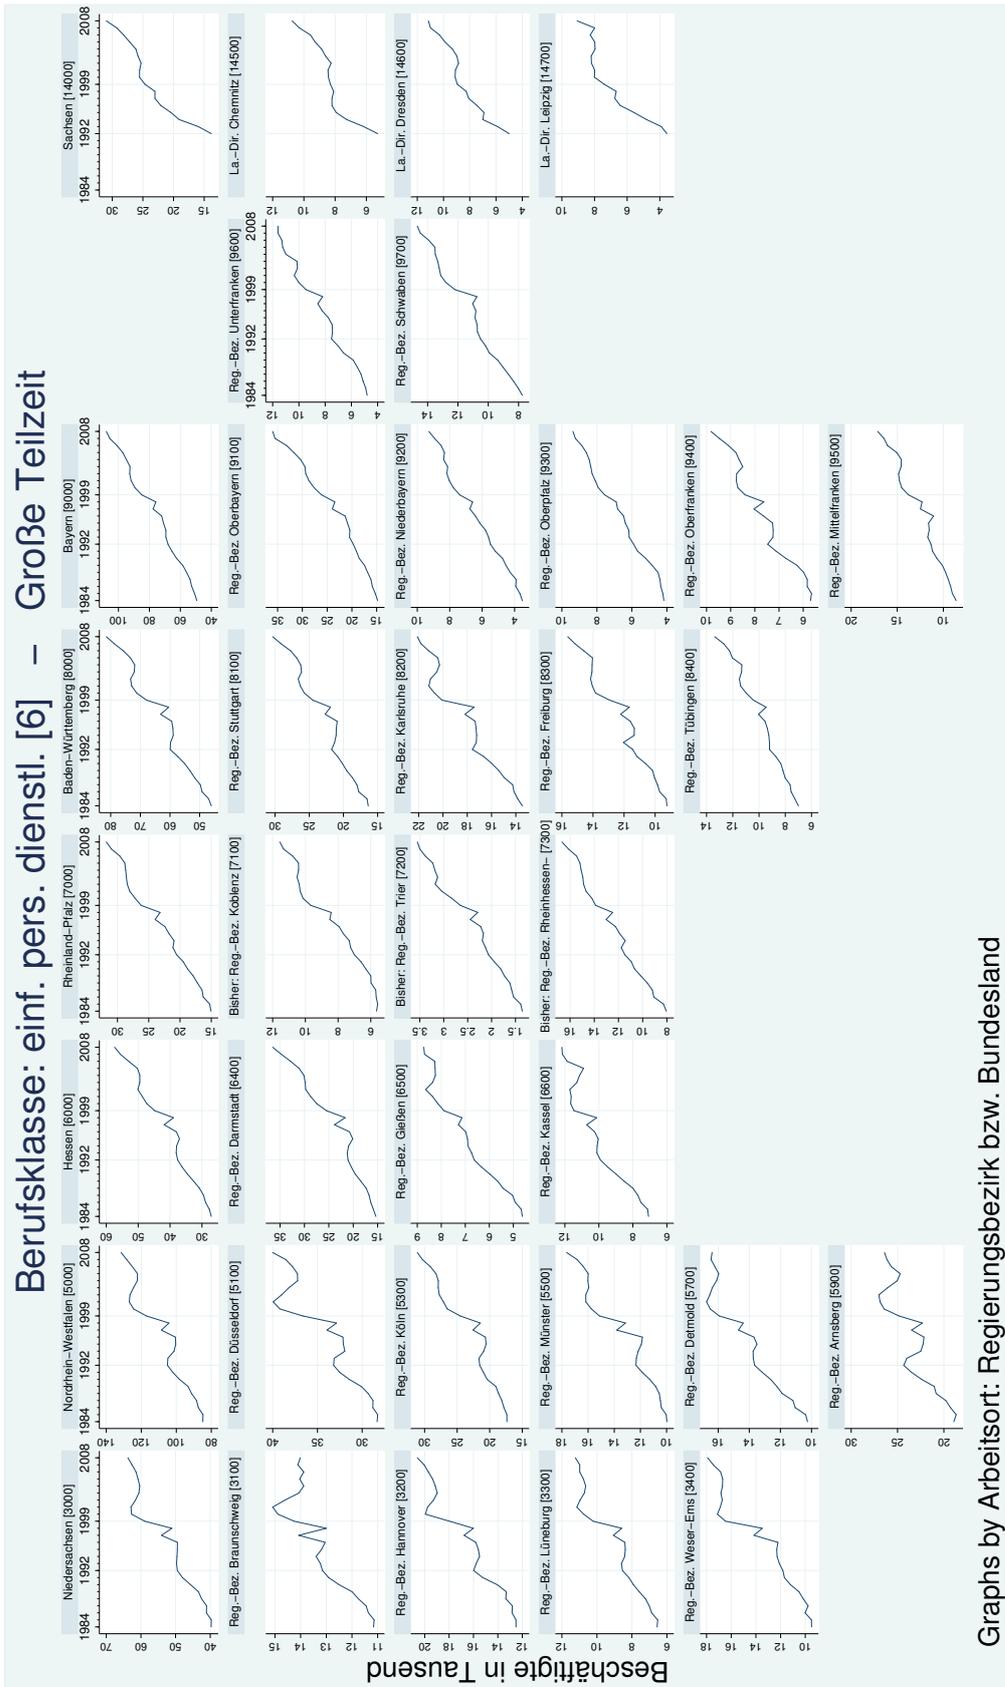


Abbildung A.66.: Anzahl Teilzeitbeschäftigte: Einfache pers. Dienstl. je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-zR-aoLand-regbez-bb-gtz.do`

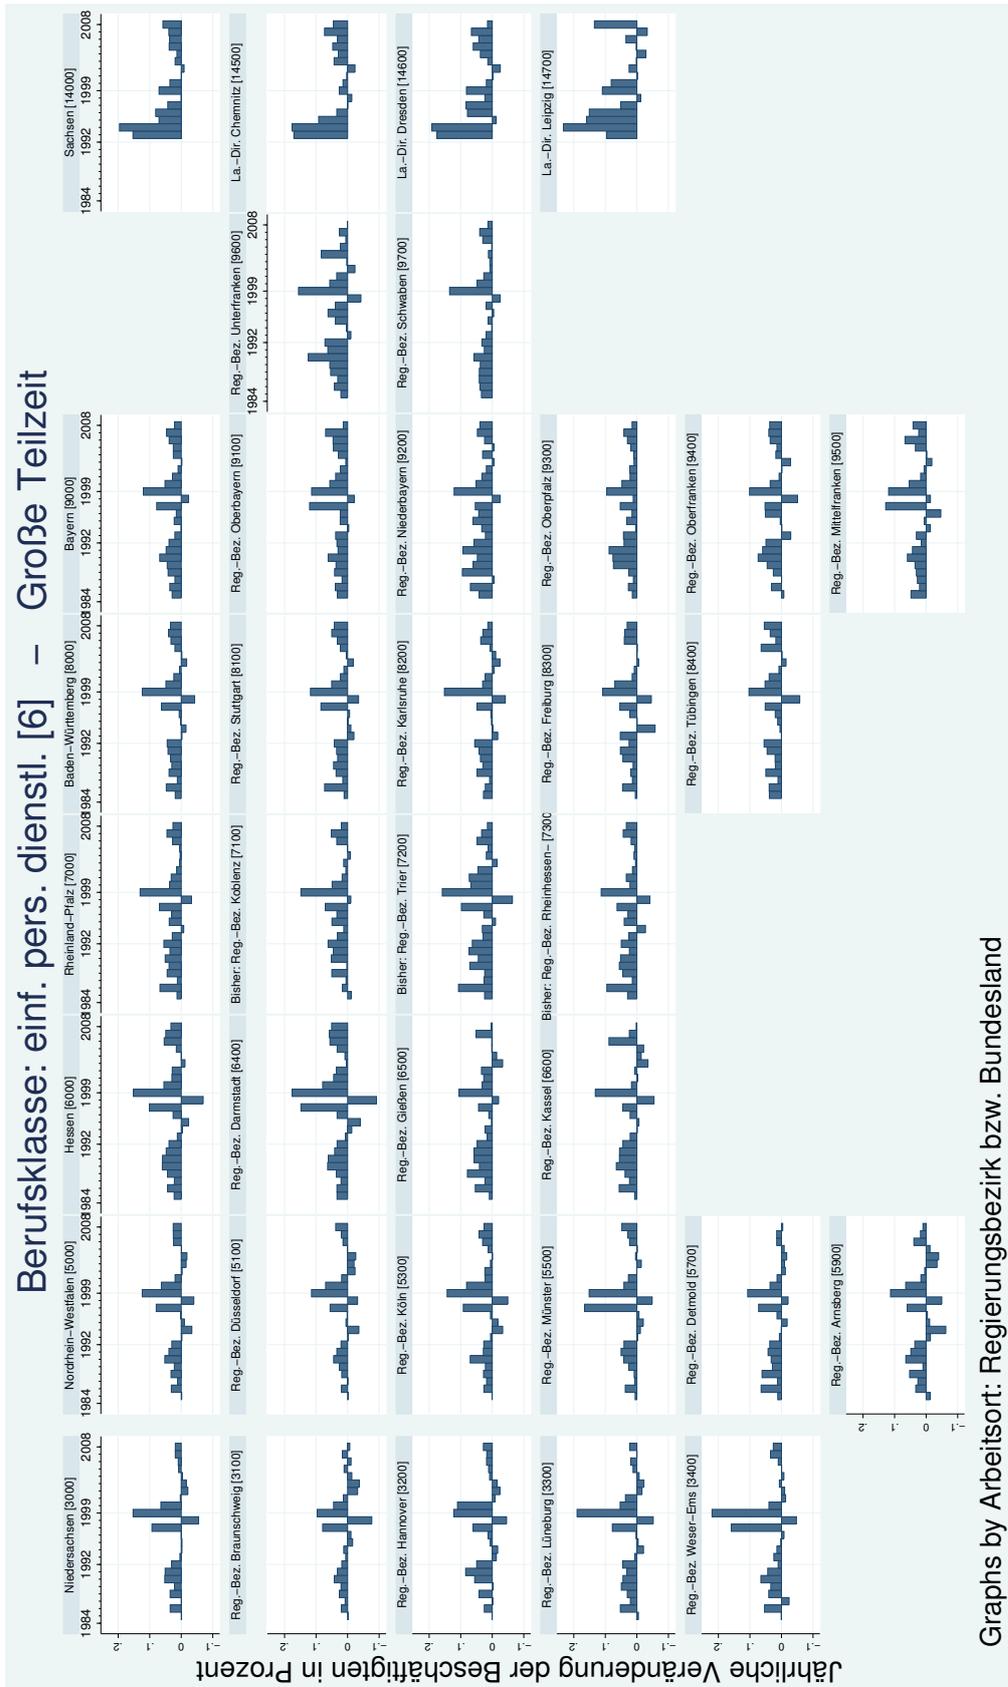


Abbildung A.67.: Jährliche Veränderung der Beschäftigung – Teilzeit: Einfache pers. Dienstl. je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

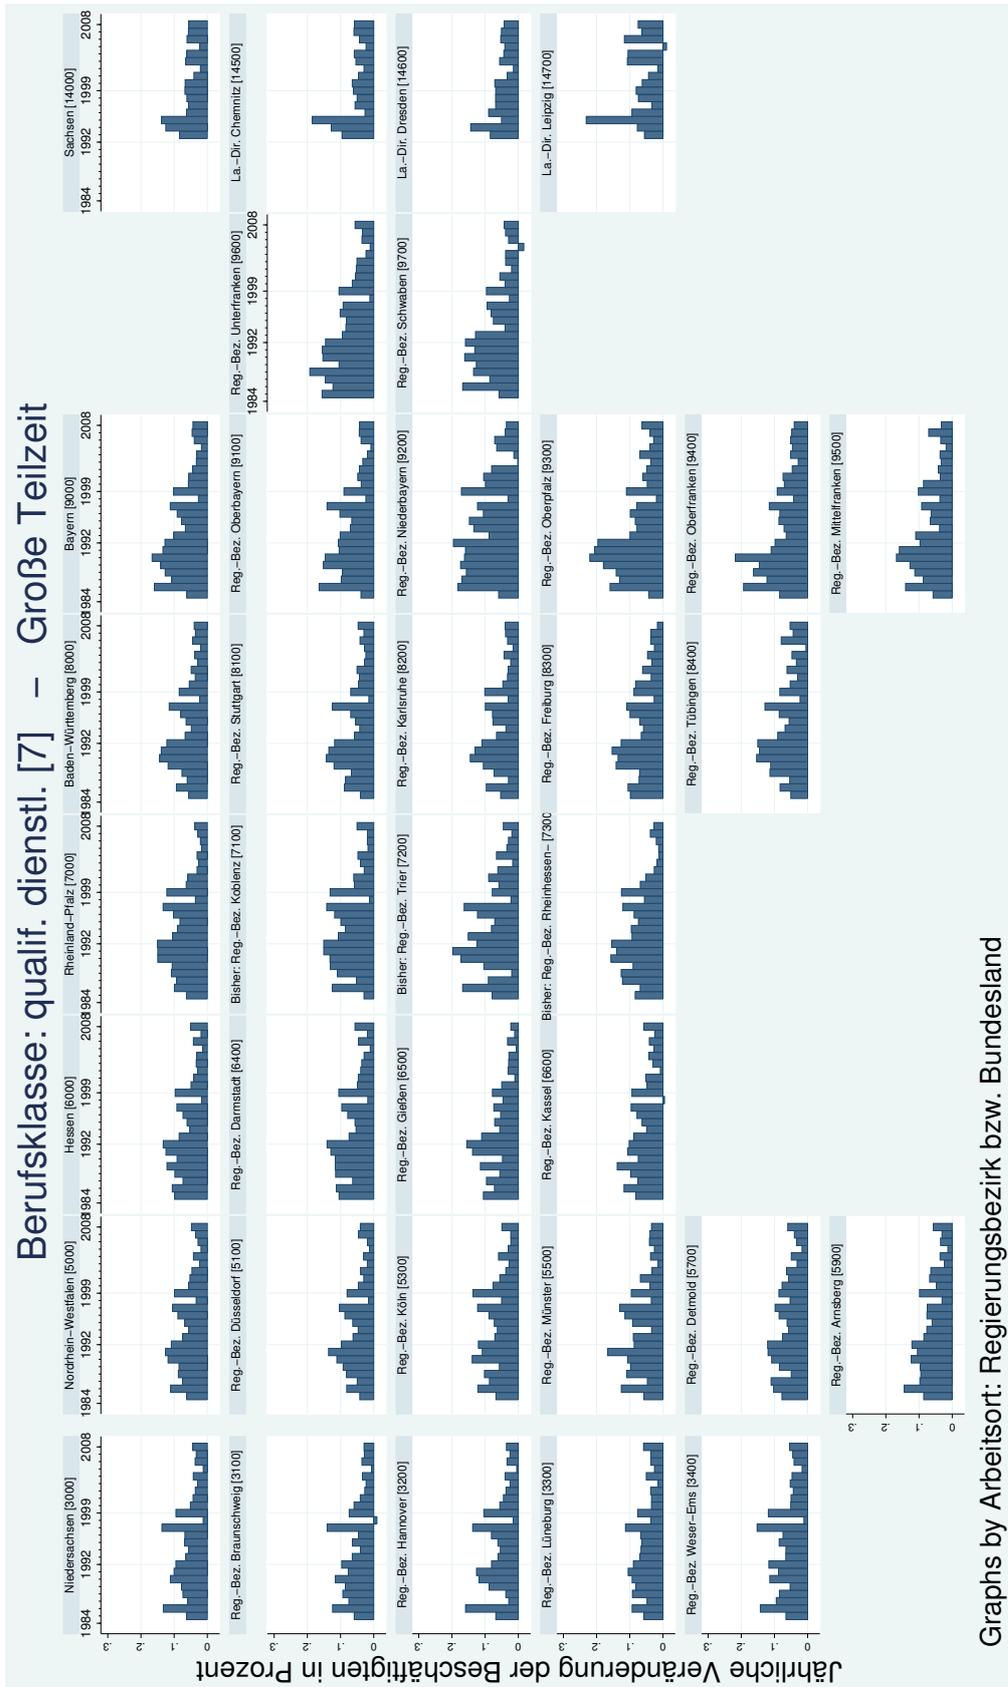


Abbildung A.69.: Jährliche Veränderung der Beschäftigung – Teilzeit: Qualifizierte Dienstl. je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

