

## Varianzschätzung für Mikrozensus Scientific Use Files ab 2005

*Bernhard Schimpl-Neimanns*



GESIS-Technical Reports 2010|03

# Varianzschätzung für Mikrozensus Scientific Use Files ab 2005

*Bernhard Schimpl-Neimanns*

## GESIS-Technical Reports

GESIS – Leibniz-Institut für Sozialwissenschaften  
Postfach 12 21 55  
68072 Mannheim  
Telefon: (0621) 1246 - 263  
Telefax: (0621) 1246 - 100  
E-Mail: [bernhard.schimpl-neimanns@gesis.org](mailto:bernhard.schimpl-neimanns@gesis.org)

ISSN: 1868-9043 (Print)  
ISSN: 1868-9051 (Online)  
Herausgeber,  
Druck und Vertrieb: GESIS - Leibniz-Institut für Sozialwissenschaften  
Lennéstraße 30, 53113 Bonn

# Varianzschätzung für Mikrozensus Scientific Use Files ab 2005

Bernhard Schimpl-Neimanns

## Zusammenfassung

Mit der Umstellung des Mikrozensus ab 2005 auf eine kontinuierliche Erhebung mit gleitender Berichtswoche sind auch die bei der Hochrechnung der Stichprobenergebnisse angewendeten Verfahren modifiziert worden. Nach der Darstellung des Stichprobendesigns des Mikrozensus und der Modifikationen wird beschrieben, wie mit den Scientific Use Files des Mikrozensus ab 2005 der Stichprobenfehler mit freier Hochrechnung (Designgewichtung) und gebundener Hochrechnung (Anpassungsgewichtung, Kalibrierung) für Gesamt- und Anteilswerte geschätzt werden kann.

*Schlüsselwörter: Mikrozensus, Scientific Use File, Varianzschätzung, Schichtung, Klumpung, Kalibrierung, verallgemeinerte Regressionsschätzung.*

**Title:** Variance estimation for the scientific use file of the German Microcensus from 2005 onwards

## Summary

Starting in 2005 the German Microcensus was organized as a continuous survey with a moving reference week. In 2005 the procedures used to estimate statistical population parameters have also been modified. After the presentation of the sampling design and the recent modifications the paper shows how sampling errors for totals and ratios using the Microcensus Scientific Use Files from 2005 can be estimated using design weights as well as calibration weights.

*Key words:* German Microcensus, Scientific Use File, variance estimation, stratification, clustering, calibration, generalised regression estimation.



## 1 Einleitung<sup>1</sup>

---

Ab dem Erhebungsjahr 2005 wurden im Mikrozensus eine Reihe von Neuerungen eingeführt. In inhaltlicher Hinsicht haben sich mit dem Mikrozensusgesetz 2005 insbesondere die Analysemöglichkeiten durch neue Fragen zur Migration erheblich erweitert.<sup>2</sup> Methodisch ist die Umstellung auf eine kontinuierliche Erhebung mit gleitender Berichtswoche hervorzuheben. Damit sind Quartalsauswertungen und die Berechnung von Jahresdurchschnittsergebnissen möglich geworden. In diesem Zusammenhang sind auch die bei der Hochrechnung der Stichprobenergebnisse angewendeten Verfahren modifiziert worden. Sowohl bei der Kompensation von Ausfällen als auch bei der Anpassung an Populationsdaten werden nicht mehr die frühere Hochrechnung mit „Soll durch Ist“ Faktoren und disjunkten Anpassungsklassen, sondern Regressionsschätzungen verwendet. Des Weiteren liegen ab 2005 für alle Personen eines Haushalts einheitliche Hochrechnungsfaktoren für Quartals- und Jahresdurchschnittsauswertungen vor.

Für die Mikrozensen bis zur Erhebung 2004 zeigen Anwendungsbeispiele, wie Varianzschätzungen auf Basis der Scientific Use Files (SUF) sowohl mit sogenannter freier Hochrechnung (Designgewichtung) als auch mit gebundener Hochrechnung (Poststratifikation) durchgeführt werden können (Rendtel und Schimpl-Neimanns 2001). Für designgewichtete Schätzungen mit den Daten ab 2005 können diese Verfahren weiter verwendet werden, wenn die Berichtsquartale als zusätzliches Schichtungsmerkmal berücksichtigt werden. Bei Quartalsauswertungen bzw. Auswertungen der Substichprobe ist lediglich die Ziehungswahrscheinlichkeit (0,25 % bzw. 0,1 %) zu beachten. Für die gebundene Hochrechnung der Daten ab 2005 sind jedoch Änderungen notwendig.

Dieser Bericht konzentriert sich deshalb darauf zu zeigen, wie die Anpassung an nicht disjunkte Anpassungsschichten und die für Personen und Haushalte einheitlichen Hochrechnungsfaktoren bei der gebundenen Hochrechnung mittels Regressionsschätzung in den Scientific Use Files des Mikrozensus ab 2005 berücksichtigt werden kann.

Im Folgenden werden zunächst das Erhebungsdesign des Mikrozensus (Kap. 2) und die Ziehung der Substichprobe des Scientific Use Files (Kap. 3) zusammenfassend beschrieben. Das vierte Kapitel zeigt die Schätzung von Gesamtwerten (Totals) mit Designgewichtung anhand eines einfachen Beispiels. Anschließend wird skizziert, wie Varianzschätzungen bei gebundener Hochrechnung mittels Regressionsschätzung bzw. Kalibrierung beim Mikrozensus ab 2005 (Kap. 5) durchgeführt werden können. Es folgen Varianzschätzungen für Verhältnswerte mit Designgewichtung (Kap. 6) und mittels Regressionsschätzung (Kap. 7). Der Bericht schließt mit einer Zusammenfassung und Überlegungen, wie künftig das Analysepotenzial des Mikrozensus durch die Bereitstellung zusätzlicher Designmerkmale besser ausgeschöpft werden kann.

---

<sup>1</sup> Wolf Bihler und Holger Breiholz haben insbesondere mit Erläuterungen zur Schätzung des Stichprobenfehlers bei den Originaldaten und durch die Bereitstellung von Ergebnissen dieser Schätzungen zum Zustandekommen des Berichts beigetragen. Hierfür sei ihnen an dieser Stelle gedankt. Gleichermaßen danke ich Siegfried Gabler und Ulrich Rendtel für konstruktive Kommentare zu früheren Fassungen des Berichts sowie Delia Jäger für das Korrekturlesen.

<sup>2</sup> Es sind aber auch Streichungen, wie zum Beispiel die Fragen nach dem Heiratsjahr und dem Kindergartenbesuch, festzustellen.

## 2 Stichprobenplan und Hochrechnungsverfahren

---

Standardverfahren der Statistikprogramme gehen bei der Schätzung der Varianz von der Annahme einer uneingeschränkten Zufallsauswahl mit Zurücklegen aus. Das Scientific Use File (SUF) entspricht aber einer systematischen Zufallsauswahl des Mikrozensus und ist wie die Originaldaten als mehrfach geschichtete Klumpenstichprobe (Flächenstichprobe) gekennzeichnet. Wird das Stichprobendesign nicht berücksichtigt, werden i. d. R. die Standardfehler unterschätzt und Hypothesentests sind fälschlicherweise eher „statistisch signifikant“. Die folgende Darstellung des Stichprobenplans des Mikrozensus beschränkt sich auf die Grundzüge (für Details siehe Afentakis und Bihler 2005; Heidenreich 1994; Krug et al. 2001; Meyer 1994; Rendtel und Schimpl-Neimanns 2001; Statistisches Bundesamt 2008).

### 2.1 Stichprobenplan

Der gegenwärtige Stichprobenplan des Mikrozensus ab 1990 beruht für das frühere Bundesgebiet auf Ergebnissen der Volkszählung 1987 und für die neuen Bundesländer auf Angaben aus dem Bevölkerungsregister Statistik 1991. Die Auswahl- bzw. Primäreinheiten (PSU: Primary Sampling Unit) – sogenannte Auswahlbezirke – bestehen aus benachbarten Wohnungen, die in einer Gebäudegruppe oder innerhalb eines größeren Gebäudes liegen. Es werden alle Sekundäreinheiten (Wohnungen, Haushalte und Personen) eines Auswahlbezirks erfasst, sodass der Auswahlatz von einem Prozent sowohl für die Primär- als auch für die Sekundäreinheiten gilt.<sup>3</sup> Die Stichprobe des Mikrozensus 2007 umfasst rund 47.000 Auswahlbezirke mit durchschnittlich 15 Personen pro Auswahlbezirk (Statistisches Bundesamt 2008: 8).

**Klumpung:** Grundlage für die Bildung der Primäreinheiten der Auswahlgesamtheit sind Ergebnisse der Volkszählung 1987 und des Bevölkerungsregisters Statistik 1991. Mit der Einteilung bzw. Schichtung von Gebäuden nach der Zahl der Wohnungen in Größenklassen wird eine Homogenisierung in siedlungsstruktureller Hinsicht erreicht. Zum Beispiel werden in der Grundausswahl Gebäude mit 1-4 Wohnungen zu Auswahlbezirken mit einer Richtgröße von 12 Wohnungen zusammengefasst (siehe Tab. 1), wobei sich die Zusammenfassung an der Reihenfolge der Hausnummern in der Straße orientiert. Für die Grundausswahl können Gebäude mit Gemeinschaftsunterkünften (z. B. Senioren- oder Pflegeheime) nur näherungsweise abgegrenzt werden („vermutete Gemeinschaftsunterkünfte“).

Um die seit der Grundausswahl entstandenen Gebäude in den Mikrozensus-Stichproben zu aktualisieren, werden diese jährlich nach Meldungen zur Bautätigkeitsstatistik in Gebäudegrößenklassen eingeteilt, die auch für die Bildung von Auswahlbezirken genutzt werden. Die Abgrenzungen unterscheiden sich von denen der Grundausswahl. Außerdem können Gemeinschaftsunterkünfte bzw. Anstalten aus den Meldungen direkt zugeordnet werden (siehe Tab. 1).

