

Warum reicht eine Stichprobe aus?

Möglichkeiten und Grenzen des Zensus 2011
DAGSTAT Symposium, DIW Berlin

Ralf Münnich

Universität Trier, Fachbereich IV, VWL
Wirtschafts- und Sozialstatistik

Berlin, 08. April 2011

Warum reicht eine Stichprobe aus?

Vorbemerkungen zum Zensus 2011

Fehler in Erhebungen

Die Stichprobenerhebung im Zensus 2011

Wie werden Zensus-Ergebnisse ermittelt

Zusammenfassung

Das Team des Zensus-Stichprobenforschungsprojektes



- ▶ Ralf Münnich (CO)
- ▶ Jan Pablo Burgard, Jan-Philipp Kolb,
Lucie Dostál, Martin Vogt



- ▶ Siegfried Gabler
- ▶ Matthias Ganninger

Externe Experten:

- ▶ Professor Partha Lahiri, University of Maryland, JPSM
- ▶ Professor Ulrich Rendtel, FU Berlin

Aufgaben des Projektes

- ▶ Analyse von möglichen Stichprobendesigns
 - ▶ Design des Zensustests
 - ▶ Variationen des Stichprobendesigns
 - ▶ Optimales Stichprobendesign
- ▶ Ermittlung einer geeigneten Schätzmethodik
 - Ziel 1 Korrektur der Registerdaten
 - ▶ Schätzung von Karteileichen und Fehlbeständen
 - ▶ Ermittlung der amtlichen Bevölkerungszahl
 - Ziel 2 Schätzung von zusätzlichen Personenmerkmalen
- ▶ Analyse der Wirkung des Stichprobendesigns auf die Schätzungen
 - ▶ Entwicklung adäquater Fehlerrechnungen
 - ▶ Entwicklung geeigneter Qualitätskriterien

Aufgaben des Projektes

- ▶ Analyse von möglichen Stichprobendesigns
 - ▶ Design des Zensustests
 - ▶ Variationen des Stichprobendesigns
 - ▶ Optimales Stichprobendesign
- ▶ Ermittlung einer geeigneten Schätzmethodik
 - Ziel 1 Korrektur der Registerdaten
 - ▶ Schätzung von Karteileichen und Fehlbeständen
 - ▶ Ermittlung der amtlichen Bevölkerungszahl
 - Ziel 2 Schätzung von zusätzlichen Personenmerkmalen
- ▶ Analyse der Wirkung des Stichprobendesigns auf die Schätzungen
- ▶ Entwicklung adäquater Fehlerrechnungen
- ▶ Entwicklung geeigneter Qualitätskriterien

Wo passieren Fehler in Erhebungen

Nicht-Stichprobenfehler

- ▶ Nonresponse (Unit/Item)
- ▶ Messfehler
- ▶ Angabefehler
- ▶ Registerfehler (Karteileichen und Fehlbeständen)

Stichprobenfehler

- ▶ in Folge verschiedener möglicher Stichproben, die gezogen werden können (Zufallsfehler)
- ▶ auf Grund von Modellannahmen in bestimmten Verfahren
- ▶ auf Grund kleiner (Teil-) Stichprobenumfänge

Wo passieren Fehler in Erhebungen

Nicht-Stichprobenfehler

- ▶ Nonresponse (Unit/Item)
- ▶ Messfehler
- ▶ Angabefehler
- ▶ Registerfehler (Karteileichen und Fehlbeständen)

Stichprobenfehler

- ▶ in Folge verschiedener möglicher Stichproben, die gezogen werden können (Zufallsfehler)
- ▶ auf Grund von Modellannahmen in bestimmten Verfahren
- ▶ auf Grund kleiner (Teil-) Stichprobenumfänge