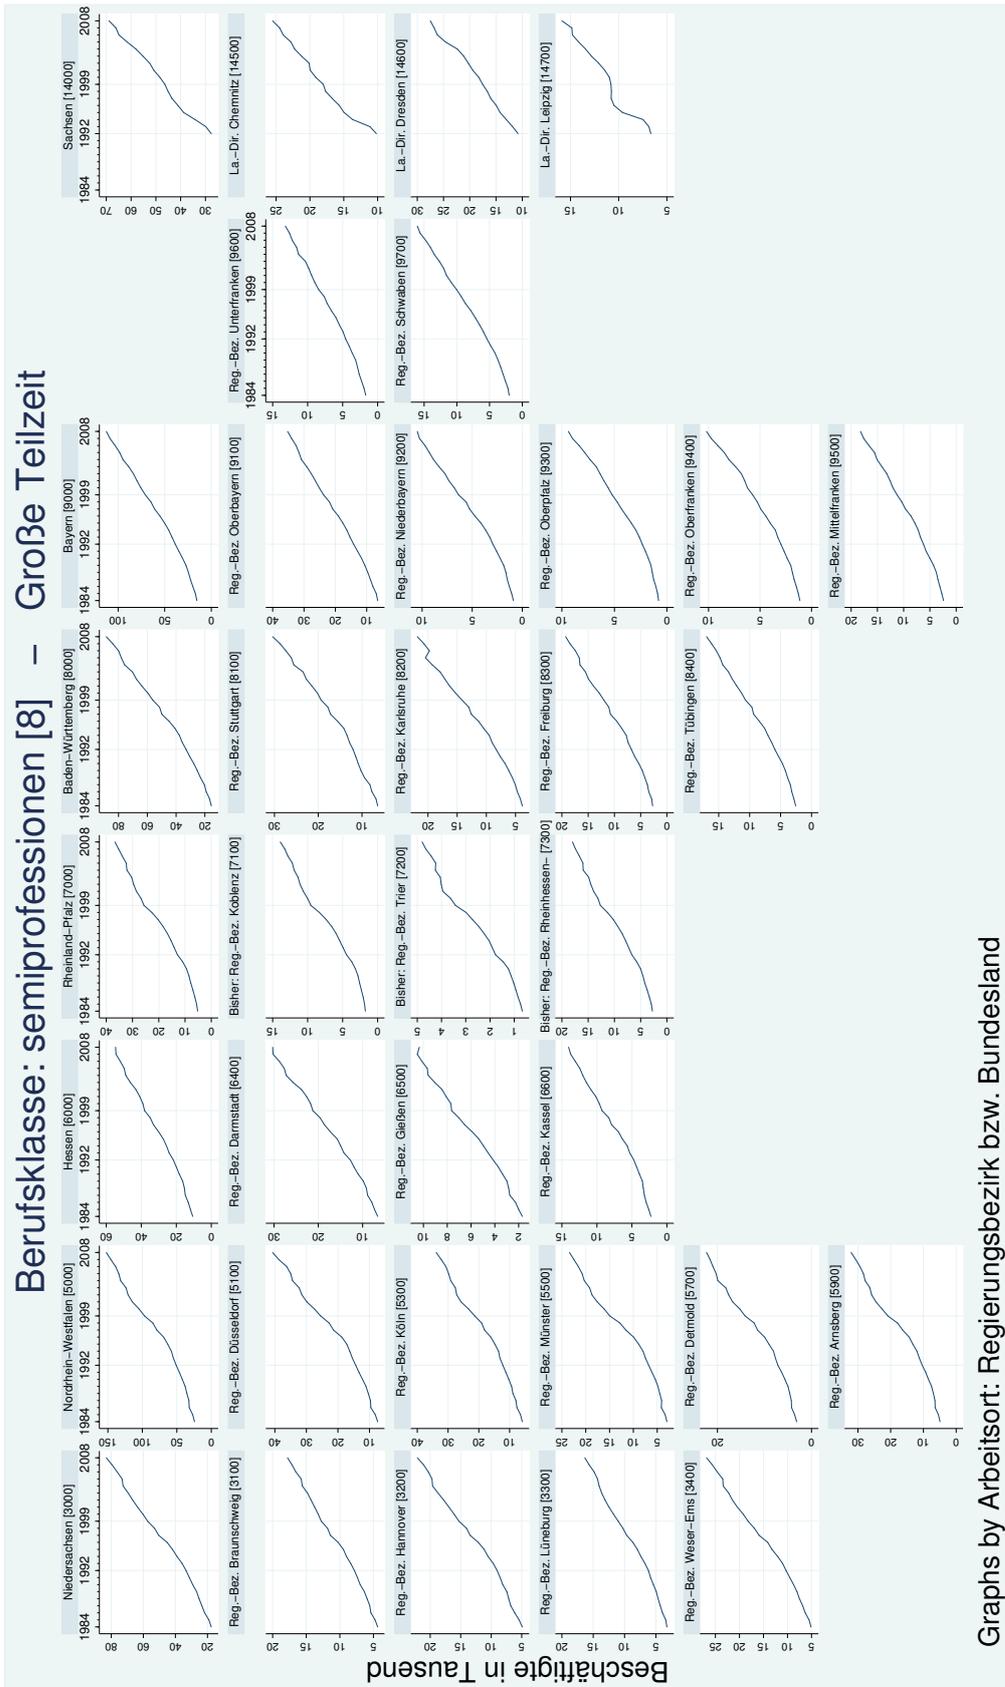


Abbildung A.70.: Anzahl Teilzeitbeschäftigte: Semiprofessionellen je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-gtz.d.o

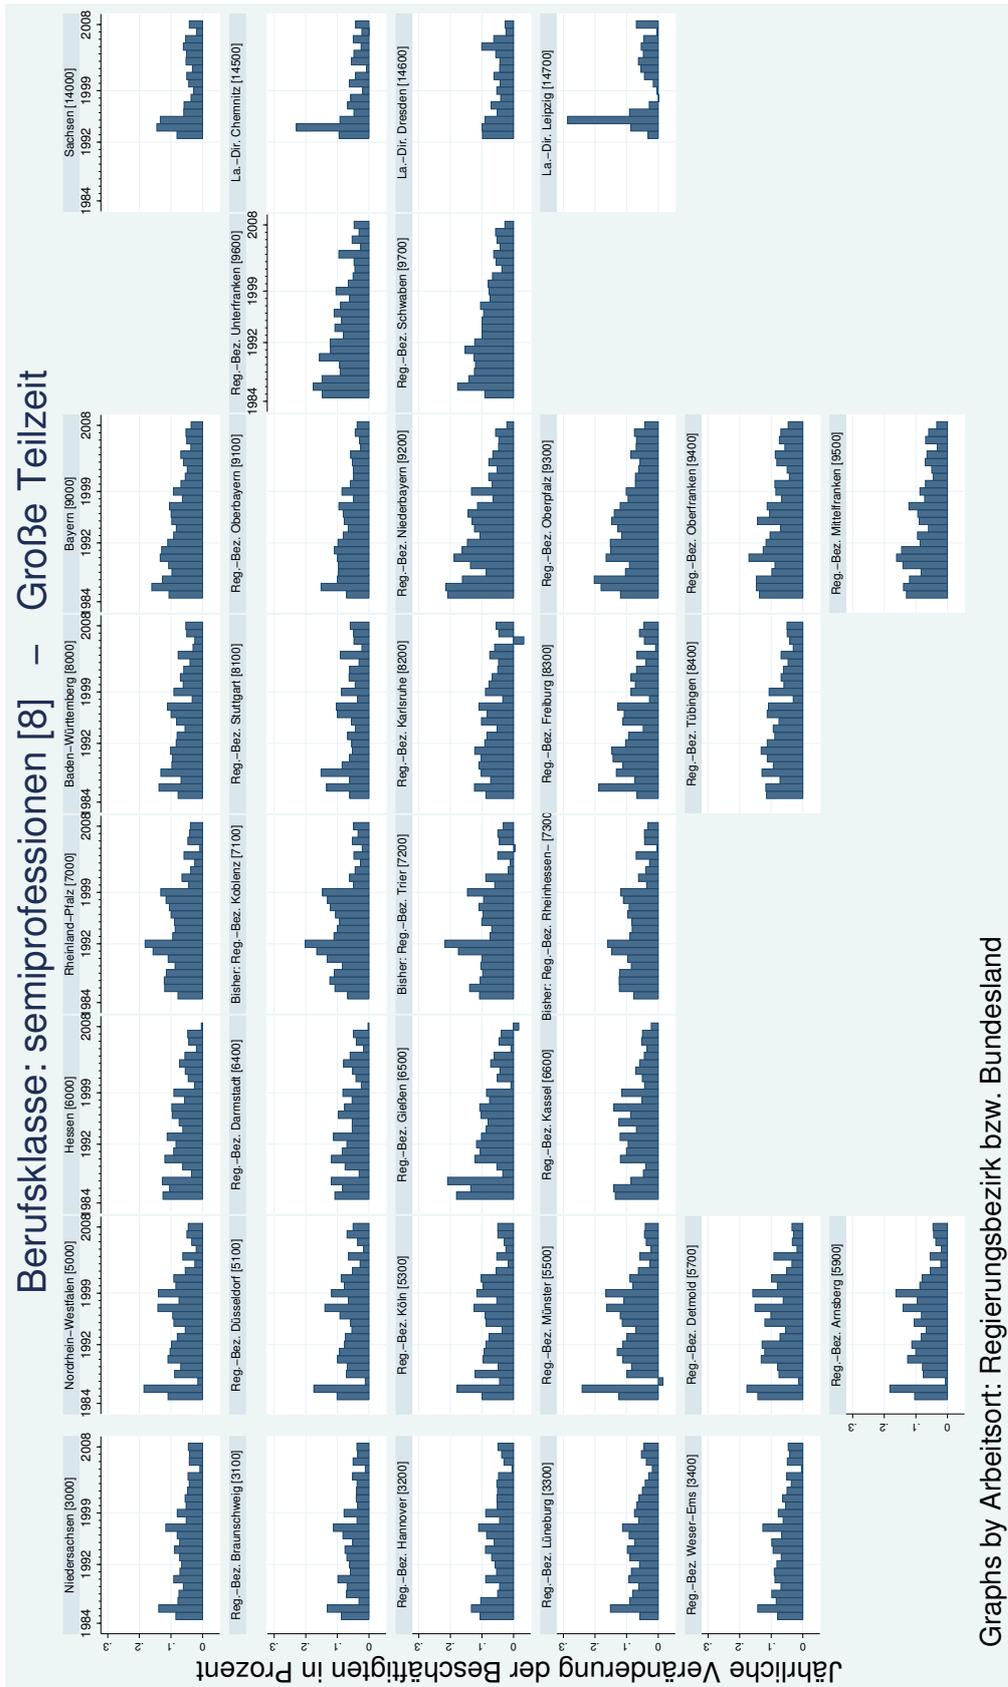


Abbildung A.71.: Jährliche Veränderung der Beschäftigung – Teilzeit: Semiprofessionen je Regierungsbezirk
 Grafik erstellt mit plot-change-ZR-aoland-regbez-bb-gtz.do

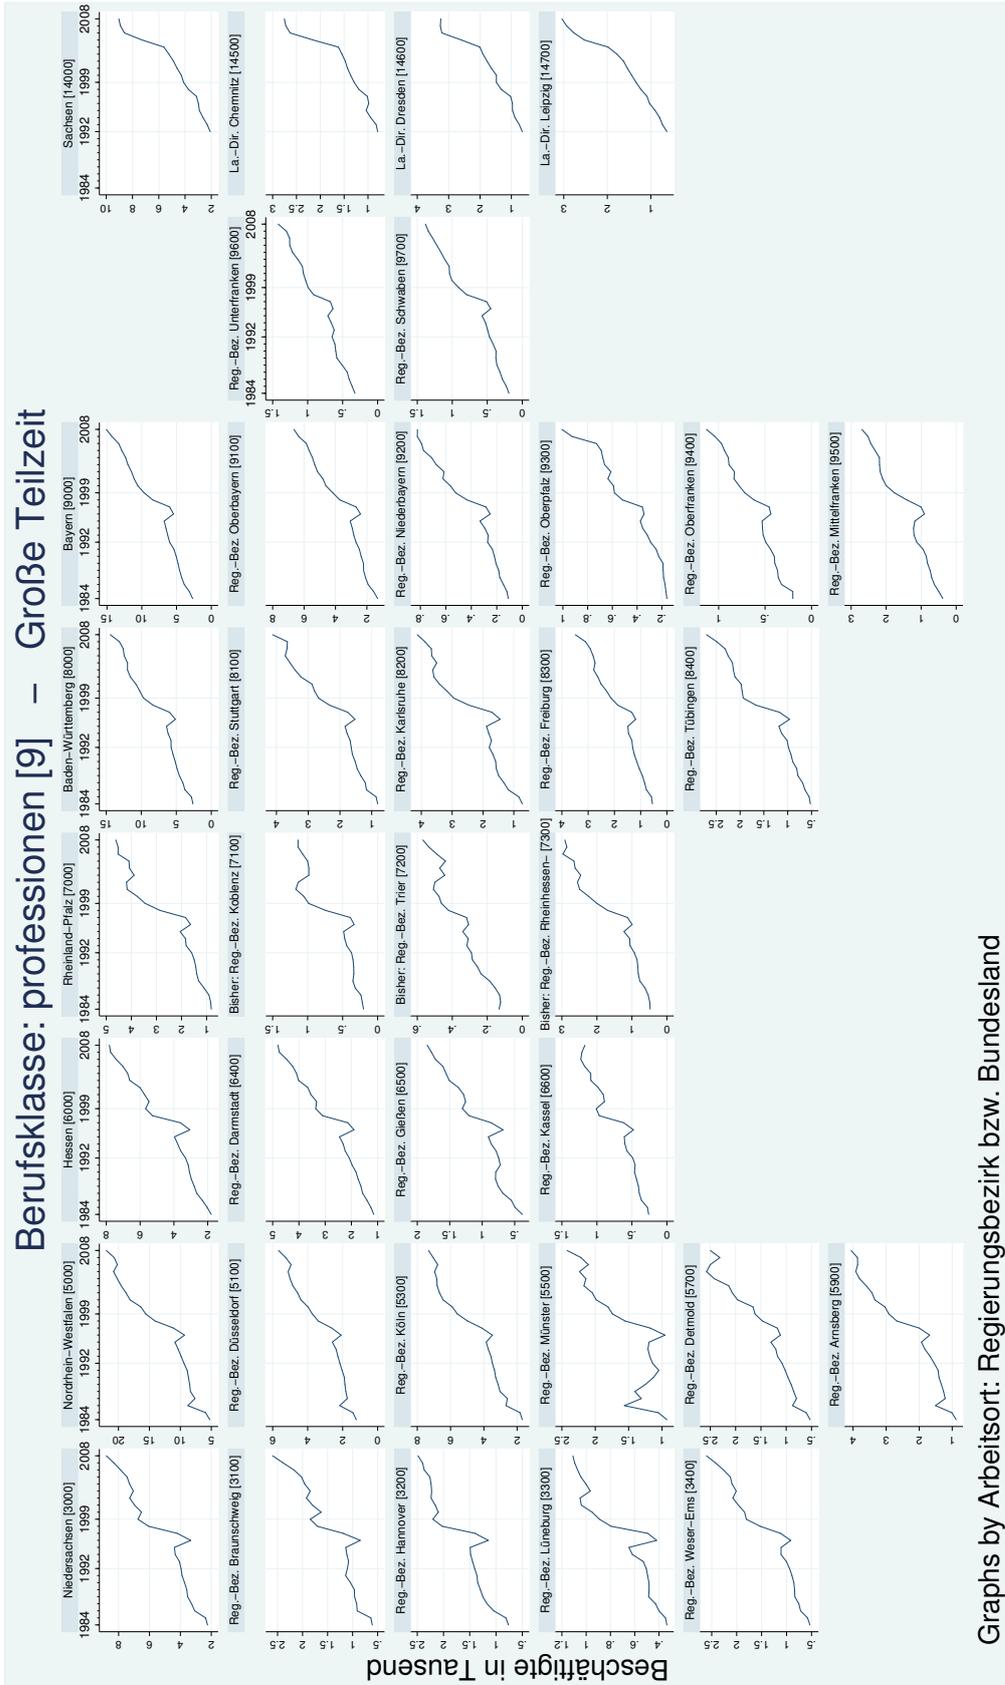


Abbildung A.72.: Anzahl Teilzeitbeschäftigte: Professionen je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aoLand-regbez-bb-gtz.do`