---

<sup>3</sup> Ausgenommen hiervon sind die Ergänzungs- und Zusatzprogramme (v. a. Merkmale der EU-Arbeitskräfteerhebung), die bis 2004 als Substichproben mit variablen Auswahlätzen von 0,4 %, 0,6 %, 0,8 % oder 1 % auf Regierungsbezirksebene durchgeführt wurden. In den anonymisierten Daten ist nur der im Bundesgebiet durchschnittliche Auswahlatz von 0,45 % bekannt.



Tendenziell vergrößert die Klumpenauswahl den Stichprobenfehler im Vergleich zu einer uneingeschränkten Zufallsauswahl. Der Stichprobenfehler ist i. d. R. um so größer, je homogener die Klumpen hinsichtlich der interessierenden Merkmale, je größer die Klumpen und je unterschiedlicher die Klumpengrößen sind.

Tabelle 1: Gebäudeschichten im Mikrozensus ab 1990

Bildung der Auswahlbezirke entsprechend den Richtgrößen	Grundauswahl Gebäude mit ... [Richtgröße]	Neubauauswahl* Gebäude mit ... [Richtgröße]
Zusammenfassung mehrerer Gebäude	1-4 Wohnungen [12 Wohnungen]	1-4 Wohnungen [6 Wohnungen]
Einzelgebäude	5-10 Wohnungen	5-8 Wohnungen
Gebäudeteile	11 oder mehr Wohnungen [6 Wohnungen]	9 oder mehr Wohnungen [6 Wohnungen]
Einzelgebäude oder Gebäudeteile	vermuteten Gemeinschaftsunterk. [15 Personen]	Gemeinschaftsunterkünften [15 Personen]

\* Bei der Neubauauswahl wird die Einteilung nach Gebäudegrößenklassen nur für die Bildung der Auswahlbezirke genutzt. Die Auswahlbezirke aller Gebäudeklassen der Neubauauswahl sind annähernd gleich groß und werden pro regionaler Schicht in einer „Neubauschicht“ zusammengefasst.

**Schichtung:** Im Unterschied zur Klumpung führt die Schichtung der Auswahlgesamtheit im Allgemeinen zu einer Verringerung des Stichprobenfehlers. Da dieser Schichtungseffekt von einer möglichst homogenen Zusammensetzung der Schichten hinsichtlich des interessierenden Merkmals bzw. von einer hohen Korrelation des interessierenden Merkmals mit dem Schichtungsmerkmal abhängt, sind in Anbetracht der Vielzahl von Merkmalen im Mikrozensus dem Ziel, durch Schichtung eine Verringerung des Stichprobenfehlers zu erreichen, Grenzen gesetzt.

Neben den Gebäudeschichten (fachliche Schichtung) gibt es regionale Schichten. Großstädte über 200.000 Einwohner und sonstige Regionen über 250.000 Einwohner bilden eigene regionale Schichten und ermöglichen somit auch Regionalauswertungen des Mikrozensus. Für Zwecke der gebundenen Hochrechnung (s. u.) wurden die regionalen Schichten zu Anpassungsschichten zusammengefasst; das sind regionale Einheiten mit durchschnittlich 500.000 Einwohnern. Darüber hinaus werden die Primäreinheiten der Auswahlgesamtheit vor der Stichprobenziehung nach regionalen Schichtuntergruppen (Regionaleinheiten mit mindestens 100.000 Einwohnern) angeordnet. Mit der Einführung der unterjährigen Erhebung ab dem Mikrozensus 2005 werden die regionalen und fachlichen Schichten zusätzlich nach Berichtsquartalen differenziert, wobei für die Quartalsstichproben (der realisierten Interviews) Unabhängigkeit angenommen wird.

**Partielle Rotation:** Der Mikrozensus soll sowohl sozioökonomische Strukturdaten im Querschnitt als auch möglichst präzise Daten über Strukturveränderungen bereitstellen. Diese Anforderungen werden im Stichprobenplan mittels partieller Rotation von Erhebungseinheiten berücksichtigt (Krug et al. 2001: 161f.). Die Auswahlbezirke und die darin wohnenden Haushalte und Personen verbleiben vier Jahre lang in der Befragung und bilden ein sogenanntes Rotationsviertel. Jährlich wird ein Viertel der Auswahlbezirke ausgetauscht. Der Mikrozensus ist somit eine Wiederholungsbefragung mit teilweiser Überlappung der Erhebungseinheiten. Die Zusammensetzung der Mikrozensusstichprobe eines Erhebungsjahres aus verschiedenen Rotationsgruppen wird bei der Auswahl durch Aufteilung der 1 %-Stichproben in vier Teile berücksichtigt.

Die Rotation ermöglicht grundsätzlich Panelanalysen von Merkmalsveränderungen auf Individual- oder Haushaltsebene über eine Vierjahresperiode. Hierfür können zwei Panels als Scientific Use Files genutzt werden (1996-1999 und 2001-2004; siehe <http://www.gesis.org/Dauerbeobachtung/GML/Daten/MZ-Panel/index.htm>). Gegenwärtig ist jedoch in den anonymisierten Querschnittsdaten (Grundfiles) die Zugehörigkeit zu den Rotationsgruppen nicht bekannt, sodass damit keine Untersuchungen von Veränderungen in den Haushalts- und Personenmerkmalen auf Individualebene möglich sind. Bei einem Vergleich von Veränderungen von Gesamt- oder Mittelwerten ist dies einerseits damit verbunden, dass die potenzielle Reduktion des Stichprobenfehlers nicht berücksichtigt werden kann, die infolge einer Korrelation von Merkmalen im Analysezeitraum entsteht. Andererseits kann bei einer Kumulation der Daten bzw. bei der Bildung von Summen von Ergebnissen mehrerer Zeitpunkte der Stichprobenfehler der Summe nicht korrekt geschätzt werden, da in diesem Fall die Varianz vergrößernde Merkmalskorrelation nicht bekannt ist.

**Substichproben:** Eine weitere Vorgabe für den Stichprobenplan des Mikrozensus ab 1990 war, dass verschiedene Themen der Ergänzungs- und Zusatzprogramme sowie der in den Mikrozensus integrierten Arbeitkräfteerhebung (EU Labour Force Survey) nur bei Substichproben mit einem reduzierten Auswahlsatz erhoben wurden. Bereits in der Planungsphase wurde für zukünftige methodische Entwicklungen eine Unterteilung der 1 %-Stichproben in 48 Teilstichproben (= 12 Monate x 4 Rotationsgruppen) vorgesehen (siehe für Details Afentakis und Bihler 2005: 1041). Darauf konnte bei der Einführung der kontinuierlichen Befragung ab 2005 für die Zuordnung des Befragungsvolumens auf die einzelnen Monate zurückgegriffen werden. Der früher variable Auswahlsatz der Substichprobe von durchschnittlich 0,45 Prozent ist ab dem Erhebungsjahr 2005 nicht mehr gültig, da die Merkmale der Arbeitkräfteerhebung mit dem vollen Auswahlsatz erhoben werden. Für die Merkmale des Ad-hoc-Moduls der Arbeitkräfteerhebung wird eine Substichprobe mit einem konstanten Auswahlsatz von 0,1 Prozent verwendet.

**Auswahltechnik:** Die Auswahltechnik unterscheidet sich zwischen der Grund- und Neubausauswahl. In der Grundauswahl wurden vor der eigentlichen Stichprobenziehung die Auswahlbezirke (PSUs) der Auswahlgesamtheit innerhalb der Schichten nach Bundesland, Regierungsbezirk, Kreis, Gemeindegrößenklasse, Gemeinde und Auswahlbezirksnummer angeordnet. Jeweils 100 aufeinanderfolgende Auswahlbezirke bildeten eine sogenannte Zone. Die Auswahlbezirke einer Zone wurden zufällig einer Zahl zwischen 0 und 99, der Stichprobennummer, zugeordnet. Alle Auswahlbezirke mit gleicher zugeordneter Nummer zählten zu einer von 100 1%-Stichproben. Aus dieser Auswahlgesamtheit wurden 20 Vorratsstichproben durch einfache Zufallsauswahl ausgewählt.

Die Zerlegung der 1%-Stichproben in Rotationsviertel zu je 0,25 % erfolgte durch zufällige Zuordnung von vier aufeinanderfolgenden Zonen, die einen sogenannten Block bilden, zu einer Zahl von eins bis vier (Zonenummer). Die Auswahlbezirke mit gleicher Zonenummer zählen zum gleichen Rotationsviertel. Die Vorratsstichproben wurden mit ähnlichen Zufallsverfahren für weitere Substichproben zerlegt.<sup>4</sup>

Bei der Neubausauswahl werden zunächst auf Kreis- bzw. Gemeindeebene Auswahlbezirke auf Basis der Bautätigkeitsstatistik gebildet. Diese werden nach Gebäudegrößenklassen angeordnet und innerhalb jeder regionalen Schicht nach der Reihenfolge ihrer Bildung durchnummeriert. Die Ziehung der

---

<sup>4</sup> Hierfür werden die 1 %-Stichproben bis hin zu 0,05 %-Substichproben aufgeteilt.

Auswahlbezirke der Neubauswahl erfolgt durch systematisches Ziehen mit festem Intervall bei zufälligem Startpunkt.

## 2.2 Hochrechnungsverfahren

Wie in allen Umfragen kann auch beim Mikrozensus der Stichprobenplan nicht ohne Abstriche realisiert werden. Es kommt u. a. zu Untererfassungen in Form von Ausfällen der zu befragenden Haushalte. Bei der Hochrechnung des Mikrozensus wird ein zweistufiges Verfahren verwendet. Im ersten Schritt der Ausfallkorrektur wird von der Nettostichprobe der erfolgreich befragten Haushalte auf die Bruttostichprobe aller zu befragenden Haushalte hochgerechnet. Im zweiten Schritt wird diese Bruttostichprobe an Eckzahlen aus der laufenden Bevölkerungsfortschreibung angepasst. Ab 2005 werden dabei auch Ergebnisse des Ausländerzentralregisters verwendet. Dieses als nachträgliche Schichtung (Poststratifikation) bezeichnete Vorgehen soll systematische Untererfassungen ausgleichen, die z. B. durch Mängel bei der Erfassung von Neubauten entstehen können (Herberger 1985: 35). Mit der Gewichtung wird erreicht, dass zumindest die bei der Anpassung verwendeten Merkmale mit den Verteilungen der externen Bevölkerungsdaten übereinstimmen.

**Kompensation bzw. Ausfallkorrektur:** Aufgrund der Auskunftspflicht handelt es sich bei den Ausfällen hauptsächlich um Haushalte, die während der Befragung nicht erreichbar waren. Bis zum Mikrozensus 2004 wird eine hohe Ausschöpfung von rund 97 Prozent berichtet. Mit der Umstellung auf eine kontinuierliche Erhebung ab 2005 und einer entsprechend kürzeren Feldzeit stieg der Unit-Nonresponse auf rund fünf Prozent der zu befragenden Haushalte.

Die Ausfallkorrektur wird mit Hilfe von Informationen über die Haushalte, die nicht geantwortet haben, geschätzt. Für die Mehrzahl der ausgefallenen Haushalte liegen solche Angaben in Form von Melderegisterauskünften oder Vorjahresergebnissen vor. Seit dem Mikrozensus 1990 werden für die Ausfallkorrektur verschiedene Merkmale des Haushalts zu Kompensationstypen kombiniert. Bis 2004 wurde das Kompensationsgewicht als Verhältnis der zu befragenden Haushalte (Soll) zu den befragten Haushalten (Ist) auf der Ebene von regionalen Untergruppen<sup>5</sup> gebildet (Heidenreich 1994: 114-116). Infolge der unterjährigen Erhebung kann es zu sehr kleinen Zellenbesetzungen und entsprechend großen Schwankungen des Hochrechnungsfaktors kommen. Um diese Probleme zu vermeiden, wird das Gewicht zur Ausfallkorrektur ab 2005 für unterschiedliche regionale Einheiten und getrennte Randverteilungen mittels Regressionsschätzung (Kalibrierung) berechnet.

In die Regression gehen die in Tabelle 2 genannten Merkmale auf Haushaltsebene als erklärende Variablen ein, wobei Interaktionseffekte der regionalen und demografischen Merkmale gebildet werden. Die Anzahl der insgesamt zu befragenden Haushalte, einschließlich ausgefallener Haushalte, sind die Eck- bzw. „Populations“-werte  $t_x$ , an die die Anzahl der befragten Haushalte, d. h. die Gesamtwerte der Stichprobe  $\hat{t}_x$ , angepasst werden (siehe dazu die Modelldarstellung in Kap. 5; für Details zum Verfahren siehe Afentakis und Bihler 2005: 1043-1044). Mit dem so ermittelten Faktor  $g$ , dessen Kehrwert die geschätzte Antwortwahrscheinlichkeit ist, werden die Haushaltsausfälle der ersten Stufe korrigiert.

---

<sup>5</sup> Die im Mikrozensus ab 1990 gebildeten regionalen Untergruppen bestehen aus vollständigen Kreisen oder Gemeinden innerhalb einer Regionalschicht und umfassen mindestens 100.000 Einwohner.

Tabelle 2: Kompensationsmodell im Mikrozensus ab 2005

Regionale Ebene	Kompensationsterme
Privathaushalte	
Bundesland	<ul style="list-style-type: none"> <li>▪ Rotationsviertel</li> <li>▪ Neubauschicht (ja / nein)</li> </ul>
Regionale Anpassungsschicht	<ul style="list-style-type: none"> <li>▪ Haushaltsgröße (1 / 2 / 3+)</li> <li>▪ Staatsangehörigkeit der Haushaltsbezugsperson (deutsch / nicht deutsch)</li> <li>▪ Wohnsitz der Haushaltsbezugsperson (Haupt- / Nebenwohnung)</li> </ul>
	zusätzlich für Einpersonenhaushalte
	<ul style="list-style-type: none"> <li>▪ Geschlecht</li> <li>▪ Alter (&lt;60 / 60+)</li> </ul>
Regionale Untergruppe	<ul style="list-style-type: none"> <li>▪ Privathaushalte insgesamt</li> </ul>
Gemeinschaftsunterkünfte	
Regierungsbezirk	<ul style="list-style-type: none"> <li>▪ Zahl der Personen in Gemeinschaftsunterkünften</li> </ul>

Quelle: Afentakis und Bihler 2005: 1044.

**Anpassung an bekannte Populationsverteilungen:** Von 1990 bis 2004 erfolgte die Anpassung an Ergebnisse der laufenden Bevölkerungsfortschreibung für die Merkmalskombinationen Geschlecht und Staatsangehörigkeit (Deutsche / Ausländer) auf der regionalen Ebene der Anpassungsschichten sowie für Soldaten und Wehrpflichtige an entsprechende Bestandsmeldungen auf Regierungsbezirksebene (siehe Heidenreich 1994). Diese sowohl in der Stichprobe als auch in den Populationsdaten vorliegenden Merkmale werden als Hilfsmerkmale bezeichnet. Insgesamt ergeben sich daraus sechs disjunkte Anpassungsklassen pro Regionaleinheit. Der personenbezogene Anpassungsfaktor wird als Quotient der Eckwerte der Populationsdaten (Soll) und der nach Korrektur der Haushaltsausfälle gewichteten Mikrozensusdaten (Ist) pro Anpassungsklasse und Regionaleinheit (Anpassungsschicht bzw. Regierungsbezirk) ermittelt. Der Haushalts- und Familienfaktor ist das arithmetische Mittel der personenbezogenen Anpassungsfaktoren. Die mit den jeweiligen Hochrechnungsfaktoren gewichteten Haushalts- und Personenauswertungen können jedoch zu widersprüchlichen Ergebnissen führen.<sup>6</sup>

Ab 2005 erfolgt die Anpassung nicht mehr mit disjunkten Anpassungsschichten und den oben beschriebenen Faktoren, sondern auf unterschiedlichen regionalen Ebenen an getrennte Randverteilungen der Populationsdaten wie bei der Kompensation mittels Regression (Kalibrierung) (Afentakis und Bihler 2005).<sup>7</sup> Das Verfahren hat den Vorteil, dass bei der Schätzung kleine Zellenbesetzungen vermieden werden können. Jedoch werden die Populationsverteilungen für Merkmalskombinationen i. d. R. nur dann getroffen, wenn das Regressionsmodell entsprechende Interaktionsterme der Hilfsmerkmale enthält. Zum Beispiel enthält das Anpassungsmodell u. a. die Merkmalskombinationen

<sup>6</sup> Wertet man beispielsweise die Zahl verheiratet zusammenlebender Männer und Frauen mittels personenspezifischer Hochrechnungsfaktoren aus, ergeben sich unterschiedliche Gesamtwerte. Dieses unplausible Ergebnis kann durch Gewichtung mit dem Hochrechnungsfaktor für Haushalte und Familien vermieden werden.

<sup>7</sup> Bei der Hochrechnung der Zusatzerhebung zur Wohnsituation im Mikrozensus 2006 werden im zweiten Schritt nicht die Daten der Bevölkerungsfortschreibung und des Ausländerzentralregisters, sondern Eckwerte der laufenden Wohnungsfortschreibung verwendet. Die Anpassung erfolgt auf regionaler Ebene von Anpassungsschichten für Jahresdurchschnittsergebnisse an Zahlen der Wohnungen in Wohn- und Nichtwohngebäuden. Im Unterschied zum SUF MZ 2005 sind die Hochrechnungsvariablen im SUF MZ 2006 bereits mit dem Kehrwert der Inklusionswahrscheinlichkeit 1 / 0,7 multipliziert.

Alter x Geschlecht und Staatsangehörigkeit x Geschlecht, sodass die geschätzten Populationsverteilungen für die Interaktion Alter x Staatsangehörigkeit von den Populationswerten ggf. abweichen können. Die Anpassung wird für Quartale durchgeführt. Der Hochrechnungsfaktor für Jahresdurchschnittsergebnisse ist das arithmetische Mittel der Quartalfaktoren.

Tabelle 3: Anpassungsmodell im Mikrozensus ab 2005

Regionale Ebene	Hochrechnungsterme	Quelle
Bundesland	Alter (<15 / 15-44 / 45+) x Geschlecht	Laufende Bevölkerungsfortschreibung <sup>1)</sup>
	Staatsangehörigkeit (deutsch / türkisch / EU-25 / nicht EU-25) x Geschlecht <sup>2)</sup>	Ausländerzentralregister <sup>3)</sup>
	Zeit- und Berufssoldaten einschl. Bundes- und Bereitschaftspolizei / Grundwehrdienstleistende / Zivilbevölkerung <sup>4)</sup>	Bundesministerium der Verteidigung, Bundespolizei, Bundesministerium des Innern <sup>5)</sup>
	Bevölkerung insgesamt je Monat	Laufende Bevölkerungsfortschreibung
Regierungsbezirk <sup>6)</sup>	Staatsangehörigkeit (deutsch / nicht deutsch) x Geschlecht	Laufende Bevölkerungsfortschreibung
Regionale Anpassungsschicht	Bevölkerung insgesamt <sup>7)</sup>	Laufende Bevölkerungsfortschreibung

- 1) Zeitreihenschätzung auf Basis des jeweils letzten verfügbaren Wertes sowie unabhängigen Zeitreihen der Bevölkerungsstatistik.
  - 2) In Bremen (teilw.) und in den neuen Bundesländern wird die Staatsangehörigkeit lediglich nach deutsch und nicht deutsch differenziert.
  - 3) Aus dem Ausländerzentralregister (i. d. R. zum Stichtag 31. 12.) werden nur die Anteile der nicht deutschen Bevölkerung für die Differenzierung der Zahl der Ausländer aus der laufenden Bevölkerungsfortschreibung verwendet.
  - 4) Außer in Hamburg, Bremen und im Saarland sind Grundwehrdienstleistende mit Zeit- und Berufssoldaten und Bundes- und Bereitschaftspolizei zusammengefasst.
  - 5) Quartalsweise Eckwerte für die Zeit- und Berufssoldaten sowie die Grundwehrdienstleistenden stammen vom Bundesministerium für Verteidigung und von der Bundespolizei. Zahlen der Bereitschaftspolizei liegen für den Stichtag 31. 12. vom Bundesministerium des Innern vor und werden für das Folgejahr verwendet.
  - 6) In Bundesländern mit Regierungsbezirken: Niedersachsen, Nordrhein-Westfalen, Hessen, Rheinland-Pfalz, Baden-Württemberg, Bayern und Sachsen. In Sachsen-Anhalt wird nur nach Geschlecht differenziert.
  - 7) Hamburg und Saarland sind nicht in regionale Anpassungsschichten unterteilt.
- Quelle: Afentakis und Bihler 2005: 1045.