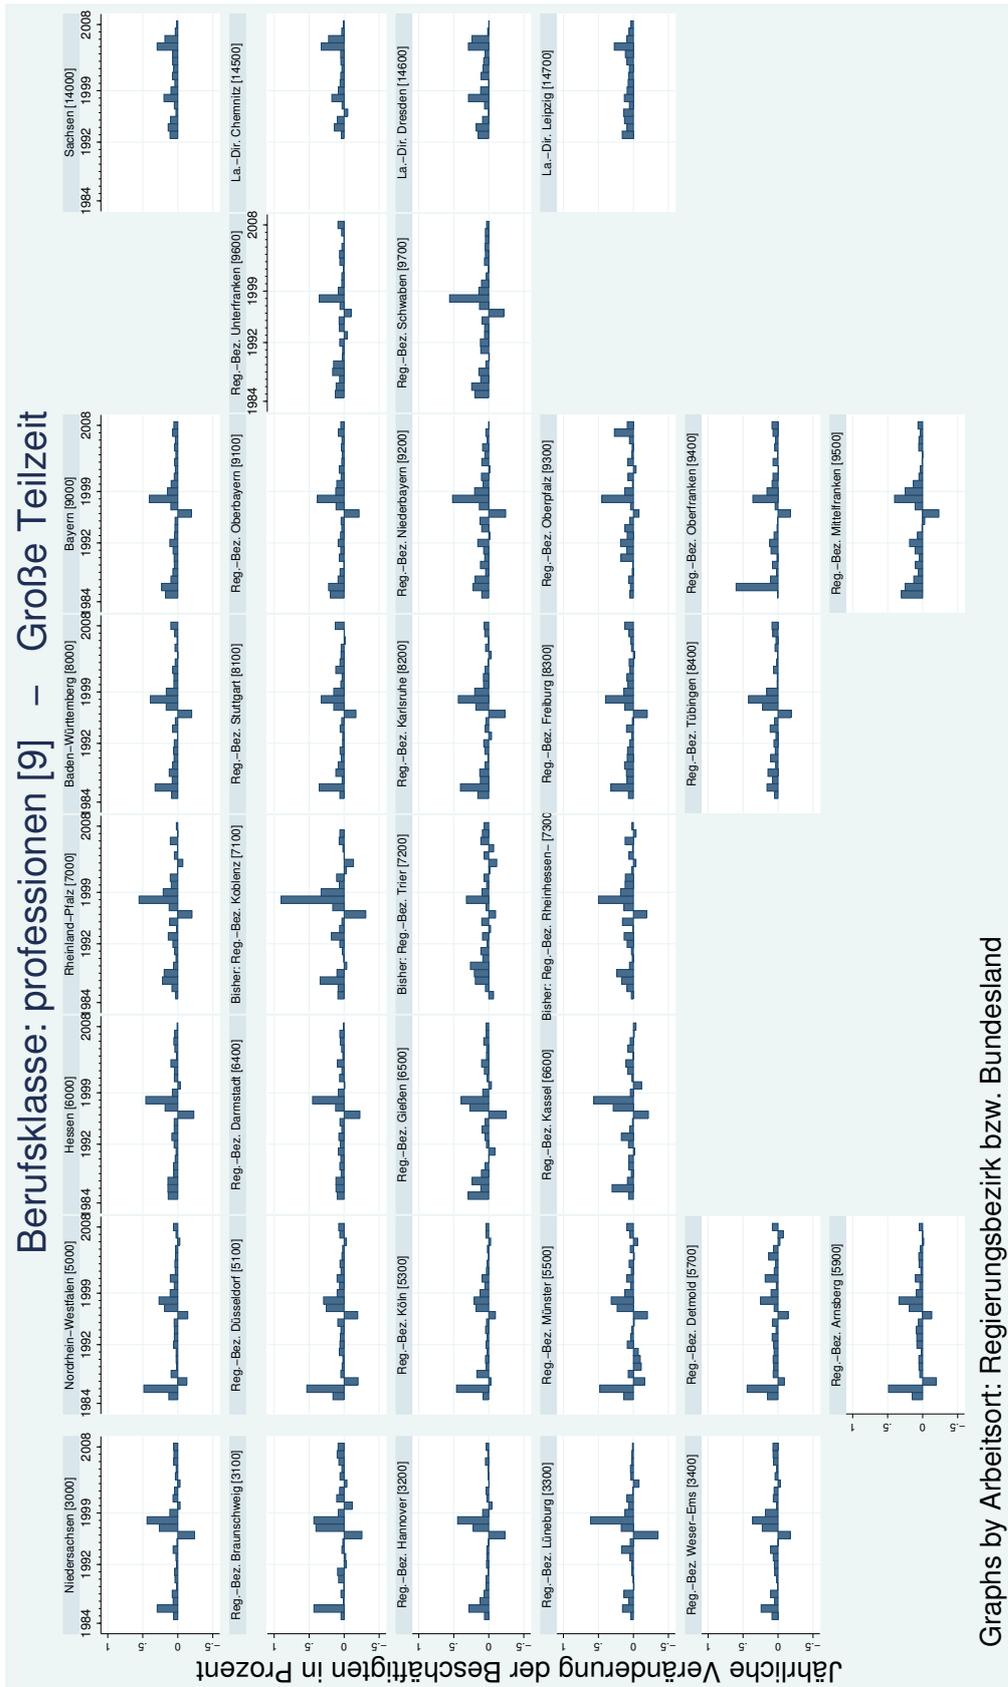


Abbildung A.73.: Jährliche Veränderung der Beschäftigung – Teilzeit: Professionen je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

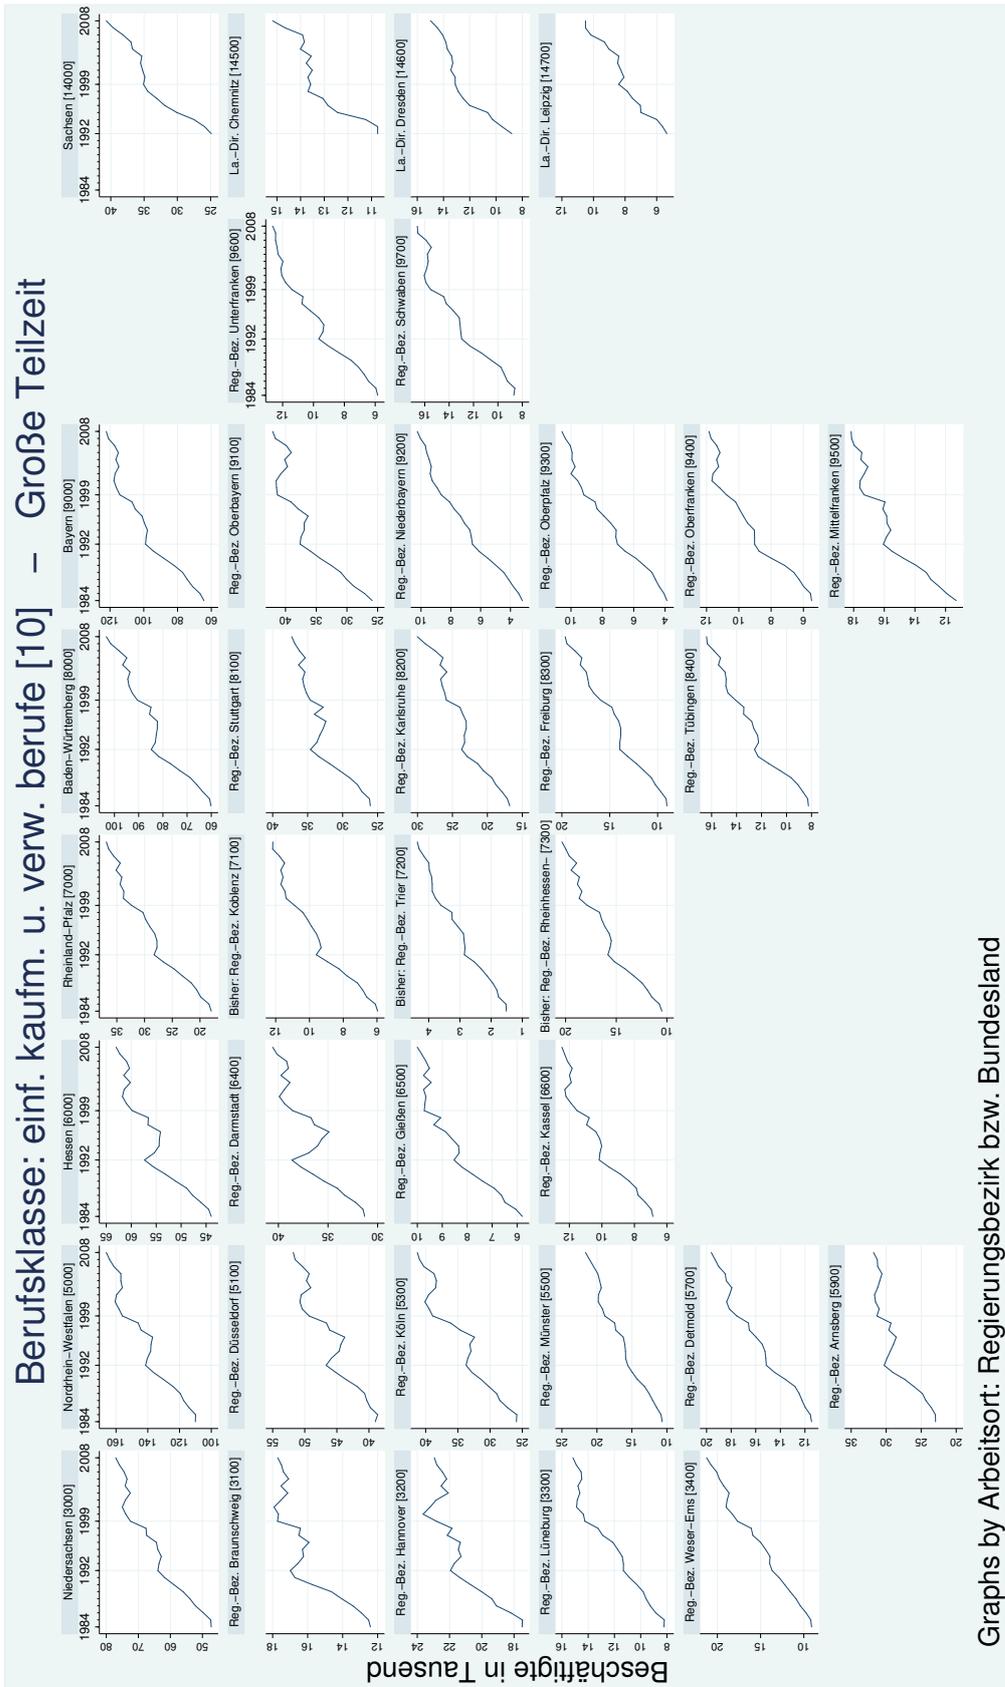


Abbildung A.74.: Anzahl Teilzeitbeschäftigte: Einf. kaufm. u. verw. Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-gtz.do




Abbildung A.75.: Jährliche Veränderung der Beschäftigung – Teilzeit: Einf. kaufm. u. verw. Berufe je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