Das frühere Problem potenziell inkonsistenter Haushalts- und Personenauswertungen, das aus der Anpassung der Stichprobe an Populationsdaten auf Personenebene resultiert, wird durch die Konstruktion eines für alle Personen eines Haushalts gleichen Hochrechnungsfaktors gelöst. Dies wird dadurch erreicht, dass bei der Kalibrierung für jede Person die Mittelwerte des Haushalts der Hilfsmerkmale verwendet werden (Afentakis und Bihler 2005: 1042; vgl. dazu auch Steel und Clark (2007) für einen Vergleich von Schätzungen auf Personen- und Haushaltsebene). Die Kompensationsfaktoren der ersten Stufe gehen als sogenannte Eingangsgewichte  $\hat{\theta}_i$  in die Regressionsschätzung ein. Neben der quartalsweisen Hochrechnung sind mit dem Ausländerzentralregister neue Populationsdaten hinzugekommen. Neue Anpassungsklassen sind durch die Berücksichtigung von Altersgruppen und Staatsangehörigkeitsgruppen entstanden (siehe Tab. 3).

### 3 Substichprobenziehung des Scientific Use Files

---

Das Ziehungsverfahren des SUF berücksichtigt die wesentlichen Designelemente des Mikrozensus: Die Schichtung und Klumpung. Zunächst werden die Haushalte der Originaldaten nach Berichtsquartal, Bundesland, Regierungsbezirk, Gemeindegrößenklasse, Zahl der Personen im Privathaushalt, Auswahlbezirksnummer und Haushaltsnummer angeordnet.<sup>8</sup> In dieser Anordnung werden die Haushalte neu durchnummeriert. In die Auswahl von 70 Prozent aller Haushalte werden alle Haushalte – einschließlich aller Personen in diesen Haushalten – übernommen, deren letzte Platzziffer der Haushaltsnummer von den zufällig bestimmten Zahlen 2, 5 und 9 verschieden ist. Im Anschluss an die Stichprobenziehung werden die Haushalte neu sortiert (systemfreie Sortierung) und erhalten eine fortlaufende Nummerierung. Bei Erhebungsjahren mit dem vierjährigen Zusatzprogramm zur Wohnsituation (1998, 2002, 2006) wird eine 70 %-Substichprobe der Wohnungen gezogen.<sup>9</sup> Bei Gemeinschaftsunterkünften erhält jede Person eine eigene fortlaufende („Haushalts-“ bzw. „Wohnungs-“) Nummer. Nicht enthalten sind sogenannte Nullbezirke, das sind Auswahlbezirke ohne Befragte (z. B. leer stehende Häuser). Diese werden vor der Substichprobenziehung gelöscht.

Das bei der Ziehung des SUF eingesetzte Schlussziffernverfahren zählt zu den systematischen Zufallsauswahlen. Das Verfahren entspricht näherungsweise einer uneingeschränkten Auswahl und ist unproblematisch, sofern die Nummerierung nicht mit den Untersuchungsmerkmalen zusammenhängt und die Schlussziffern in etwa gleich stark besetzt sind. Die Anordnung vor der Ziehung der Substichprobe unterscheidet sich von der Schichtung im Original-Mikrozensus hauptsächlich hinsichtlich der Zahl der Personen in Privathaushalten in der Sortierfolge. Die Berücksichtigung der Haushaltsgröße gewährleistet einerseits eine hohe Ergebnisgenauigkeit des SUF im Vergleich zu den Originaldaten bzw. Veröffentlichungen der amtlichen Statistik. In Bezug auf die Berechnung des Stichprobenfehlers ist aber andererseits zu beachten, dass aufgrund der Zwischensortierung der Auswahlatz von Haushalten pro Auswahlbezirk nicht konstant 70 Prozent beträgt, sondern um diesen Wert variiert (Rendtel und Schimpl-Neimanns 2001: 91).

Im SUF stehen als Schichtungsinformationen die Variablen Bundesland und Gebäudegrößenklasse zur Verfügung. Regionale Einheiten unterhalb der Ebene der Bundesländer (Regionalschichten, Regierungsbezirk und regionale Anpassungsschichten) sind aus Datenschutzgründen nicht identifizierbar. Die Information zur Klumpung liegt in Form der Auswahlbezirksnummer vor. Der Hochrechnungsfaktor zur Kompensation der Haushaltsausfälle ist nicht im SUF enthalten.

---

<sup>8</sup> Ab dem Erhebungsjahr 2006 wird im SUF auch das Merkmal Gebäudegrößenklasse (fachliche Schichtung) verwendet, das in der Sortierfolge vor der Auswahlbezirksnummer steht.

<sup>9</sup> Der Begriff Haushalt (Haushaltsnummer, Zahl der Personen in Privathaushalten usw.) ist dann durch die Wohnung zu ersetzen.

## 4 Varianzschätzung für Gesamtwerte mit Designgewichtung bzw. freier Hochrechnung

---

Für systematische Zufallsauswahlen weisen Varianzschätzungen i. d. R. Verzerrungen auf (Gabler und Stenger 2006; Krug et al. 2001: 93f.; Särndal et al. 1997: 73f.). Zudem sind die exakten Ziehungswahrscheinlichkeiten des SUF nicht ermittelbar (s. o.). Da nicht alle Design- und Hochrechnungsinformationen verfügbar bzw. nur auf der regionalen Ebene der Bundesländer nutzbar sind, treten weitere Einschränkungen auf. In der Praxis müssen deshalb vereinfachende Annahmen getroffen werden.

Dies betrifft nicht nur Schätzungen auf Basis des SUF, sondern auch Schätzungen mit den Originaldaten. Unter anderem können die statistischen Ämter die differenzierte regionale und fachliche Schichtung nur näherungsweise berücksichtigen (Statistisches Bundesamt 2008: 12). Des Weiteren werden nicht die bei der Auswahl vorgesehenen Quartale, sondern die Quartale der Berichtswochen realisierter Interviews verwendet und es wird angenommen, dass die Quartalsstichproben unabhängig sind (Statistisches Bundesamt 2008: 13). Die Berichtswochen liegen allerdings infolge einer gewissen Flexibilität der Interviewer bei der Feldarbeit und insbesondere wegen verzögerter Beantwortung der Haushalte nicht immer innerhalb eines Monats (Afentakis und Bihler 2005: 1041). Die dabei entstehenden Schwankungen sind teilweise mit erheblichen Verzerrungen bei Haushaltsergebnissen verbunden (Statistisches Bundesamt 2009).

Vernachlässigt man die geringe Zahl von Haushaltsausfällen, kann die Ziehung des SUF idealtypisch als zweiphasiges Ziehungsverfahren betrachtet werden: 1. Ziehung der realisierten Mikrozensus-Haushalte (1 %); 2. Ziehung der Haushalts- bzw. Wohnungssubstichprobe (70 %). Näherungsweise kann auch von einer zweistufigen Auswahl ausgegangen werden (Särndal et al. 1997: 133-135, 349-350). In diesem Sinne entspricht die erste Stufe einer geschichteten Auswahl der Primäreinheiten im Original-Mikrozensus. Die zweite Stufe stellt dann die gezogene Substichprobe von Sekundäreinheiten (Haushalte bzw. Wohnungen) dar.

Aufgrund des geringen Auswahlatzes der Auswahlbezirke des Mikrozensus ist anzunehmen, dass die Varianzanteile nach der ersten Stufe vernachlässigbar sind (siehe Särndal et al. 1997: 140). Dies belegen auch frühere Ergebnisse auf Basis des Mikrozensus 1996 (Rendtel und Schimpl-Neimanns 2001), sodass die mittlerweile in den meisten Statistikpaketen vorhandenen Standardprozeduren für einstufige Varianzschätzungen verwendet werden können, wenn man die Inklusionswahrscheinlichkeit der Substichprobe berücksichtigt und entsprechend von der 70 %-Substichprobe (0,7 %) auf den Mikrozensus (1 %) hochrechnet. Im Folgenden werden in Anlehnung an eine frühere Arbeit (Schimpl-Neimanns 2009) die Schätzungen beispielhaft beschrieben.

Die einstufige Schätzung eines Gesamtwertes (Total)  $\hat{Y}$  und der Varianz  $\hat{V}(\hat{Y})$  wird in enger Anlehnung an das Stata Survey Data Reference Manual (2007: 151-152) wie folgt dargestellt:



$$(1) \quad \hat{Y} = \sum_{h=1}^L \sum_{i=1}^{n_h} \sum_{j=1}^{m_{hi}} w_{hij} y_{hij}$$

$$(2) \quad \hat{V}(\hat{Y}) = \sum_{h=1}^L (1 - f_h) \frac{n_h}{n_h - 1} \sum_{i=1}^{n_h} (y_{hi} - \bar{y}_h)^2$$

mit

$$y_{hi} = \sum_{j=1}^{m_{hi}} w_{hij} y_{hij} \quad \text{gewichteter Gesamtwert der Primäreinheit } (h, i)$$

$$\bar{y}_h = \frac{1}{n_h} \sum_{i=1}^{n_h} y_{hi} \quad \text{Mittelwert der Gesamtwerte der Primäreinheiten der Schicht } h$$

$h$  Schichten  $h = 1, \dots, L$

$i$   $i$ -te Primäreinheit in der Schicht  $h$  mit  $i = 1, \dots, N_h$

$j$   $j$ -te Sekundäreinheit (Person oder Haushalt) in der Primäreinheit  $i$

$f_h$  Auswahlsatz in Schicht  $h$  (Inklusionswahrscheinlichkeit)

$N_h$  Anzahl der Primäreinheiten in der Schicht  $h$

$n_h$  Anzahl der Primäreinheiten in der Stichprobe in Schicht  $h$

$m_{hi}$  Anzahl der Sekundäreinheiten in einer Primäreinheit  $i$  der Schicht  $h$  in der Stichprobe

Der mit  $w_{hij} = N_h/n_h$  bzw.  $w_{hij} = 1/f_h$  gewichtete Merkmalswert  $y_{hij}$  bezieht sich somit auf die Person  $j$  im Auswahlbezirk (PSU)  $i$  in Schicht  $h$ . Für die Schätzung von Jahresdurchschnittsergebnissen wird als Auswahlsatz das Produkt der Ziehungswahrscheinlichkeit des Mikrozensus (1 %) und der Ziehungswahrscheinlichkeit des SUF (70 %) angenommen. Entsprechendes gilt für Quartalsergebnisse (0,25 % x 70 %) und Auswertungen der Substichprobenmerkmale (0,1 % x 70 %), z. B. des Ad-hoc-Moduls.