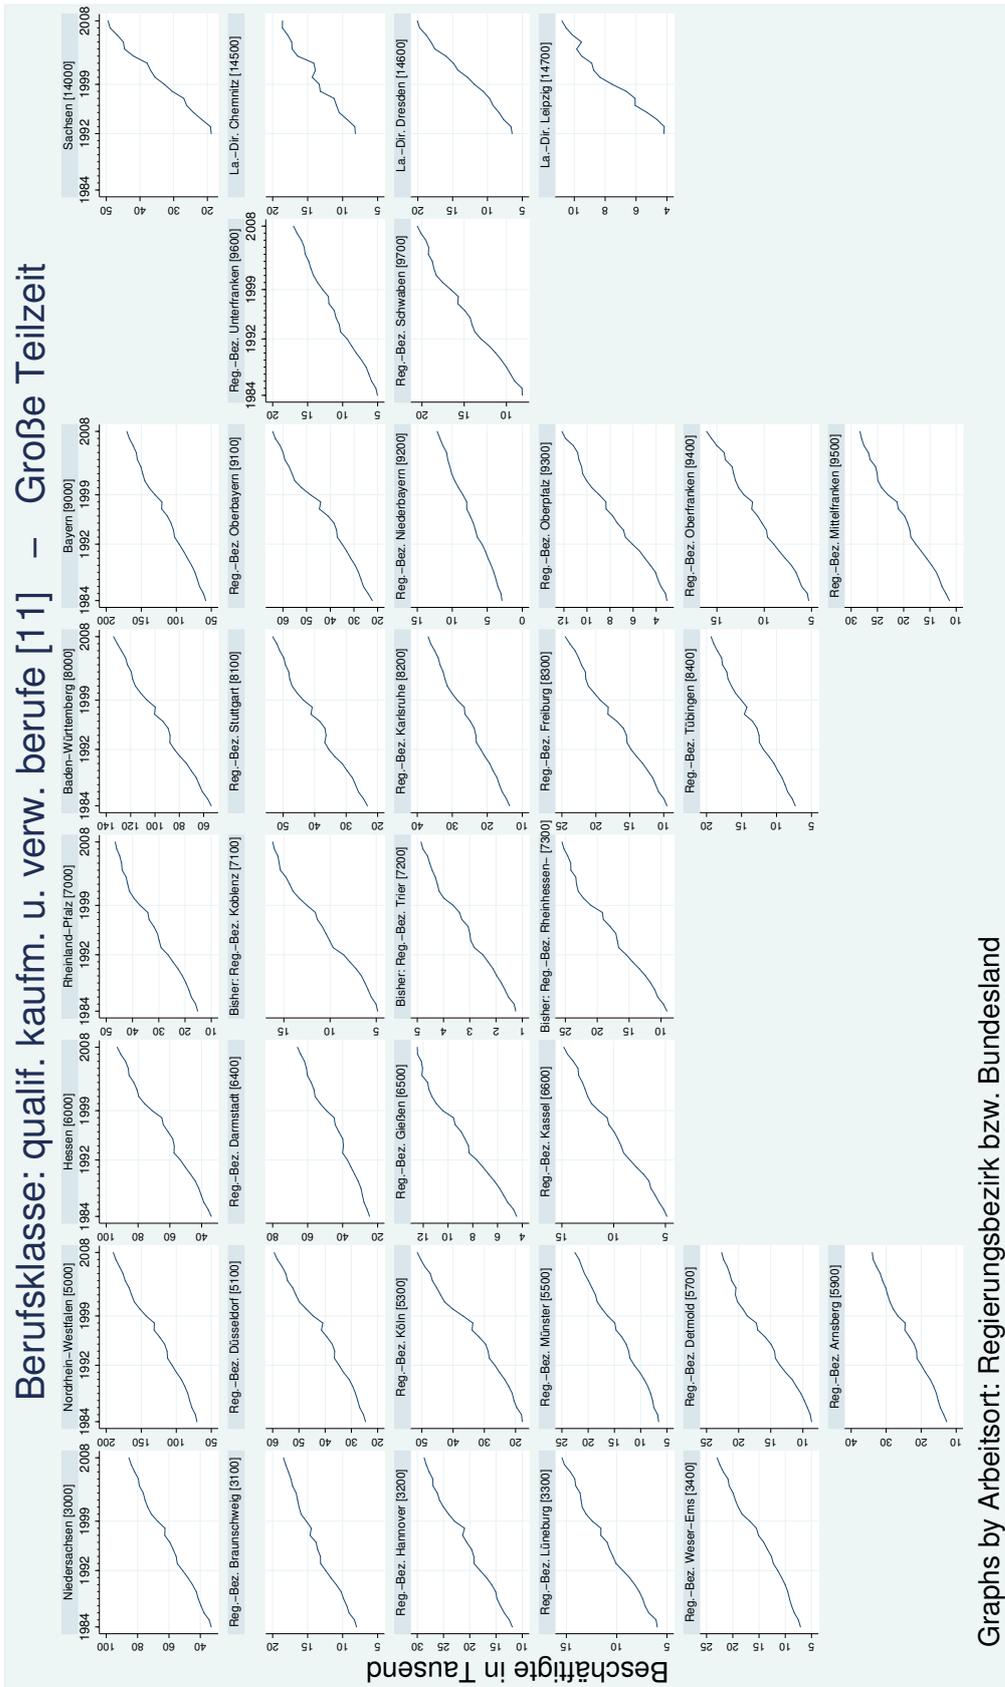


Abbildung A.76.: Anzahl Teilzeitbeschäftigte: Quali. kaufm. u. verw. Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit `plot-ZR-aoIand-regbez-bb-gtz.do`

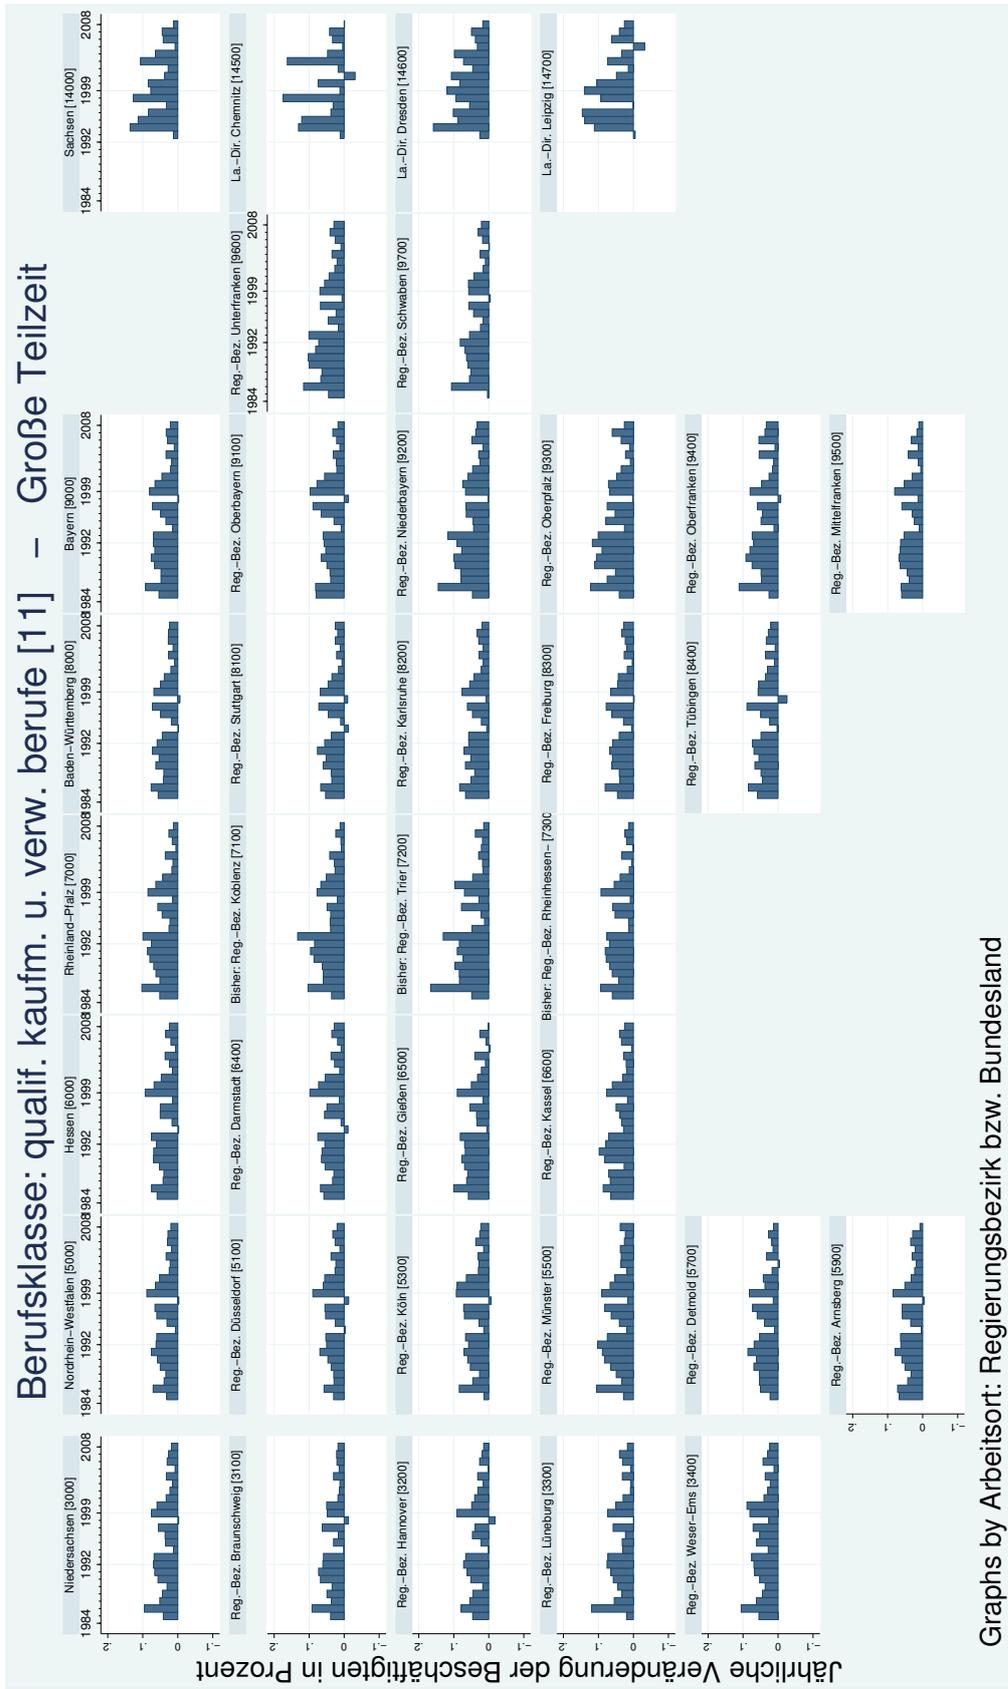
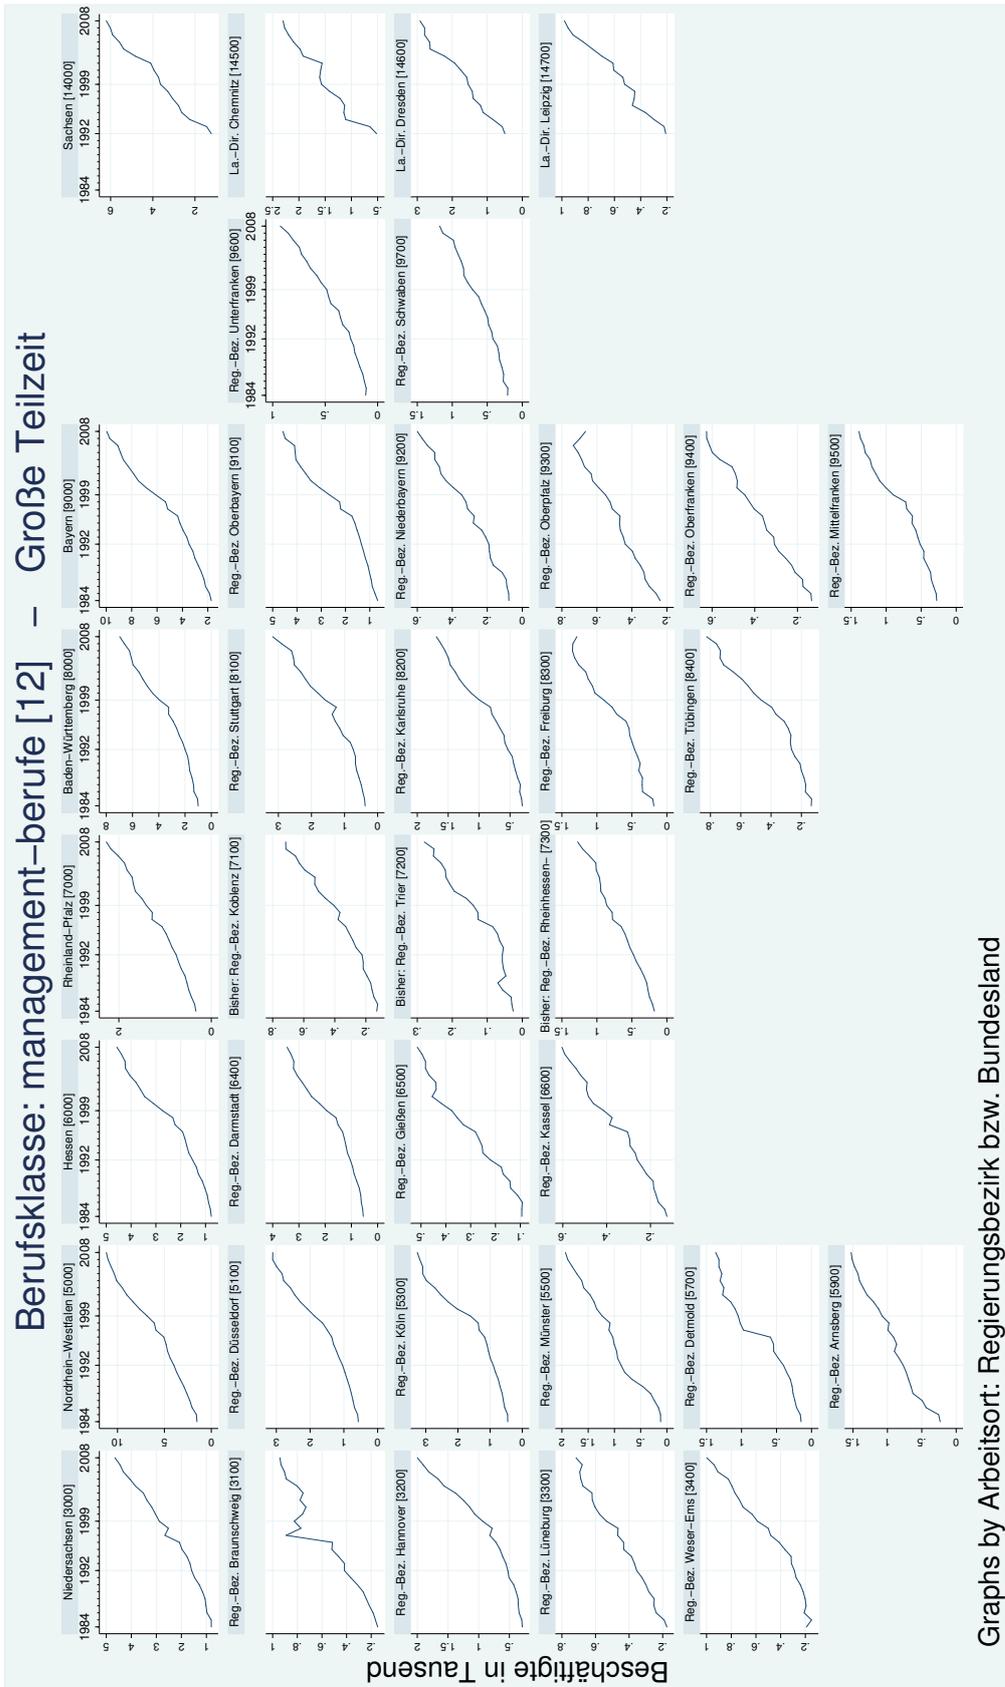


Abbildung A.77.: Jährliche Veränderung der Beschäftigung – Teilzeit: Quali. kaufm. u. verw. Berufe je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`



Graphs by Arbeitsort: Regierungsbezirk bzw. Bundesland

Abbildung A.78.: Anzahl Teilzeitbeschäftigte: Management Berufe je Regierungsbezirk (individuelle Skalen)
 Grafik erstellt mit plot-ZR-aoIand-regbez-bb-gtz.do



Abbildung A.79.: Jährliche Veränderung der Beschäftigung – Teilzeit: Management Berufe je Regierungsbezirk
 Grafik erstellt mit `plot-change-ZR-aoland-regbez-bb-gtz.do`

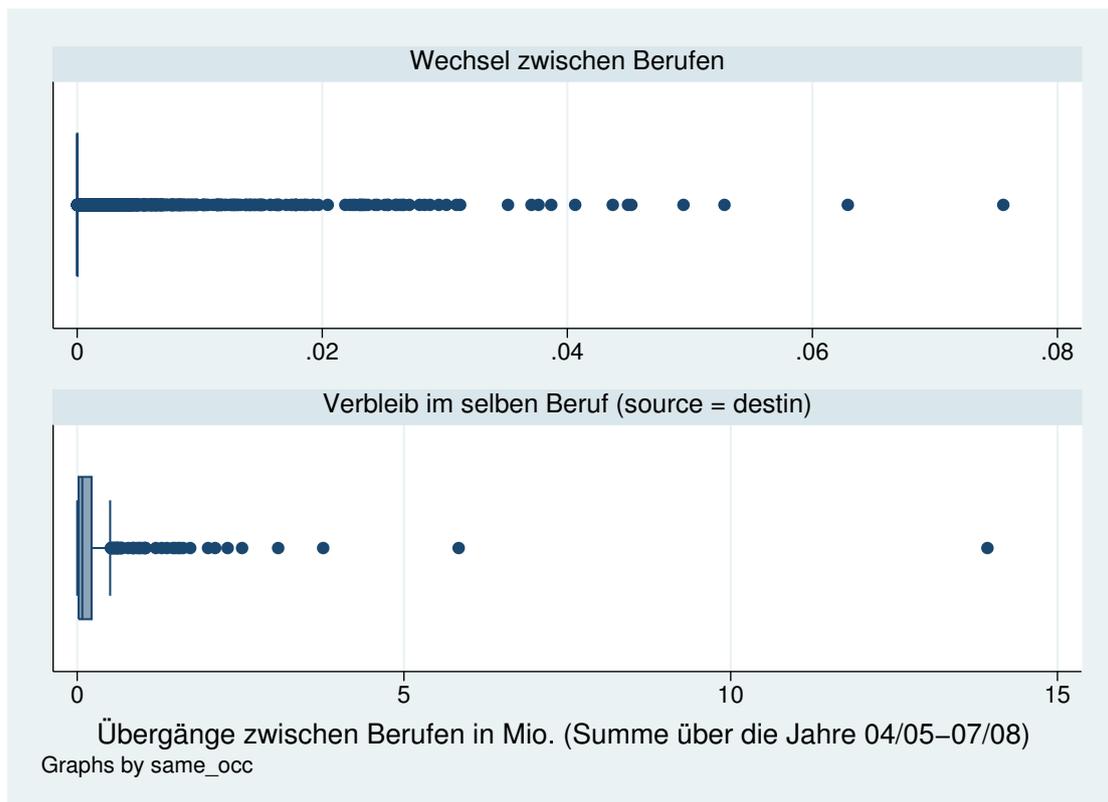


Abbildung A.80.: Boxplot der paarweisen Übergangszahlen zwischen den Berufen auf Ebene der 3-Steller