Als Beispiel wird die Zahl von Erwerbslosen geschätzt. Die interessierende Subpopulation ist die Bevölkerung am Hauptwohnsitz im (erwerbsfähigen) Alter von 15 bis 64 Jahren. Für die Definition der Schichten werden das Berichtsquartal, das Bundesland und die Gebäudegrößenklasse herangezogen. Es gibt im SUF 6 Schichten der Gebäudeschicht Gemeinschaftsunterkunft mit insgesamt 91 Personen, die nur eine PSU enthalten, sodass hierfür keine Varianz geschätzt werden kann. Wegen des geringen Umfangs ist mit dem Ausschluss dieser Schichten bei der Varianzschätzung nicht mit Verzerrungen zu rechnen. Ansonsten können diese mit mit benachbarten Schichten in sogenannte Pseudoschichten zusammengefasst werden.

Als Ergebnis erhält man im Jahresdurchschnitt rund 3,6 Millionen Erwerbslose. Der Variationskoeffizient ( $cv = \text{Std. Abw.} / \text{Gesamtwert} = 26.667 / 3.581.000$ ) beträgt lediglich 0,74 Prozent. Der Designeffekt (*DEFT*) ist die Quadratwurzel des Verhältnisses der designbasierten Schätzung der Varianz eines Parameters zu einer Schätzung unter Annahme einer einfachen Zufallsstichprobe. Der im Vergleich zu einer einfachen Zufallsstichprobe im SUF um 20 Prozent höhere Stichprobenfehler (*DEFT* = 1,2) ist vorwiegend auf die Klumpung zurückzuführen (hier ohne Nachweis). Infolge der Verringerung der Stichprobengröße sind die Variationskoeffizienten der Quartalsergebnisse etwa doppelt so groß wie beim Jahresdurchschnitt ( $(1 / 0,25)^{1/2} = 2$ ).



Tabelle 4: Ergebnisse der Schätzungen der Zahl der Erwerbslosen bei Designgewichtung im SUF und im Mikrozensus 2005

	SUF		DEFT	MZ	
	Gesamtwert	cv (%)		Gesamtwert	cv (%)
	a) Jahresdurchschnitt				
Insgesamt	3.581.000	0,74	1,21		
Deutsche	3.131.000	0,78	1,18	3.119.400	0,69
Ausländer	450.000	2,13	1,20	446.900	1,85
	b) Quartalsergebnisse				
Insgesamt					
1. Quartal	3.223.428	1,55	1,17		
2. Quartal	3.627.428	1,48	1,19		
3. Quartal	3.544.571	1,52	1,20		
4. Quartal	3.928.571	1,44	1,20		

\* Quellen: SUF: Faktisch anonymisierte Einzeldaten des Mikrozensus 2005; MZ: Unveröffentlichte Fehlerrechnung des Statistischen Bundesamtes.

Unter der Annahme einer einfachen Zufallsstichprobe ist zu erwarten, dass die Variationskoeffizienten von Schätzungen mit dem SUF im Vergleich zum Mikrozensus um rund 20 Prozent  $((1 / 0,7)^{1/2} = 1,19)$  größer sind. Aufgrund der Reduktion des Klumpeneffekts durch die Ziehung der Haushaltssubstichprobe reduzieren sich auch die Variationskoeffizienten (Rendtel und Schimpl-Neimanns 2001: 97). In Tabelle 4 liegen die Variationskoeffizienten des SUF im Vergleich zum Mikrozensus unter diesem Faktor von 1,20 (Deutsche:  $0,78 / 0,69 = 1,13$ ; Ausländer:  $2,13 / 1,85 = 1,15$ ).

## 5 Varianzschätzung für Gesamtwerte mit Regressionsschätzung bzw. gebundener Hochrechnung

Die in Abschnitt 2.2 beschriebenen Kompensations- und Hochrechnungsfaktoren werden ab dem Mikrozensus 2005 mittels Regression bzw. Kalibrierung geschätzt. Der Kalibrierungsansatz (Särndal 2007) beinhaltet nicht nur die Berechnung solcher Gewichte, mit der die Mikrozensus-Fallzahlen u. a. an Randverteilungen der Bevölkerungsfortschreibung und des Ausländerzentralregisters angepasst werden, sondern auch deren Verwendung bei der Varianzschätzung. In diesem Kapitel wird das zugrunde liegende statistische Konzept zusammenfassend dargestellt.<sup>10</sup>

Mit der Regressionsschätzung wird die Anpassung der Stichprobe an Populationsdaten verallgemeinert insofern angenommen wird, dass die Hilfsmerkmale ( $x$ ) einen statistischen Einfluss auf die interessierende Variable ( $y$ ) haben, der durch eine Regression modelliert werden kann (Särndal et al. 1997: 245ff.). Hilfsmerkmale sind z. B. die Merkmale Alter, Geschlecht, Staatsangehörigkeit und Region sowie bestimmte Merkmalskombinationen (siehe Tabelle 3), deren Stichprobenverteilungen an Populationsverteilungen angepasst werden.<sup>11</sup>

In der Stichprobe  $s$  liegen somit für die Personen Hilfsmerkmale  $x_{j1}, \dots, x_{jp}$  vor, deren Gesamtwerte zunächst mit Designgewichtung (Horvitz-Thompson-Schätzung) geschätzt werden:  $\hat{t}_{x,HT} = \sum_{j \in s} d_j x_j$ . In der Population  $U$  sind dazu die Gesamtwerte bekannt:  $t_x = \sum_{j \in U} x_j$ .

Betrachtet man die Werte des interessierenden Merkmals  $y$  als Zufallsvariable, lässt sich der postulierte Zusammenhang durch folgendes Modell  $\xi$  darstellen:

$$E_{\xi}(y_j) = x_j' \beta$$

$$V_{\xi}(y_j) = \sigma_j^2$$

Das Ziel besteht darin, unter Verwendung der Populationsdaten zu den Hilfsmerkmalen  $\hat{t}_{x,HT}$  den Gesamtwert der interessierenden Variablen  $y$  unter Berücksichtigung des Designgewichtes  $d_j = 1/(\pi_j \hat{\theta}_j)$  zu schätzen, wobei  $\pi_j$  die Inklusionswahrscheinlichkeit und  $\hat{\theta}_j$  die für die Korrektur der Haushaltsausfälle geschätzte Antwortwahrscheinlichkeit darstellen.

Die neu zu bestimmenden Gewichte  $w_j = g_j * d_j$  sind dabei so zu wählen, dass die mit  $w_j$  gewichteten Hilfsmerkmale die Populationsverteilungen wiedergeben:  $t_x = \sum_{j \in s} w_j x_j$ . Des Weiteren sollen ab dem Mikrozensus 2005 die Personengewichte innerhalb eines Haushalts gleich sein.<sup>12</sup>

Der verallgemeinerte Regressionsschätzer eines Gesamtwertes (Total) ist in Matrixnotation:

<sup>10</sup> Das Kapitel ist weitestgehend Abschnitt 4.5 in Schimpl-Neimanns 2009 entnommen.

<sup>11</sup> Allgemein werden alle unabhängig von der Stichprobe verfügbaren Informationen als Hilfsmerkmale bezeichnet.

<sup>12</sup> Personen in Gemeinschaftsunterkünften werden jeweils als Einpersonenhaushalt behandelt (Afentakis und Bihler 2005: 1043).

$$\begin{aligned}\hat{t}_{y,reg} &= \sum_{j \in S} \left( 1 + (\mathbf{t}_x - \hat{\mathbf{t}}_{x,HT})' \left( \sum_{j \in S} d_j \mathbf{x}_j \mathbf{x}_j' \right)^{-1} \mathbf{x}_j \right) d_j y_j \\ &= \hat{t}_{y,HT} + \hat{\mathbf{B}}' (\mathbf{t}_x - \hat{\mathbf{t}}_{x,HT})\end{aligned}$$

mit den Regressionskoeffizienten

$$\hat{\mathbf{B}} = \left( \sum_{j \in S} d_j \mathbf{x}_j \mathbf{x}_j' \right)^{-1} \left( \sum_{j \in S} d_j \mathbf{x}_j y_j \right)$$

Werden die Hilfsmerkmale  $\hat{\mathbf{t}}_{x,HT}$  bei designgewichteter Hochrechnung der Stichprobe gegenüber dem Populationswert  $t_x$  unterschätzt und sind sie mit der interessierenden Variablen  $y$  positiv korreliert, dann wird auch der zu schätzende Gesamtwert  $\hat{t}_{y,HT}$  unterschätzt und durch die Regressionsschätzung entsprechend korrigiert. Das Ausmaß der Korrektur hängt von zwei Faktoren ab. Erstens vom Regressionskoeffizienten  $\hat{\mathbf{B}}$ , der mittels linearer Regression der interessierenden Variable  $y$  auf die zur Anpassung verwendeten Hilfsmerkmale  $x$  geschätzt wird. Je enger die Hilfsmerkmale mit der interessierenden Variablen korreliert sind, umso stärker wird die Korrektur ausfallen. Zweitens hängt die Korrektur davon ab, wie nahe die mit der Stichprobe geschätzten Gesamtwerte der Hilfsmerkmale  $\hat{\mathbf{t}}_{x,HT}$  bei den bekannten Gesamtwerten der Population  $t_x$  liegen.