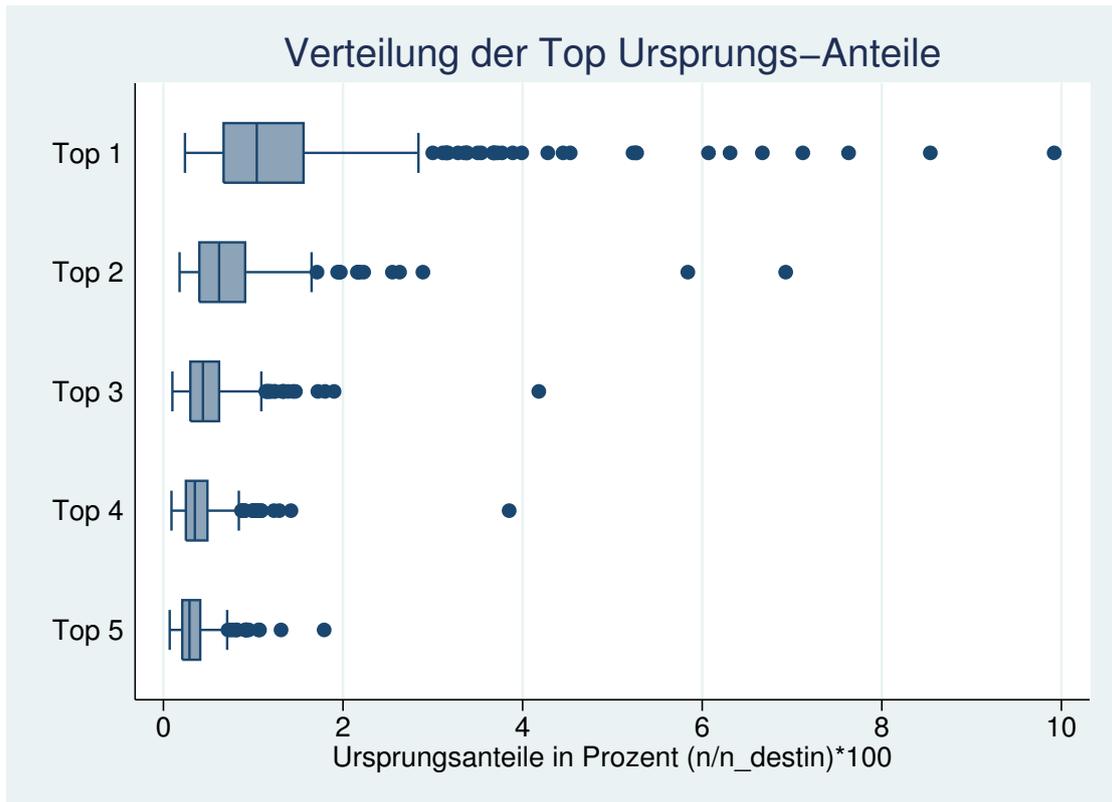


Abbildung A.81.: Verteilungen der Top 1 - Top 5 Ursprungsanteile

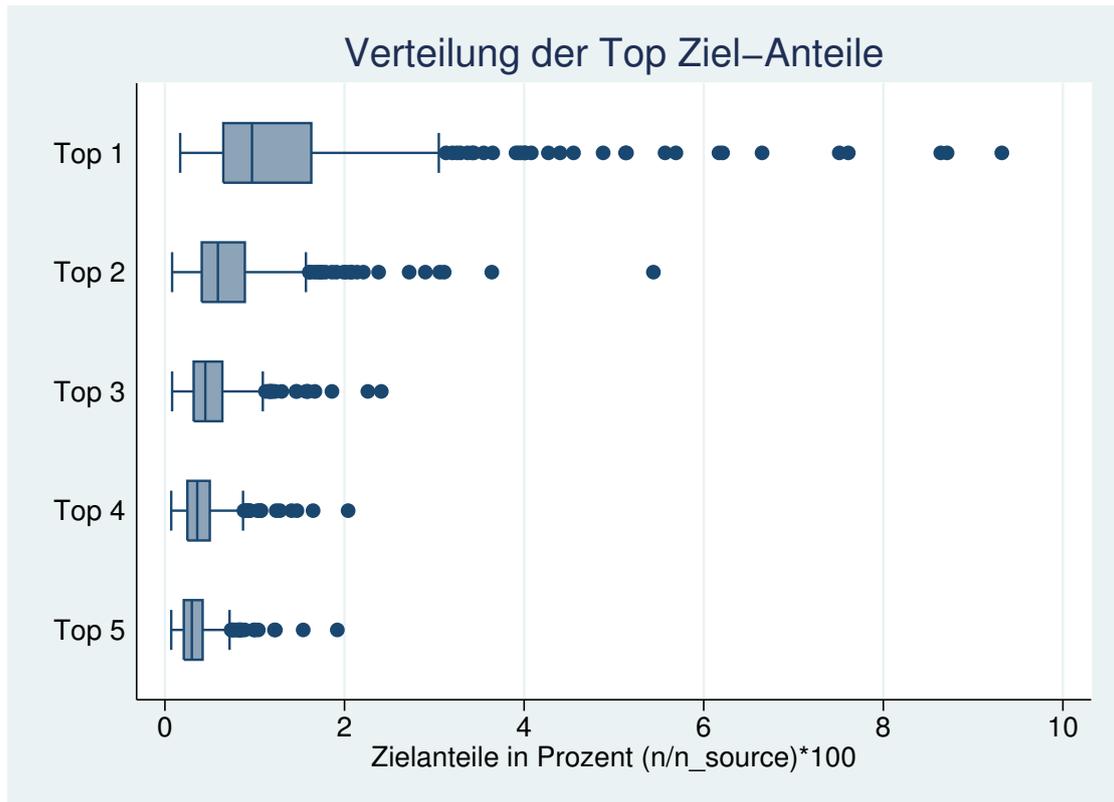


Abbildung A.82.: Verteilungen der Top 1 - Top 5 Zielanteile

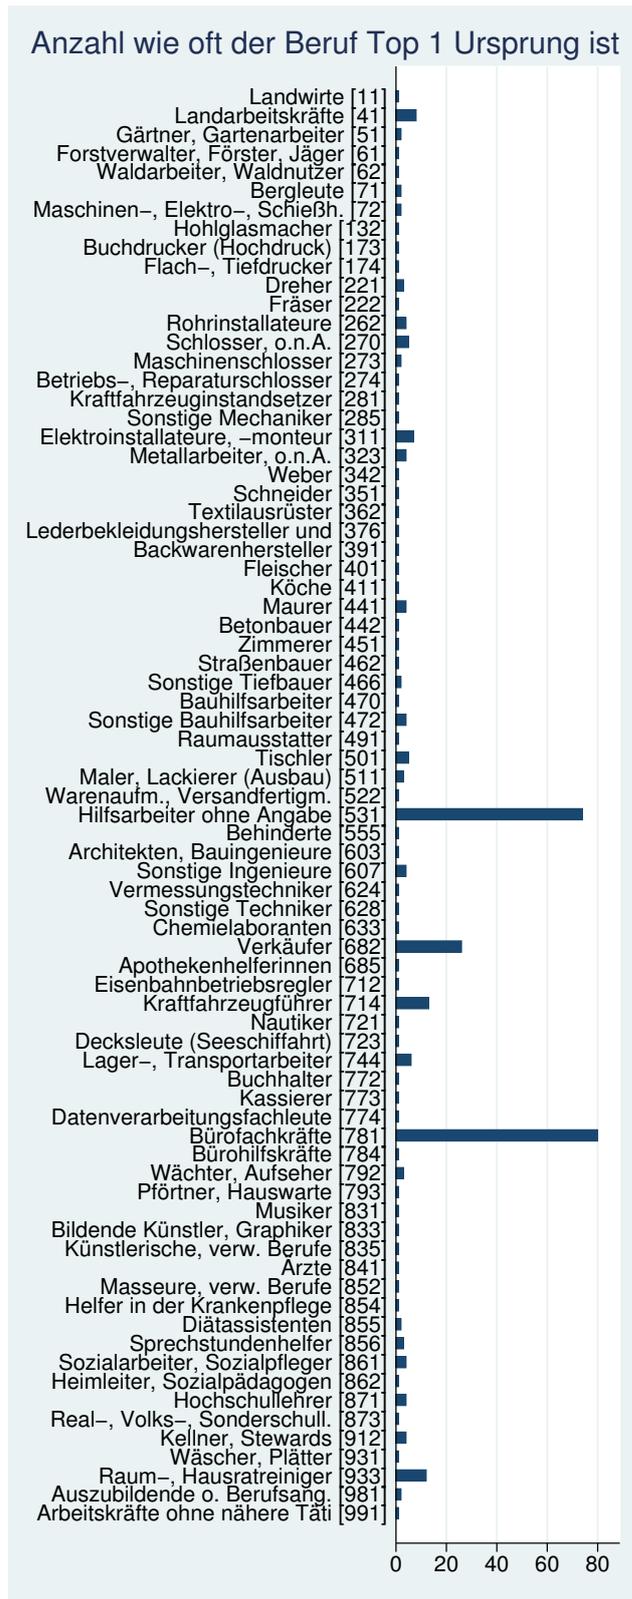


Abbildung A.83.: Top Ursprungsberufe

A. Appendix

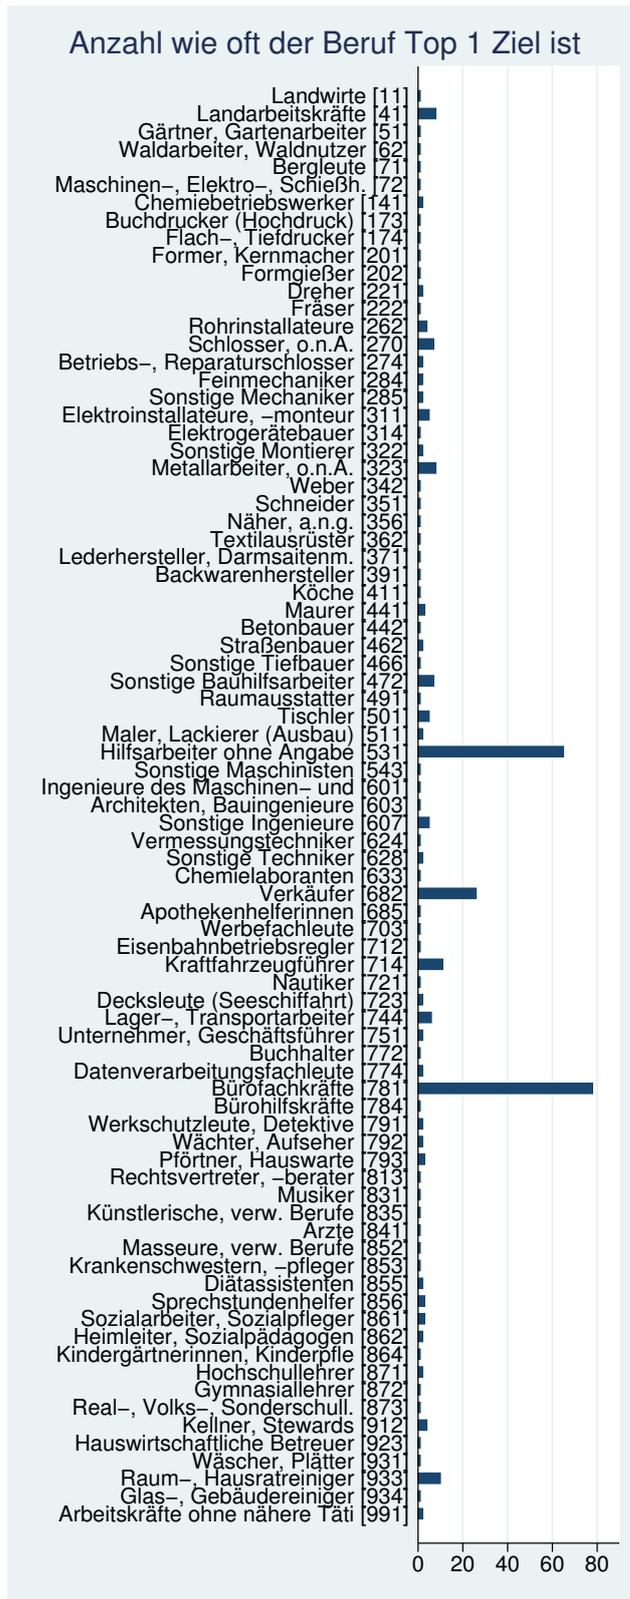


Abbildung A.84.: Top Zielberufe

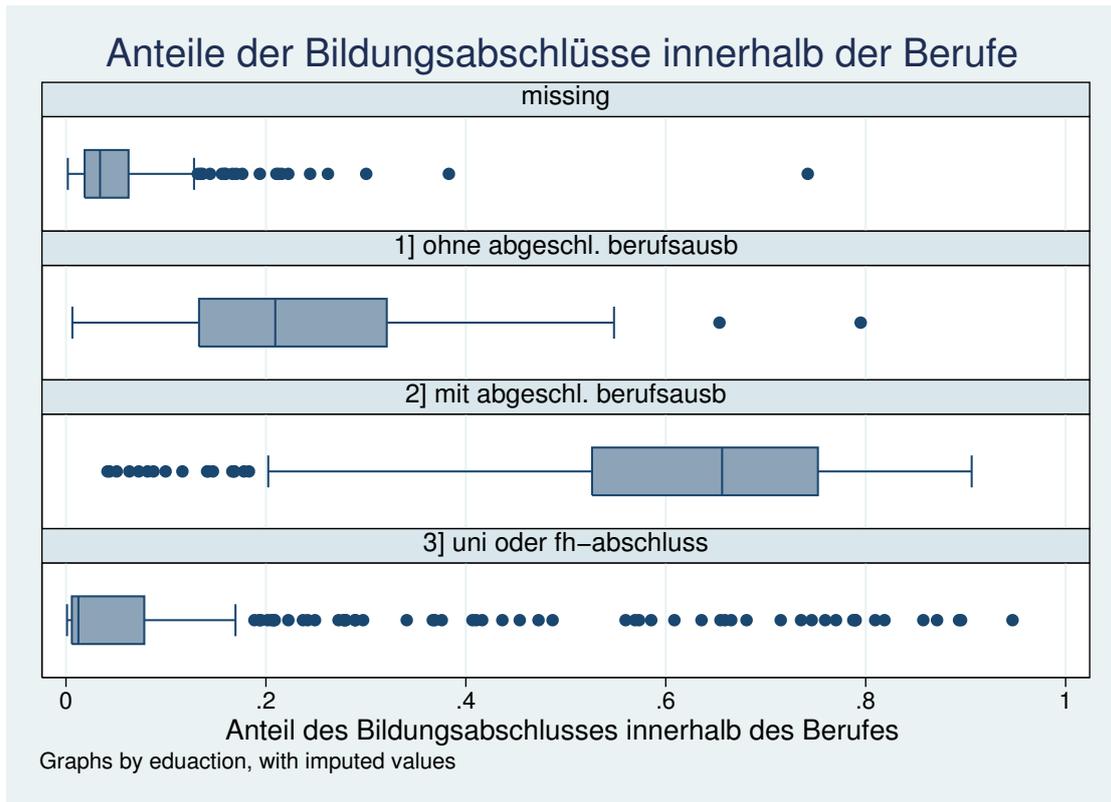


Abbildung A.85.: Verteilung der Bildungsabschlüsse - über die Berufe

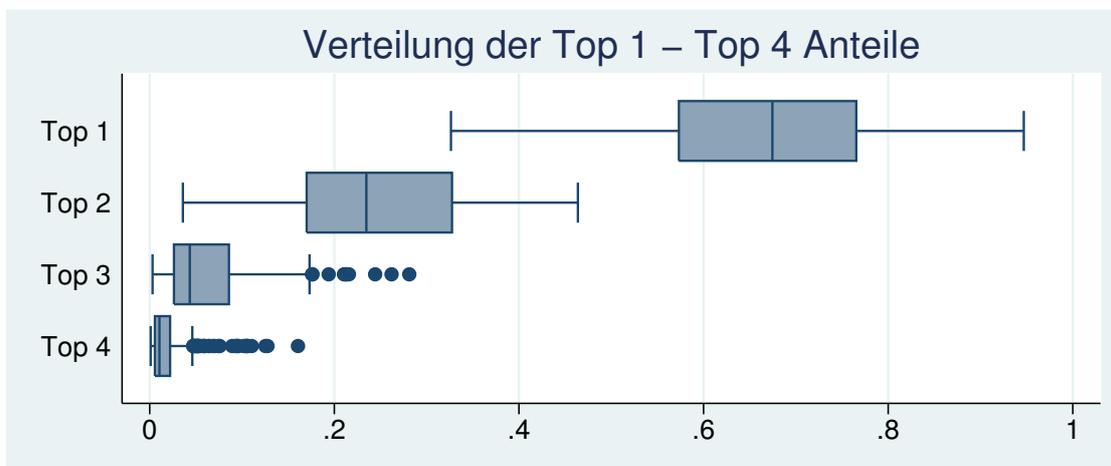


Abbildung A.86.: Verteilung der Top Bildungsabschlüsse - über die Berufe

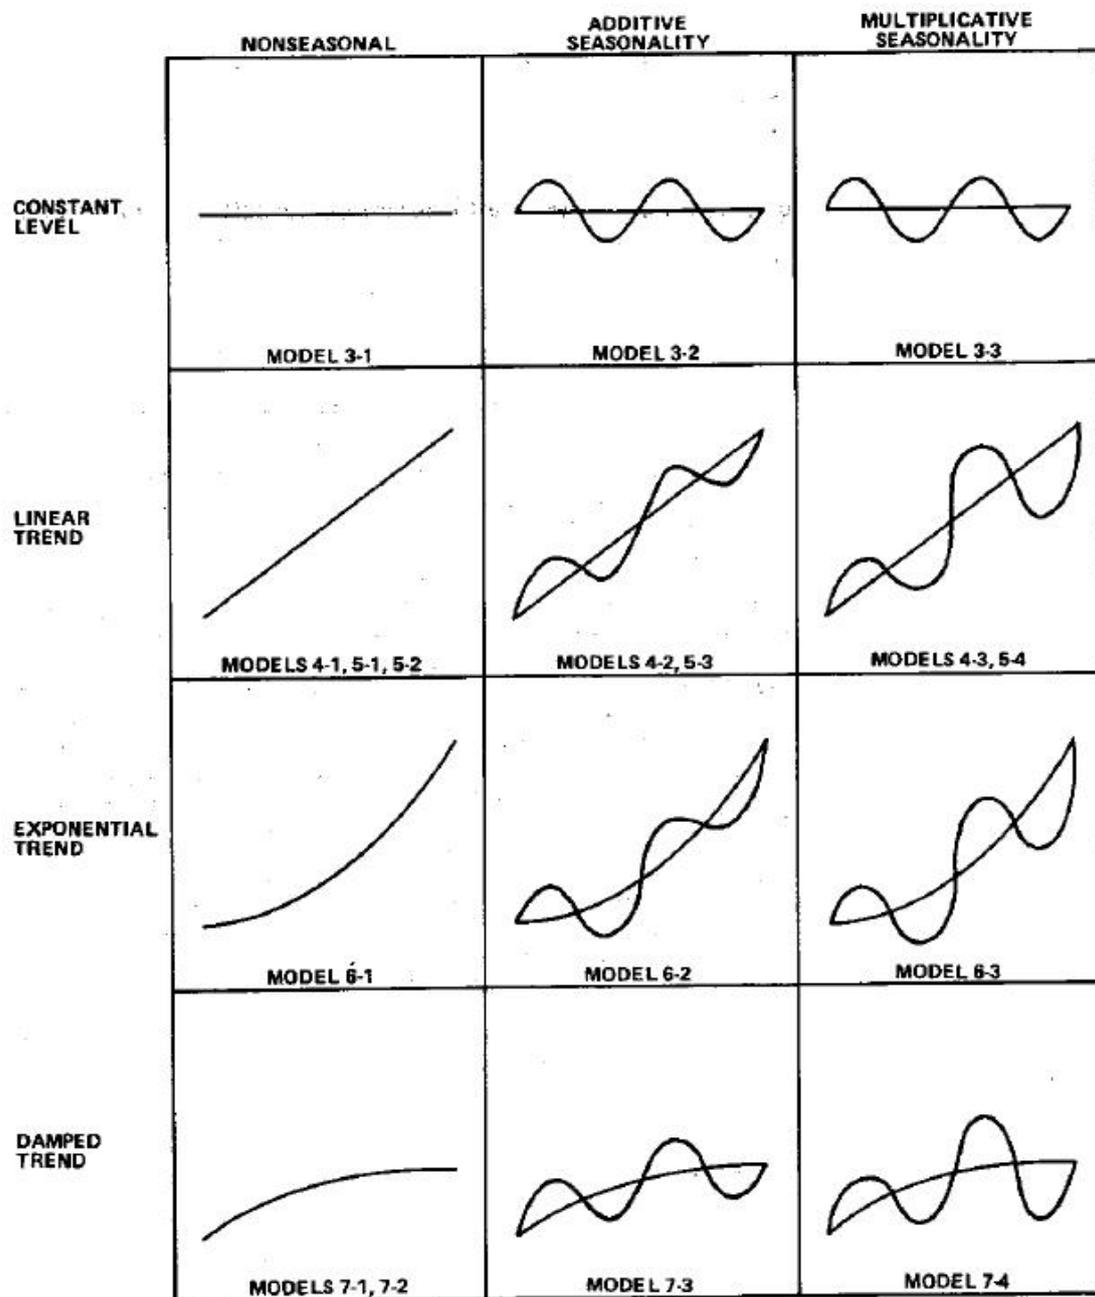


Exhibit 1. Forecast profiles from exponential smoothing

Abbildung A.87.: Smoothing Methoden (entnommen aus Gardner (1985))

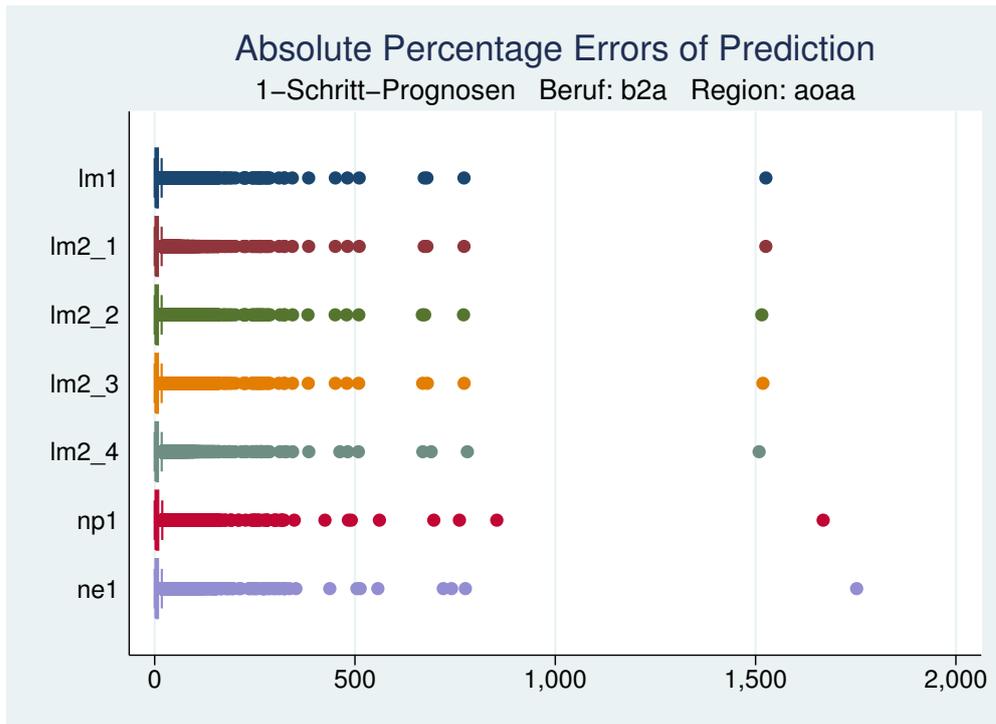


Abbildung A.88.: Boxplots der *MAPEP*'s für $p = 1$ – Vollzeit

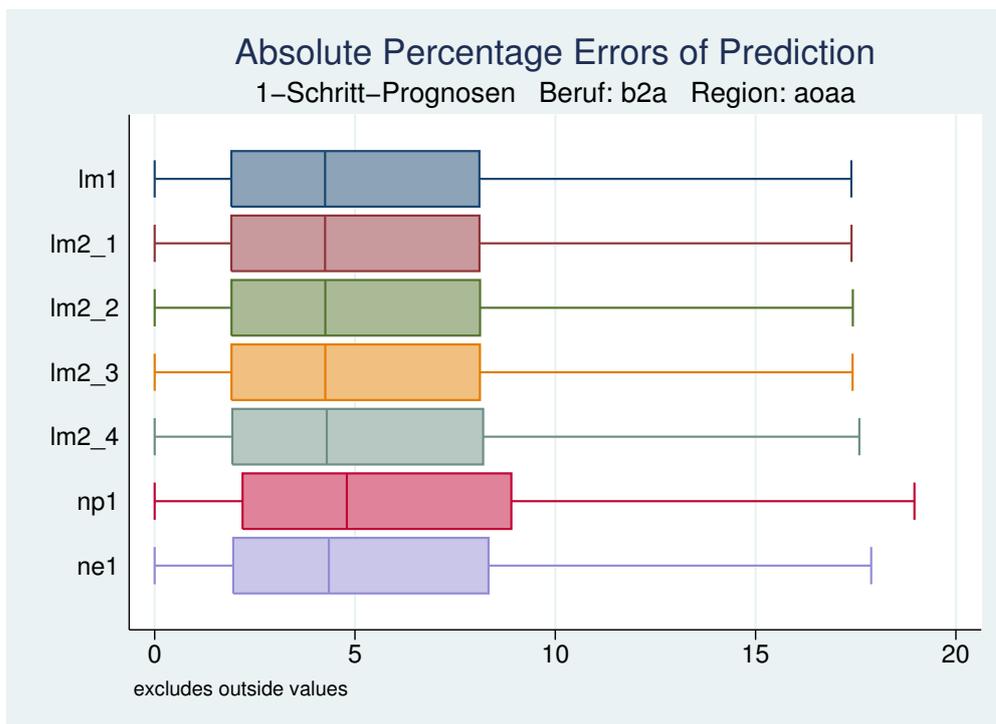


Abbildung A.89.: Boxplots der *MAPEP*'s für $p = 1$ – ohne extreme Werte – Vollzeit

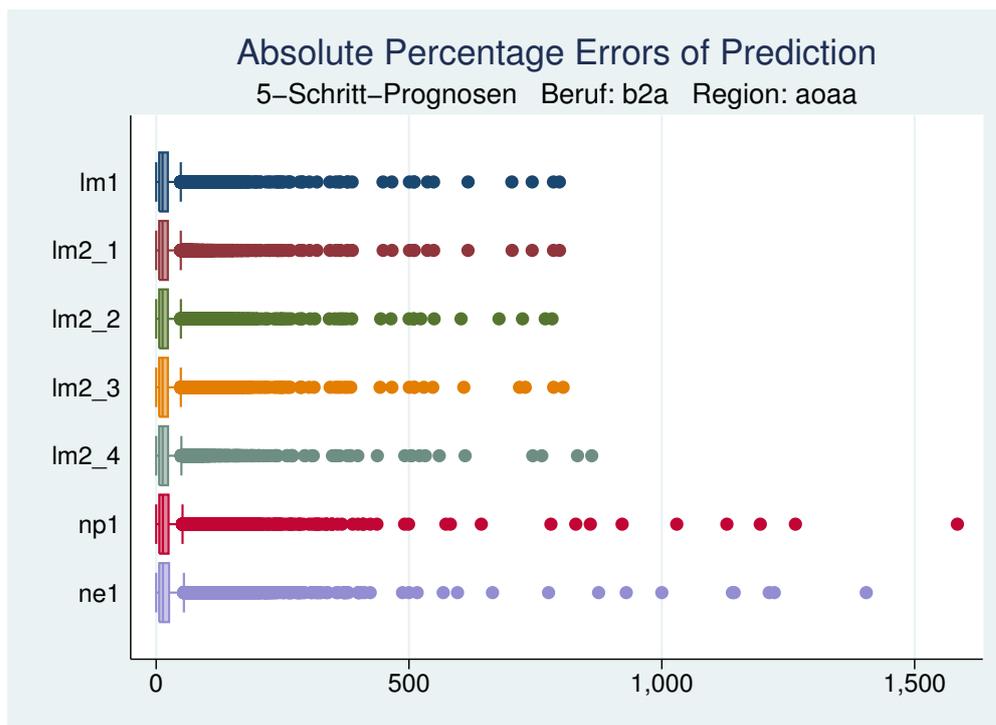


Abbildung A.90.: Boxplots der *MAPEP*'s für $p = 5$ – Vollzeit

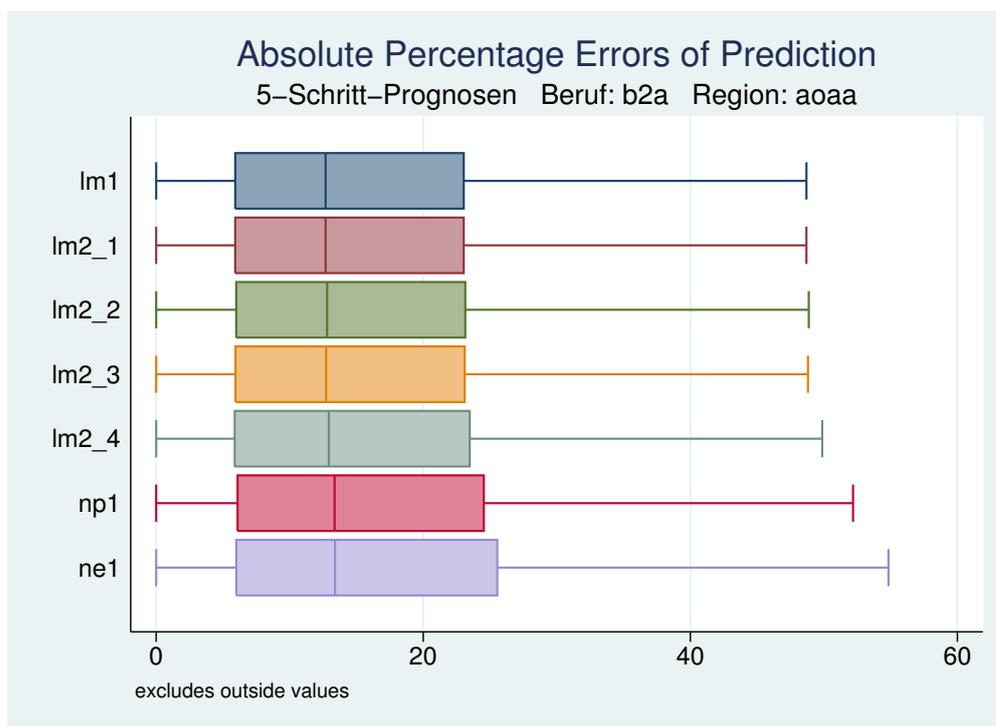


Abbildung A.91.: Boxplots der *MAPEP*'s für $p = 5$ – ohne extreme Werte – Vollzeit