Der im Gewicht  $w_j$  enthaltene Korrekturfaktor  $g_j$ , der in die Schätzung der interessierenden Variable einfließt, gibt den Beitrag der Hilfsmerkmale zur Reduktion von Abweichungen zwischen Stichprobe und Population wieder und kann, wenn keine weiteren Restriktionen vorliegen,<sup>13</sup> wie folgt berechnet werden:

$$g_j = 1 + (\mathbf{t}_x - \hat{\mathbf{t}}_x)' \left( \sum_{j \in S} \frac{\mathbf{x}_j \mathbf{x}_j'}{\pi_j \hat{\theta}_j} \right)^{-1} \mathbf{x}_j$$

Allerdings sind die vom Statistischen Bundesamt bei der Schätzung verwendeten regional differenzierten Populationsdaten im SUF nicht bekannt und der Kompensationsfaktor für Haushaltsausfälle ( $1/\hat{\theta}_j$ ) ist im SUF nicht enthalten. Unter Verwendung der Hochrechnungsfaktoren im SUF können Populationsverteilungen nur auf der regionalen Ebene der Länder geschätzt werden. Somit können die Hochrechnungsfaktoren und der Korrekturfaktor des SUF nur näherungsweise repliziert werden. Deshalb wird der Korrekturfaktor mittels der im SUF vorliegenden Hochrechnungsfaktoren berechnet:

$$g_j = w_j / d_j .$$

Die Regressionsschätzung ergibt für interessierende Merkmale, die zugleich als Hilfsmerkmale bei der Anpassung bzw. Ermittlung des Korrekturfaktors  $g_j$  berücksichtigt wurden, die Gesamtwerte der Population und eine Varianz von Null. Der Einsatz der Original Hochrechnungsfaktoren im SUF führt jedoch zu einer größeren, von Null verschiedenen Varianz, da die Verteilungen des SUF nicht extra an die Populationsverteilungen angepasst wurden.<sup>14</sup> Vorteilhaft ist aber, dass bei der Schätzung von Ge-

<sup>13</sup> Im Mikrozensus ab 2005 werden für die Korrekturfaktoren Unter- und Obergrenzen bestimmt, sodass die Berechnung der Korrekturfaktoren iterativ durchgeführt werden muss (Afentakis und Bihler 2005).

<sup>14</sup> Unter vollständiger Identifikation der Hilfsmerkmale ist bei einer Regression des Hochrechnungsfaktors auf die Hilfsmerkmale ein  $R^2$  von 100 Prozent zu erwarten. Im SUF ergibt die Regression des Hochrechnungsfaktors für Jahresdurchschnitte auf die für die regionale Ebene der Länder abgegrenzten 190 arithmetischen Mittelwerte der Hilfsmerkmale im Haushalt ein  $R^2$  von rund 95 Prozent. Verzichtet man auf die Interaktionen der Hilfsmerkmale für die Länder und verwendet nur 14 auf Bundesebene definierte Hilfsmerkmale, reduziert

samtwerten konsistente und mit Veröffentlichungen der amtlichen Statistik vergleichbare Ergebnisse erreicht werden.

Im Mikrozensus bis 2004 konnten die Regressionskoeffizienten  $\hat{\mathbf{B}}$  aufgrund disjunkter Anpassungsschichten als arithmetisches Mittel der interessierenden Variablen in den einzelnen Anpassungsschichten ermittelt werden (Schimpl-Neimanns 2009: 38). Weil ab 2005 die Anpassung an getrennte Randverteilungen erfolgt (siehe Tabelle 3), müssen die Regressionskoeffizienten geschätzt werden. Dafür sind im SUF 190 Hilfsmerkmale abzugrenzen. Entsprechend zum Korrekturfaktor, der für alle Personen eines Haushalts gleich ist, sind die arithmetischen Mittelwerte der Hilfsmerkmale sowie der Mittelwert des interessierenden Merkmals im Haushalt zu berechnen. Um den damit verbundenen Aufwand zu reduzieren, werden Programme auf den Webseiten von Gesis bereitgestellt.

Der obige Regressionsschätzer des Gesamtwertes lässt sich als gewichtete Summe der  $\gamma$ -Werte bzw. deren Mittelwerte im Haushalt darstellen:

$$(3) \quad \hat{t}_{\gamma,reg} = \sum_{j \in S} w_j \gamma_j$$

Als Schätzung für die Varianz wird die Varianz der Hilfsvariablen  $u_j$ , d. h. der mit dem Korrekturfaktor  $g_j$  gewichteten Residuen  $(y_j - \hat{y}_j)$ , verwendet:<sup>15</sup>

$$(4) \quad u_j = g_j (y_j - \mathbf{x}_j' \hat{\mathbf{B}}) = g_j (y_j - \hat{y}_j)$$

Bei der Schätzung des Stichprobenfehlers unter der Annahme einer einstufigen Ziehung müssen also lediglich Gleichung 1 durch 3 ersetzt und in Gleichung 2 statt der interessierenden Variablen  $y_j$  die gewichteten Residuen  $u_j$  aus Gleichung 4 eingesetzt werden.

Je besser das interessierende Merkmal von den bei der Anpassung berücksichtigten Hilfsmerkmalen statistisch erklärt wird, d. h. je kleiner die (gewichteten) Residuen  $u_j$  der Regression von den  $\gamma$ -Werten auf die Hilfsmerkmale sind, umso geringer ist die Varianz des Regressionsschätzers im Vergleich zur designgewichteten Schätzung.

Die Varianzschätzung wird designbasiert durchgeführt. Da das statistische Modell  $\xi$  nur für die Herleitung des Populationsschätzers dient, wird der Regressionsschätzer als modellgestützt („model assisted“) bezeichnet. Särndal et al. (1997: 239) halten dazu fest: „If the population data are well described by the assumed model, the regression estimator normally will bring about a large variance reduction, as compared to the  $\pi$  estimator [HT-Schätzer; B.S-N.]. If the population is not well described by the model, the improvement on the  $\pi$  estimator may be modest, but the regression estimator still guarantees approximate unbiasedness.“

Gleichwohl ist zu beachten, dass sowohl die Populationsdaten als auch die Stichprobendaten nicht frei von systematischen Fehlern sind. Hinsichtlich der Qualität der Bevölkerungsfortschreibung ist bekannt, dass sie zu hohe Ausländerzahlen aufweist (siehe Opfermann et al. 2006), sodass mit der Anpassung des Mikrozensus an Ergebnisse der Bevölkerungsfortschreibung auch deren Fehler auf den Mikrozensus übertragen werden können. Des Weiteren sind die Zahlen der Erwerbstätigen und Er-

---

sich das  $R^2$  lediglich um ein Prozent. Die mit den Original Hochrechnungsfaktoren entstehende größere Varianz kann als vernachlässigbar betrachtet werden.

<sup>15</sup> In der Darstellung der Fehlerrechnung des Statistischen Bundesamtes (2008: 15) werden die gewichteten Residuen mit  $z_k$  bezeichnet.

werbslosen des Mikrozensus im Vergleich zu anderen Quellen untererfasst, was durch die Hochrechnungsfaktoren nicht ausgeglichen werden kann (Statistisches Bundesamt 2006a). Schließlich kommt es auch zu verzerrten Haushaltsergebnissen, da die zu befragenden Haushalte ungleich auf die zeitlichen Berichtszeiträume verteilt sind (Statistisches Bundesamt 2009). Im gegenwärtigen Kompensations- und Hochrechnungsmodell sind die durch schwer erreichbare Haushalte verbundenen Probleme von Ausfällen und verspätet eintreffenden Interviews nicht ausreichend berücksichtigt.

Wie oben erwähnt, hängt der Erfolg der Korrekturgewichtung bzw. die Chance des Ausgleichs systematischer Fehler maßgeblich von der Korrelation des interessierenden Merkmals mit den bei der Anpassung verwendeten (demografischen) Hilfsmerkmalen ab. Zumindest ist aber gewährleistet, dass die hochgerechneten Ergebnisse des Mikrozensus hinsichtlich der angepassten Populationsmerkmale konsistent sind. Nicht zuletzt können Forscher, die mit den so hochgerechneten Ergebnissen arbeiten, mit der Regressionsschätzung hierfür Varianzschätzungen durchführen. Wie dies praktisch umgesetzt werden kann, zeigt das folgende Beispiel.

Tabelle 5 enthält die Ergebnisse der Regressionsschätzungen. Im Vergleich zur Veröffentlichung des Statistischen Bundesamtes wird mit der Designgewichtung im SUF (siehe Tab. 4) die Zahl der Erwerbslosen um 22 Prozent unterschätzt (3.581.000 vs. 4.583.000). Der mit dem SUF geschätzte Gesamtwert liegt um lediglich 0,3 Prozent darüber. Die geringfügige Abweichung kann mit der Substichprobenziehung und/ oder den nicht extra im SUF angepassten Hochrechnungsfaktoren zusammenhängen.

Tabelle 5: Ergebnisse der Schätzungen der Zahl der Erwerbslosen bei Regressionsschätzung im SUF und im Mikrozensus 2005

	SUF		$t_{y,reg} / t_{y,HT}$	MZ	
	Gesamtwert	cv (%)		Gesamtwert	cv (%)
a) Jahresdurchschnitt					
Insgesamt	4.597.878	0,72	1,3	4.583.000	
Deutsche	3.818.104	0,75	1,2	3.803.468	0,63
Ausländer	779.774	1,95	1,7	774.958	1,63
b) Quartalsergebnisse					
Insgesamt					
1. Quartal	4.702.373	1,51	1,5		
2. Quartal	4.653.052	1,40	1,3		
3. Quartal	4.551.995	1,44	1,3		
4. Quartal	4.484.086	1,35	1,1		

\* Quellen: Siehe Tab. 4. Insgesamt des Mikrozensus bei gebundener Hochrechnung (4.583.000): Statistisches Bundesamt (2006b: 81).

Das Verhältnis  $t_{y,reg} / t_{y,HT}$  entspricht dem arithmetischen Mittelwert des für die gebundene Hochrechnung verwendeten Faktors der Merkmale im SUF.

Die relativen Standardfehler bzw. Variationskoeffizienten der Zahl der Erwerbslosen insgesamt (a) Jahresdurchschnitt) des SUF unterscheiden sich zwischen freier ( $cv = 0,74\%$ ) und gebundener Hochrechnung ( $cv = 0,72\%$ ) nur minimal. Der geringe Präzisionsgewinn war kaum anders zu erwarten, da die Hilfsmerkmale nicht stark mit dem Merkmal Erwerbslos korrelieren ( $R^2 = 0,13$ ). Wie aber der Vergleich der Variationskoeffizienten für ausländische Erwerbslose im SUF bei Designgewichtung ( $cv = 2,13\%$ ) und Regressionsschätzung ( $cv = 1,95\%$ ) zeigt, kann die Reduktion des Stichproben-

fehlers bei gebundener Hochrechnung höher ausfallen, wenn die Hilfsmerkmale stärker mit dem interessierenden Merkmal korrelieren (in diesem Fall:  $R^2 = 0,19$ ).

Beim Jahresdurchschnitt führt die gebundene Hochrechnung im Vergleich zur Designgewichtung zu einer Hochgewichtung der Fallzahlen um 1,3 (Insgesamt), bzw. bei Ausländern um 1,7. Bei Auswertungen des Mikrozensus 1996 lagen diese Faktoren noch bei 1,1 bzw. 1,6 (Rendtel und Schimpl-Neimanns 2001: 107). Zwar ist die Vergleichbarkeit aufgrund der Änderungen des Hochrechnungsverfahrens ab 2005 eingeschränkt, dennoch ist insgesamt seit der Einführung des Stichprobenplans ab dem Mikrozensus 1990 die Tendenz systematisch steigender Hochrechnungsfaktoren festzustellen. Dies korrespondiert damit, dass die Bevölkerungsfortschreibung als zentrale Basis der Hochrechnung des Mikrozensus mit wachsendem zeitlichen Abstand zur letzten Volkszählung zunehmend ungenauer wird (Statistisches Bundesamt 2007: 5). Die Veränderung der mittleren Hochrechnungsfaktoren zwischen dem 1. Quartal (1,5) und 4. Quartal (1,1) des Jahres 2005 weist auch auf Startschwierigkeiten bei der Umsetzung der unterjährigen Durchführung des Mikrozensus hin.

## 6 Varianzschätzung für Verhältniswerte mit Designgewichtung

In der Forschungspraxis werden häufig Verhältnis- oder Anteilswerte berechnet, d. h. das Verhältnis der Gesamtwerte von zwei Merkmalen  $\hat{Y}$  und  $\hat{Z}$ .

$$(5) \quad \hat{R} = \hat{Y} / \hat{Z}$$

Bei Designgewichtung ist die Kovarianz der Zähler- und Nennermerkmale zu berücksichtigen. Die asymptotische Varianz ist

$$(6) \quad \hat{V}(\hat{R}) = \frac{1}{\hat{Z}^2} \{ \hat{V}(\hat{Y}) - 2\hat{R}\hat{V}(\hat{Y}, \hat{Z}) + \hat{R}^2\hat{V}(\hat{Z}) \}$$

Für die Varianzschätzung wird die Hilfsvariable (score variable) benutzt (Stata 2007: 155):

$$(7) \quad u_j(\hat{R}) = \frac{y_j - \hat{R}z_j}{\hat{Z}}$$

Die Schätzung von Populationsmittelwerten kann gleichermaßen vorgenommen werden. In den meisten Fällen beziehen sich Mittelwerte auf eine Subpopulation. Bei dieser Schätzung für eine Teilmenge (Domain) der Grundgesamtheit durch die Stichprobe mittels einer Indikatorvariablen für die Zugehörigkeit zur Subpopulation ist lediglich  $\hat{Z}$  durch den (hochgerechneten) Umfang der Subpopulation  $\hat{N}$  im Nenner auszutauschen.

Der Einfachheit halber wird das obige Beispiel mit der Berechnung der Erwerbslosenquote fortgeführt. Die Erwerbslosenquote ist definiert als Anteil der Erwerbslosen ( $y$ ) an den Erwerbspersonen ( $z$ ).

*Tabelle 6:* Ergebnisse der Schätzungen der Erwerbslosenquote bei Designgewichtung im SUF und im Mikrozensus 2005

	SUF		DEFT	MZ	
	Anteil (%)	cv (%)		Anteil (%)	cv (%)
	a) Jahresdurchschnitt				
Insgesamt	11,1	0,69	1,16		
Deutsche	10,4	0,73	1,14	10,4	0,63
Ausländer	19,8	1,78	1,11	19,7	1,52
	b) Quartalsergebnisse				
Insgesamt					
1. Quartal	11,5	1,44			
2. Quartal	11,3	1,38			
3. Quartal	10,8	1,40			
4. Quartal	10,8	1,34			

\* Quellen: Siehe Tab. 4.

Die Erwerbslosenquote liegt in dieser einfachen beispielhaften Auswertung im Jahresdurchschnitt insgesamt bei elf Prozent, für Ausländer dagegen bei 20 Prozent. Der Variationskoeffizient bzw. relative Standardfehler (cv) beträgt bei der Verhältnisschätzung 0,69 Prozent (insgesamt; Ausländer: 1,78 %) und ist aufgrund der Kovariation zwischen Zähler- und Nennermerkmal geringer als der Variationsko-

effizient bei der Schätzung des Gesamtwertes von Erwerbslosen in Beispiel 1 ( $cv = 0,74\%$ ). Die ab 2005 erstmals ermittelbaren unterjährigen Ergebnisse zeigen zwischen dem ersten und vierten Quartal eine leicht rückläufige Erwerbslosenquote von 11,5 auf 10,8 Prozent.



## 7 Varianzschätzung für Verhältniswerte mit Regressionsschätzung bzw. gebundener Hochrechnung

Das Verhältnis zweier Gesamtwerte mit gebundener Hochrechnung kann wie in Kapitel 5 beschrieben geschätzt werden. Die Regressionsschätzungen sind für das Zähler- und für das Nennermerkmal durchzuführen. Da sowohl im Zähler- als auch im Nennermerkmal die gleichen Hilfsmerkmale verwendet werden, kann der Korrekturfaktor  $g_j$  wie oben gezeigt geschätzt werden. Ebenfalls ist das Gewicht  $w_j$  gleich.

Der Regressionsschätzer des Verhältniswertes ist (Särndal et al. 1997: 294f.)

$$(8) \quad \hat{R} = \hat{Y}_r / \hat{Z}_r$$

mit

$$\hat{Y}_r = \sum_{j \in S} w_j y_j \quad \text{und} \quad \hat{Z}_r = \sum_{j \in S} w_j z_j$$

Sowohl für das Zähler- als auch für das Nennermerkmal werden Regressionsschätzungen durchgeführt und die gewichteten Residuen als Hilfsvariablen bei der Varianzschätzung verwendet (siehe Gleichung 4).

$$u_{yj} = g_j (y_j - \mathbf{x}'_j \hat{\mathbf{B}}) = g_j (y_j - \hat{y}_j)$$

$$u_{zj} = g_j (z_j - \mathbf{x}'_j \hat{\mathbf{B}}) = g_j (z_j - \hat{z}_j)$$

Die für Verhältniswerte allgemeine Formel der Varianzschätzung (siehe Gleichung 6) wird auch hier eingesetzt (Särndal et al. 1997: 296). Im Unterschied zur Hilfsvariablen in Gleichung 7 steht jedoch in Gleichung 9 nicht der Gesamtwert des gewichteten Residuums ( $u_{zk}$ ), sondern der gewichtete Gesamtwert des Nennermerkmals des Verhältniswertes  $\hat{Z}$  im Nenner.

$$(9) \quad u_j(\hat{R}) = \frac{u_{yj} - \hat{R}u_{zj}}{\hat{Z}}$$

Tabelle 7 enthält die entsprechenden Schätzungen. Im Jahresdurchschnitt wird die Erwerbslosenquote bei gebundener Hochrechnung mit 11,3 Prozent im Vergleich zur Designgewichtung (insgesamt: 11,1 %) geringfügig höher geschätzt, desgleichen der Standardfehler, wobei sich aber die relativen Standardfehler (geb. Hochrechnung:  $cv = 0,70\%$  vs. freie Hochrechnung:  $cv = 0,69\%$ ) nicht wesentlich unterscheiden (siehe Tab. 6). Dass keine Varianzreduktion auftritt (und tendenziell sogar eine schwache Zunahme zu beobachten ist), hängt damit zusammen, dass die Hilfsmerkmale in diesem Beispiel nicht zur statistischen Erklärung der Differenz ( $y_j - \hat{R}z_j$ ) beitragen (siehe Särndal et al. 1997: 296).

*Tabelle 7:* Ergebnisse der Schätzungen der Erwerbslosenquote bei Regressionsschätzung im SUF und im Mikrozensus 2005

	SUF		MZ	
	Anteil (%)	cv (%)	Anteil (%)	cv (%)
	a) Jahresdurchschnitt			
Insgesamt	11,3	0,70		
Deutsche	10,4	0,74	10,3	0,63
Ausländer	20,6	1,83	20,4	1,53
	b) Quartalsergebnisse			
Insgesamt				
1. Quartal	11,7	1,48		
2. Quartal	11,5	1,38		
3. Quartal	11,1	1,41		
4. Quartal	11,0	1,33		

\* Quellen: Siehe Tab. 4.