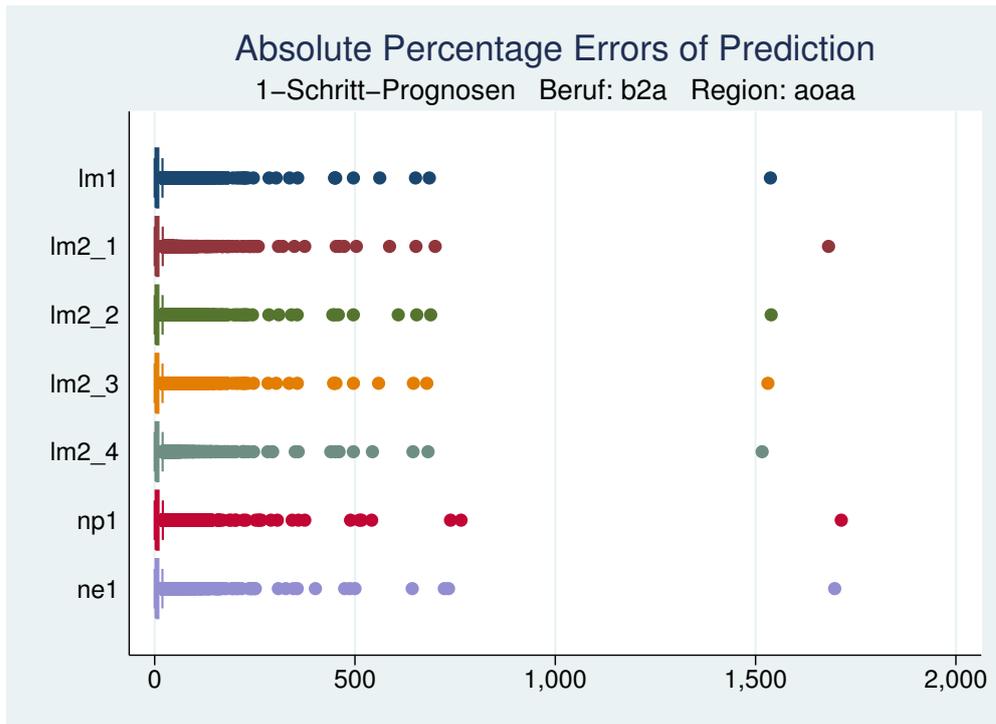


Abbildung A.92.: Boxplots der *MAPEP*'s für $p = 1$ – Große Teilzeit

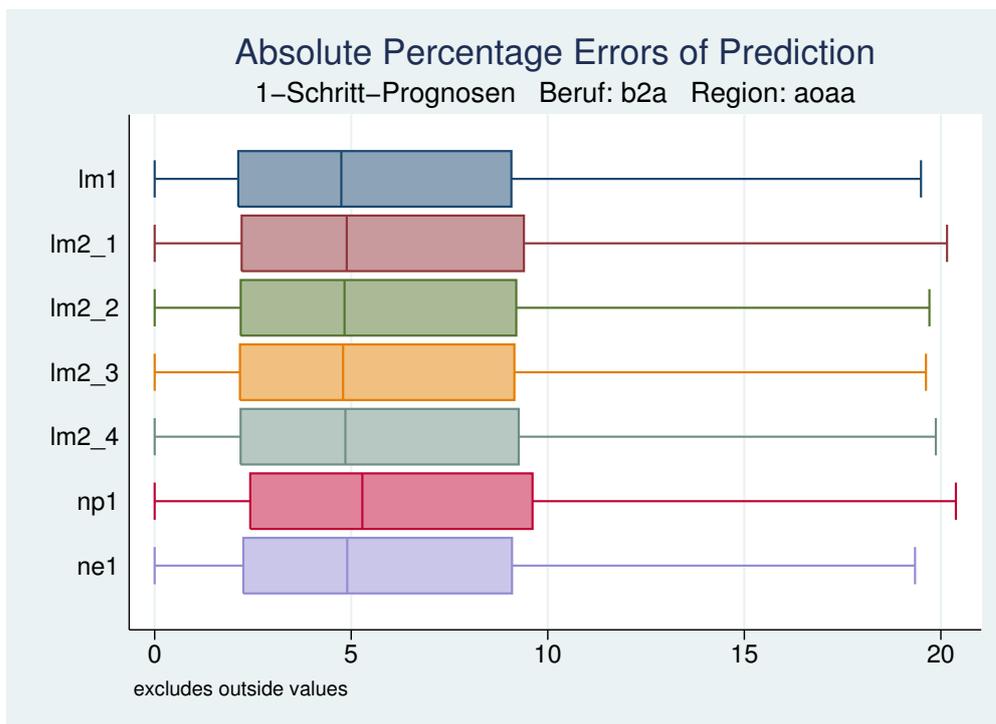


Abbildung A.93.: Boxplots der *MAPEP*'s für $p = 1$ – ohne extreme Werte – Große Teilzeit

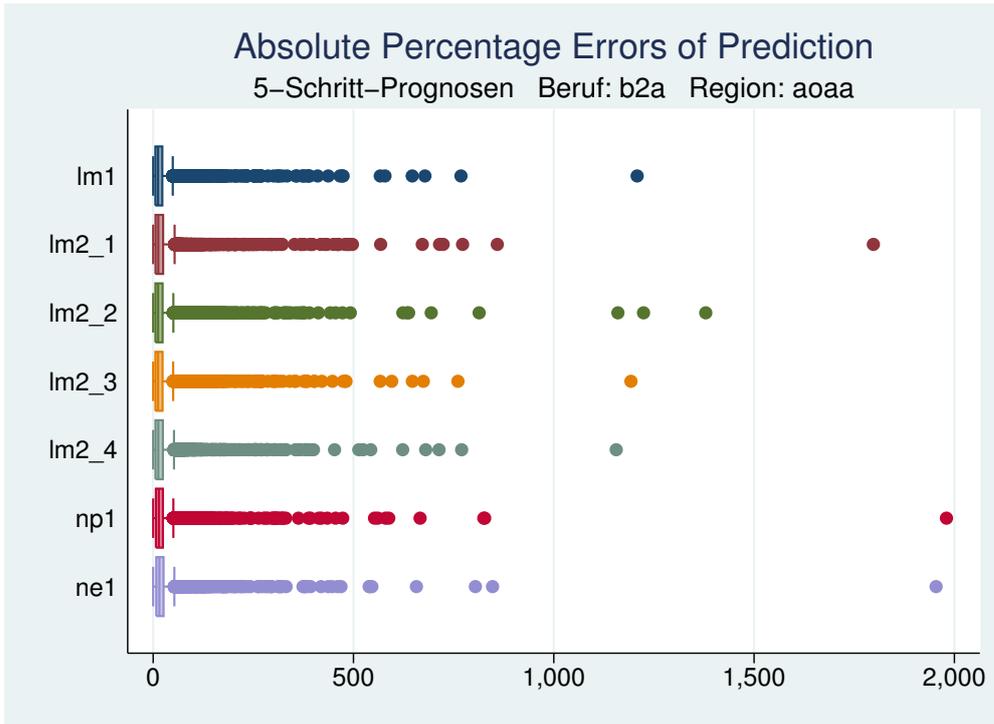


Abbildung A.94.: Boxplots der *MAPEP*'s für $p = 5$ – Große Teilzeit

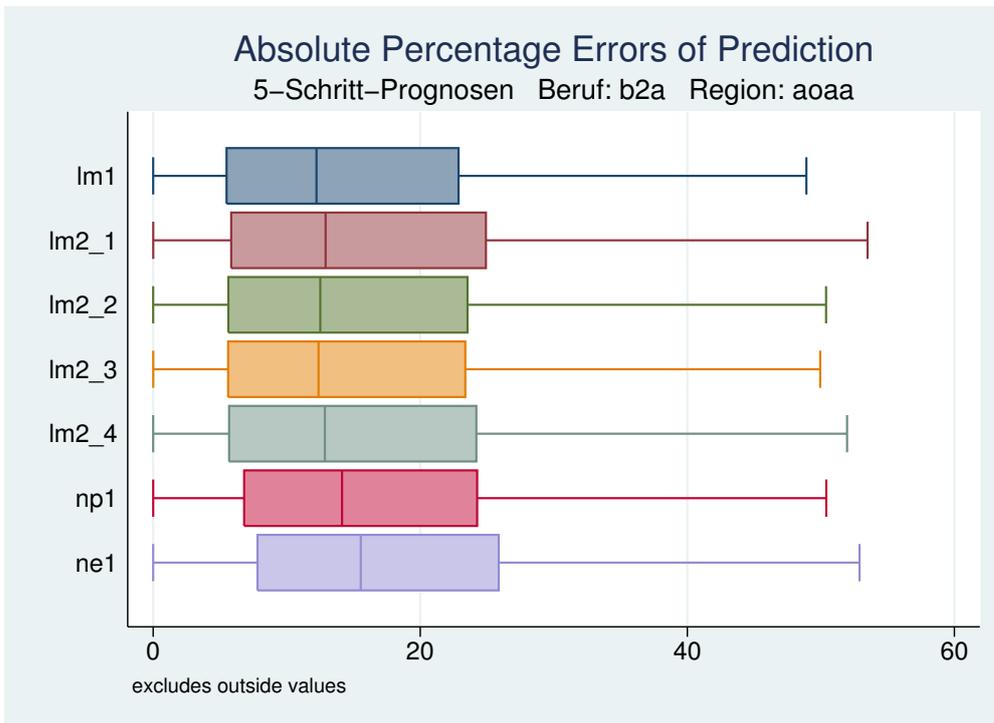


Abbildung A.95.: Boxplots der *MAPEP*'s für $p = 5$ – ohne extreme Werte – Große Teilzeit

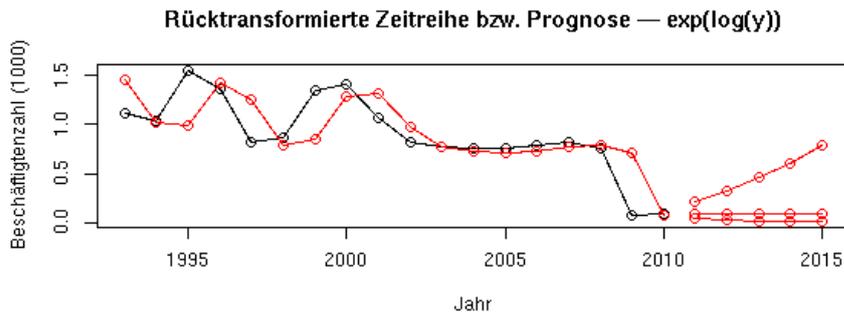
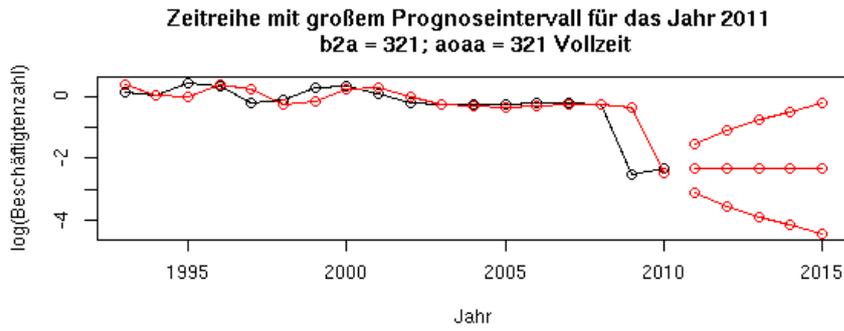


Abbildung A.96.: Zeitreihe mit sehr großem Prognoseintervall

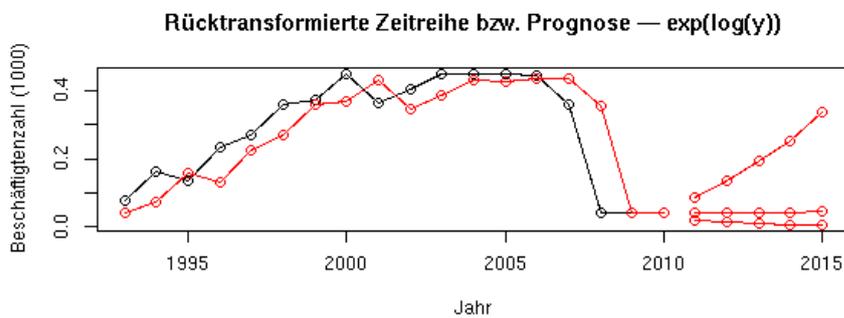
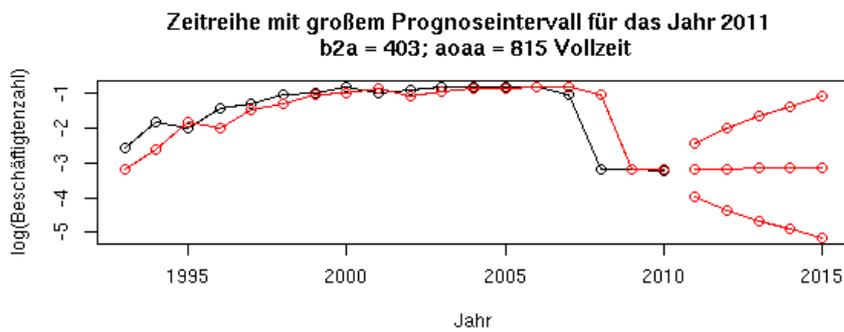