## 8 Schluss

---

Ein wichtiges Gütekriterium der Scientific Use Files des Mikrozensus besteht darin, dass Forscher veröffentlichte Ergebnisse der statistischen Ämter replizieren können. Die Veröffentlichungen der amtlichen Statistik basieren i. d. R. auf einer gebundenen Hochrechnung, mit der die Fallzahlen des Mikrozensus an bekannte Populationsverteilungen angepasst werden. Hinsichtlich der Schätzung von Gesamt- und Verhältniswerten kann festgehalten werden, dass bei Gewichtung des Scientific Use Files mit den darin enthaltenen Hochrechnungsfaktoren weitestgehend zu amtlichen Veröffentlichungen vergleichbare Ergebnisse erzielt werden. Auftretende Differenzen sind auf die Substichprobenziehung und Anonymisierung zurückzuführen und i. d. R. vernachlässigbar gering.

Der Stichprobenfehler ist ein weiterer wichtiger Indikator für die Beurteilung der Qualität von Schätzungen, die auf der Grundlage der Scientific Use Files durchgeführt werden. Hierfür enthalten die Daten anonymisierte Informationen zum Stichprobendesign sowie zur Hochrechnung, sodass Forscher grundsätzlich in der Lage sind, selbst Schätzungen des Stichprobenfehlers vorzunehmen. Im Zuge der Umstellung auf eine kontinuierliche Erhebung mit gleitender Berichtswoche wurde ab dem Mikrozensus 2005 auch das Hochrechnungsverfahren geändert. Die für den Mikrozensus bis 2004 verfügbaren Beispielprogramme können damit nicht mehr eingesetzt werden. In diesem Bericht wurde deshalb gezeigt, wie mit den Scientific Use Files des Mikrozensus ab 2005 Schätzungen durchgeführt werden können. Die Konstruktion der dafür benötigten arithmetischen Mittelwerte der Hilfsmerkmale im Haushalt ist mit einem gewissen Aufwand verbunden, kann aber vielfältig für weitere Schätzungen eingesetzt werden. Die hierzu unter [Mikrodaten-Tools](#) im Gesis-Web bereitgestellten Programme für PASW bzw. SPSS, SAS und Stata können diesen einmaligen Aufwand verringern.

Das Analysepotenzial des Mikrozensus liegt nicht nur in der Verfügbarkeit sozioökonomischer Strukturdaten im Querschnitt, sondern die ab 1973 zugänglichen Scientific Use Files erlauben auch die Analyse von Strukturveränderungen und entsprechende Trenddatenanalysen werden zunehmend durchgeführt. Die Überlappung von Erhebungseinheiten (partielle Rotation) ist mit dem methodischen Vorteil der Reduktion des Stichprobenfehlers bei der Untersuchung von Differenzen oder Veränderungsquoten von Populationsschätzungen verbunden. Dieser Vorteil kann gegenwärtig nicht genutzt werden. Damit dies möglich wird, wäre das Merkmal der Zugehörigkeit zur Rotationsgruppe im Scientific Use File bereitzustellen.

Vor dem Hintergrund offener methodischer Fragen im Kontext der Berücksichtigung von Haushaltsausfällen und spät antwortenden Haushalten bei der Hochrechnung könnte die Bereitstellung des Kompensationsgewichts im Scientific Use File dazu beitragen, dass auch vonseiten der akademischen Forschung Methodenstudien durchgeführt werden können.

## Literatur

---

- Afentakis, Anja, und Wolf Bihler, 2005: Das Hochrechnungsverfahren beim unterjährigen Mikrozensus ab 2005. [Wirtschaft und Statistik \(10\): 1039-1048](#). URL: <http://www.destatis.de/jetspeed/portal/cms/Sites/destatis/Internet/DE/Content/Publikationen/Querschnittsveroeffentlichungen/WirtschaftStatistik/Mikrozensus/Hochrechnungunterjaehrig.property=file.pdf>.
- Gabler, Siegfried, und Horst Stenger, 2006: Systematische Primärauswahl mit Anwendungen in Wirtschafts- und Sozialstatistik. S. 37-50 in: Hans Wolfgang Brachinger, Alfred Hamerle, Ralf Münich und Walter Schweitzer (Hg.): *Wirtschaftsstatistik. Festschrift zum 65. Geburtstag von Professor Dr. Dr. h.c. mult. Eberhard Schaich*. München: Vahlen.
- Heidenreich, Hans-Joachim, 1994: Hochrechnung des Mikrozensus ab 1990. S. 112-123 in: Siegfried Gabler, Jürgen H. P. Hoffmeyer-Zlotnik und Dagmar Krebs (Hg.): *Gewichtung in der Umfragepraxis*. Opladen: Westdeutscher Verlag.
- Herberger, Lothar, 1985: Aktualität und Genauigkeit der repräsentativen Statistik der Bevölkerung und des Erwerbslebens. *Allgemeines Statistisches Archiv* 69: 16-55.
- Krug, Walter, Martin Nourney und Jürgen Schmidt, 2001: *Wirtschafts und Sozialstatistik. Gewinnung von Daten*. München: Oldenbourg (6. völlig Neubearbeitete und erweiterte Auflage).
- Meyer, Kurt, 1994: Zum Auswahlplan des Mikrozensus ab 1990. S. 106-111 in: Siegfried Gabler, Jürgen H. P. Hoffmeyer-Zlotnik und Dagmar Krebs (Hg.): *Gewichtung in der Umfragepraxis*. Opladen: Westdeutscher Verlag.
- Opfermann, Heike, Claire Grobecker und Elle Krack-Roberg, 2006: Auswirkung der Bereinigung des Ausländerzentralregisters auf die amtliche Ausländerstatistik. *Wirtschaft und Statistik* (5): 480-494.
- Rendtel, Ulrich, und Bernhard Schimpl-Neimanns, 2001: Die Berechnung der Varianz von Populationsschätzern im Scientific Use File des Mikrozensus ab 1996. [ZUMA-Nachrichten 48: 85-116](#). URL: [http://www.gesis.org/Publikationen/Zeitschriften/ZUMA\\_Nachrichten/documents/pdfs/48/zn48\\_10-bernhard.pdf](http://www.gesis.org/Publikationen/Zeitschriften/ZUMA_Nachrichten/documents/pdfs/48/zn48_10-bernhard.pdf).
- Särndal, Carl-Erik, 2007: The calibration approach in survey theory and practice. *Survey Methodology* 33(2): 99-119.
- Särndal, Carl-Erik, Bengt Swensson und Jan Wretman, 1997: *Model Assisted Survey Sampling*. New York: Springer (korrigierte vierte Auflage).
- Schimpl-Neimanns, Bernhard, 2009: Schätzung des Stichprobenfehlers im Mikrozensus mit Stata – Eine Einführung mit Beispielen zum Campus File Mikrozensus 2002. [GESIS-Methodenbericht 2009/02](#). Mannheim: GESIS. URL: [http://www.gesis.org/fileadmin/upload/forschung/publikationen/gesis\\_reihen/gesis\\_methodenberichte/2009/gesis\\_mb\\_09\\_02.pdf](http://www.gesis.org/fileadmin/upload/forschung/publikationen/gesis_reihen/gesis_methodenberichte/2009/gesis_mb_09_02.pdf).
- Schimpl-Neimanns, Bernhard, und Ulrich Rendtel, 2001: SAS-, SPSS- und STATA-Programme zur Berechnung der Varianz von Populationsschätzern im Mikrozensus ab 1996. [ZUMA-Methodenbericht 2001/04](#). Mannheim: ZUMA. URL: [http://www.gesis.org/fileadmin/upload/dienstleistung/tools\\_standards/mikrodaten\\_tools/Varianz/SP-Fehler/tb01\\_04.pdf](http://www.gesis.org/fileadmin/upload/dienstleistung/tools_standards/mikrodaten_tools/Varianz/SP-Fehler/tb01_04.pdf)
- Stata, 2007: *Stata Survey Data Reference Manual*. Release 10. College Station, TX: Stata Press.
- Statistisches Bundesamt, 2006a: Mikrozensus und Arbeitskräfteerhebungen. Zur Problematik nichtstichprobenbedingter Fehler. [Methodenpapier](#). Wiesbaden. URL: <http://www.destatis.de/jetspeed/portal/cms/Sites/destatis/Internet/DE/Content/Wissenschaftsforum/MethodenVerfahren/Mikrozensus/Veroeffentlichungen/PapierMikrozensusArbeitskraefteerhebung.property=file.pdf>.
- Statistisches Bundesamt, 2006b: [Fachserie 1, Reihe 4.1.1](#), Bevölkerung und Erwerbstätigkeit, Stand und Entwicklung der Erwerbstätigkeit, Band 2: Deutschland. Ergebnisse des Mikrozensus 2005.

Wiesbaden. URL: <https://www-ec.destatis.de/csp/shop/sfg/bpm.html.cms.cBroker.cls?cmspath=struktur,vollanzeige.csp&ID=1019220>.

Statistisches Bundesamt, 2007: [Qualitätsbericht Bevölkerungsfortschreibung](#). Wiesbaden. URL: <http://www.destatis.de/jetspeed/portal/cms/Sites/destatis/Internet/DE/Content/Publikationen/Qualitaetsberichte/Bevoelkerung/Bevoelkerungsfortschreibung.property=file.pdf>.

Statistisches Bundesamt, 2008: [Fachserie 1, Reihe 3](#). Bevölkerung und Erwerbstätigkeit, Haushalte und Familien. Ergebnisse des Mikrozensus 2007. Wiesbaden. URL: <https://www-ec.destatis.de/csp/shop/sfg/bpm.html.cms.cBroker.cls?cmspath=struktur,vollanzeige.csp&ID=1022463>.

Statistisches Bundesamt, 2009: Mikrozensus: Haushaltszahlen ab 2005 [[Methodenpapier](#)]. Wiesbaden. URL: <http://www.destatis.de/jetspeed/portal/cms/Sites/destatis/Internet/DE/Content/Wissenschaftsforum/MethodenVerfahren/Mikrozensus/MikrozensusHaushaltszahlen.property=file.pdf>.

Steel, David G., und Robert G. Clark, 2007: Person-level and household-level regression estimates in household surveys. *Survey Methodology* 33(1): 51-60.