Abbildung A.97.: Zeitreihe mit sehr großem Prognoseintervall

A. Appendix

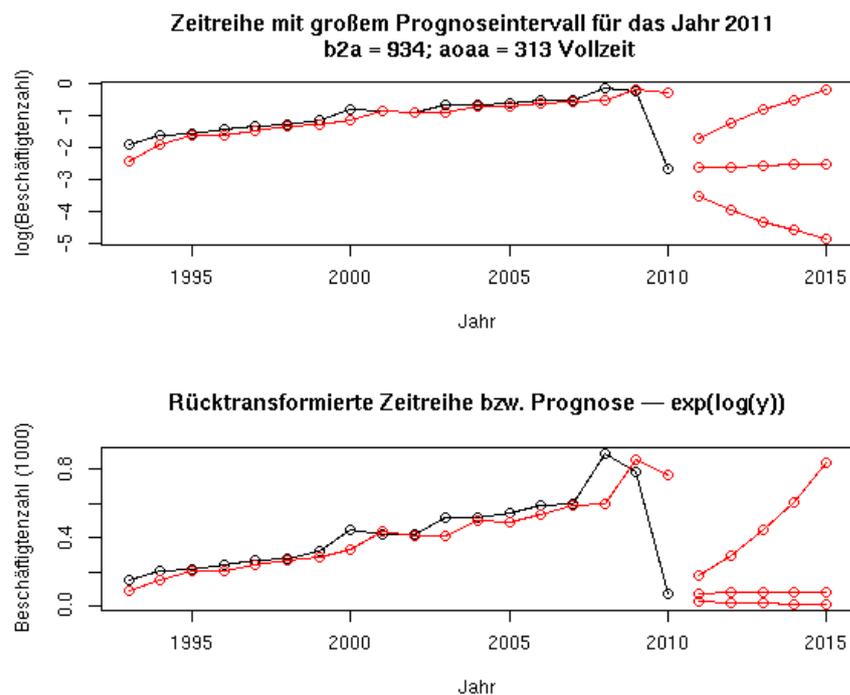


Abbildung A.98.: Zeitreihe mit sehr großem Prognoseintervall

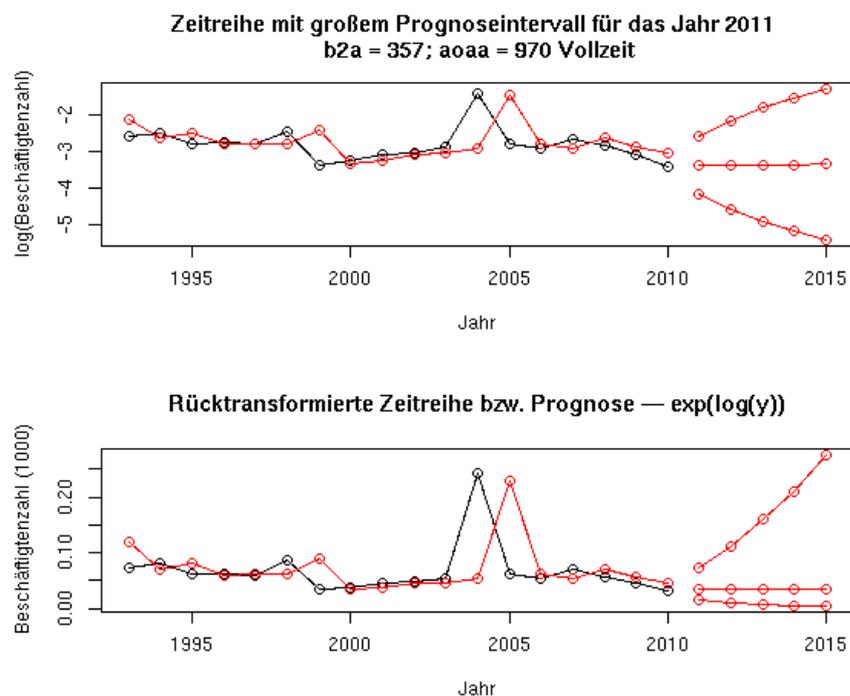


Abbildung A.99.: Zeitreihe mit sehr großem Prognoseintervall

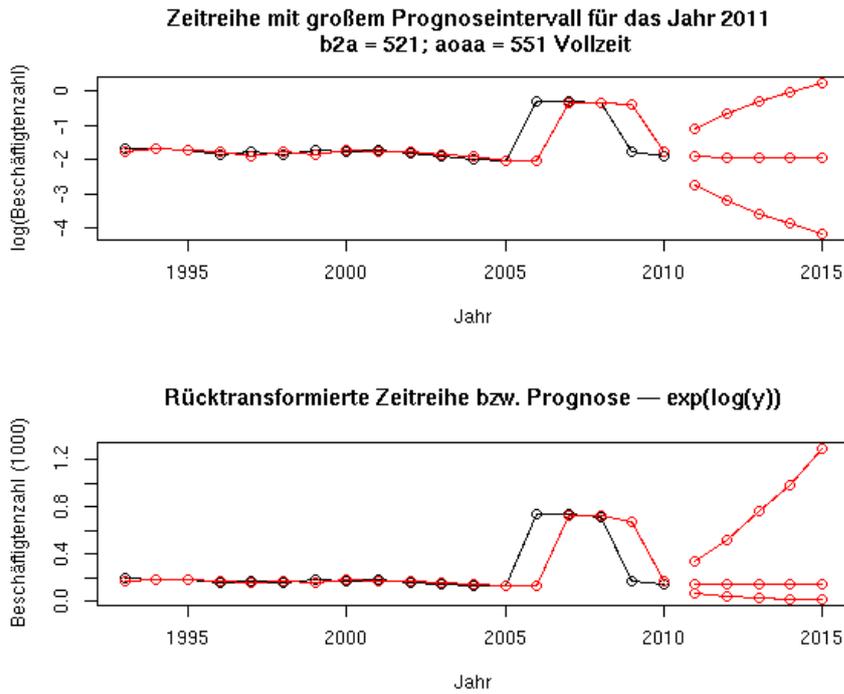


Abbildung A.100.: Zeitreihe mit sehr großem Prognoseintervall

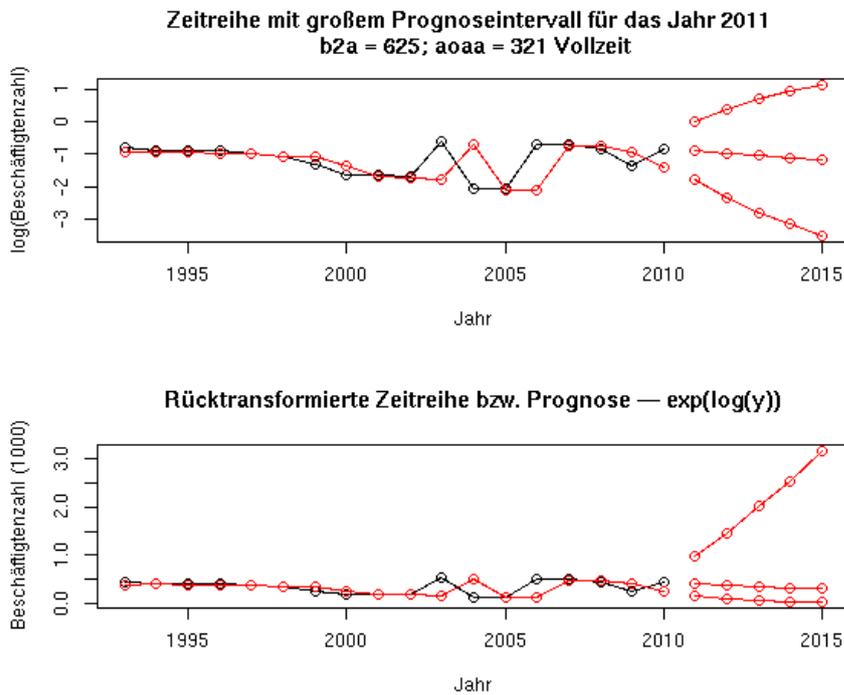


Abbildung A.101.: Zeitreihe mit sehr großem Prognoseintervall

A. Appendix

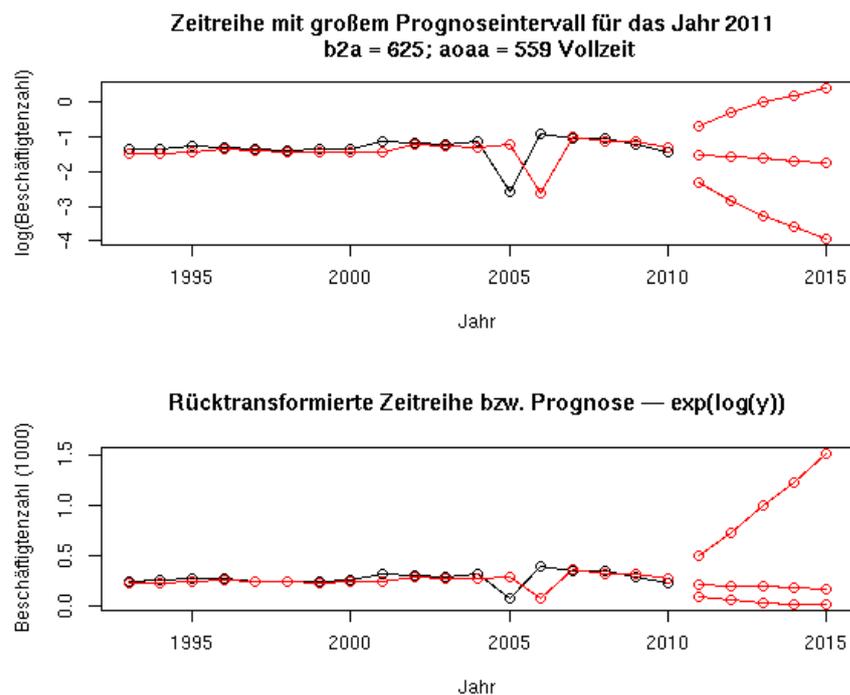


Abbildung A.102.: Zeitreihe mit sehr großem Prognoseintervall

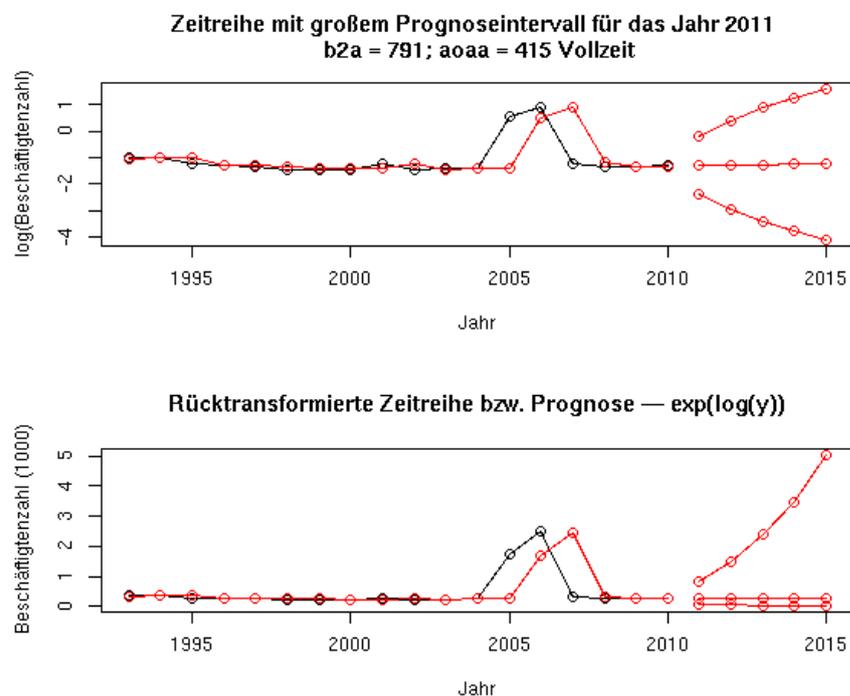


Abbildung A.103.: Zeitreihe mit sehr großem Prognoseintervall

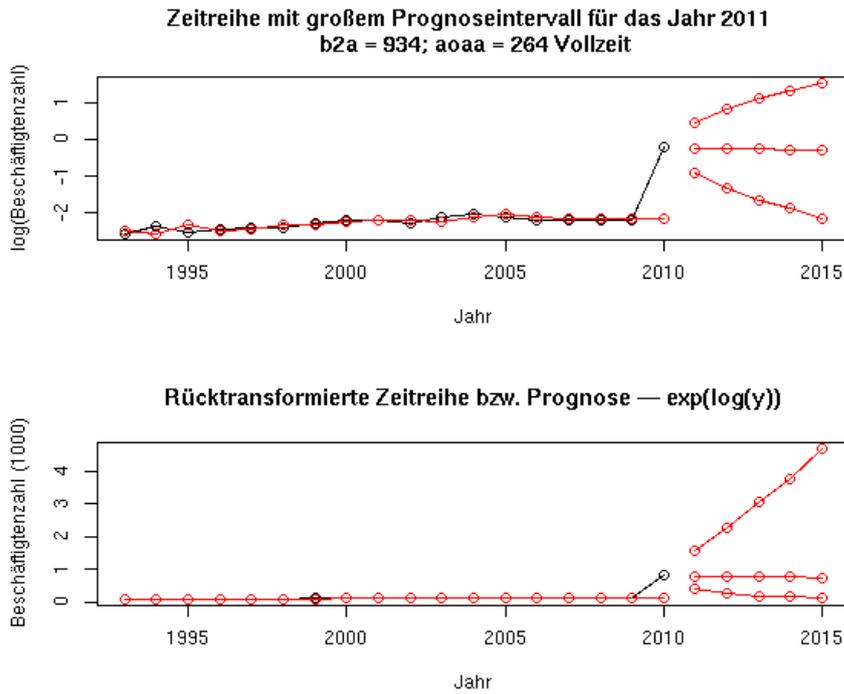


Abbildung A.104.: Zeitreihe mit sehr großem Prognoseintervall

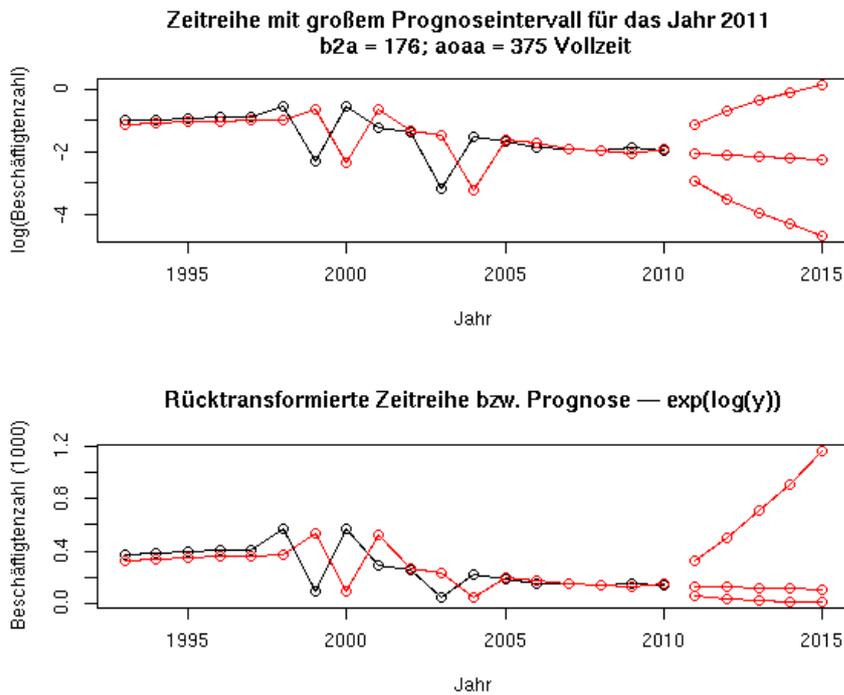


Abbildung A.105.: Zeitreihe mit sehr großem Prognoseintervall