Ergebnisse des Zensustests 2001

- ▶ Karteileichen: 1,8 %
- ▶ Fehlbestände: 1,7 %
- ▶ Große Differenzen zwischen den Gemeinden
 - Karteileichen:
 - ▶ 0,7% in Gemeinden bis 10 000 Einwohner
 - ▶ 1,4% in Gemeinden mit 10 000 - 50 000 Einwohner
 - ▶ 1,5% in Gemeinden mit 50 000 - 100 000 Einwohner
 - ▶ 3,4% in Gemeinden mit 100 000 und mehr Einwohner
 - Fehlbestände:
 - ▶ 1,3% in Gemeinden bis 10 000 Einwohner
 - ▶ 1,3% in Gemeinden mit 10 000 - 50 000 Einwohner
 - ▶ 2,1% in Gemeinden mit 50 000 - 100 000 Einwohner
 - ▶ 2,4% in Gemeinden mit 100 000 und mehr Einwohner
- ▶ Weitere Abhängigkeiten: z.B. Adressgröße

Präzisionsvorgaben für den Zensus 2011

Ziel 1 Für jede Gemeinde bzw. Stadtteil g :

$$\text{RRMSE}(\hat{\tau}_{Z\langle g \rangle}) = \frac{\text{RMSE}(\hat{\tau}_{Z\langle g \rangle})}{\tau_{Z\langle g \rangle}} \leq 0,005$$

Ziel 2 Ist der Anteil interessierender Beobachtungen an der Zensus-Bevölkerung gleich p , dann muss im Falle von $p \geq 1/15$

$$\text{RRMSE}(\hat{\tau}_{Y\langle \text{area} \rangle}) \leq \frac{1}{p \cdot 100}$$

gelten.

Anteil Merkmalsträger (in %)	6,7	10	20	30	50	80
Relativer Standardfehler (in %)	15	10	5	3,33	2	1,5

Ausgangspunkt: Schäfer-Design

Gemeinde ab 10.000 EW Ziehung von 550 Anschriften

Gemeinde unter 10.000 EW Ziehung eines *Anteils* von 550
Anschriften (proportional zu EW einer Gemeinde am Kreis)

Schäfer, J. (2004): Ergänzende Verfahren für einen künftigen registergestützten Zensus. In: Statistische Analysen und Studien Nordrhein-Westfalen, Band 17, S. 20-27, Landesamt für Datenverarbeitung und Statistik Nordrhein-Westfalen.

Variationen

- ▶ Berücksichtigung von Stadtteilen
- ▶ Berücksichtigung von Verbandsgemeinden

Ausgangspunkt: Schäfer-Design

Gemeinde ab 10.000 EW Ziehung von 550 Anschriften

Gemeinde unter 10.000 EW Ziehung eines *Anteils* von 550
Anschriften (proportional zu EW einer Gemeinde am Kreis)

Schäfer, J. (2004): Ergänzende Verfahren für einen künftigen registergestützten Zensus. In: Statistische Analysen und Studien Nordrhein-Westfalen, Band 17, S. 20-27, Landesamt für Datenverarbeitung und Statistik Nordrhein-Westfalen.

Variationen

- ▶ Berücksichtigung von Stadtteilen
- ▶ Berücksichtigung von Verbandsgemeinden

Welche Besonderheiten müssen berücksichtigt werden?

- ▶ Welche gesetzlichen Bestimmungen sind zu beachten?
 - ▶ Ziehung von Anschriften
 - ▶ Etwa 10% der Bevölkerung
- ▶ Weitere zu beachtende Besonderheiten
 - ▶ Effizienz versus Machbarkeit
 - ▶ Berücksichtigung der hierarchischen Struktur (Ziel 2)
 - ▶ Beurteilungskriterien: RRMSE
 - ▶ Multikriterielle Betrachtung
- ▶ Wahl eines Designs, das die Präzisionsanforderungen einhält
 - ▶ Welches Schätzverfahren wird zu Grunde gelegt?
 - ▶ Wie werden die Zielvorgaben präzisiert?
 - ▶ Wo werden *tatsächlich* Stichproben gezogen?

Welche Besonderheiten müssen berücksichtigt werden?

- ▶ Welche gesetzlichen Bestimmungen sind zu beachten?
 - ▶ Ziehung von Anschriften
 - ▶ Etwa 10% der Bevölkerung
- ▶ Weitere zu beachtende Besonderheiten
 - ▶ Effizienz versus Machbarkeit
 - ▶ Berücksichtigung der hierarchischen Struktur (Ziel 2)
 - ▶ Beurteilungskriterien: RRMSE
 - ▶ Multikriterielle Betrachtung
- ▶ Wahl eines Designs, das die Präzisionsanforderungen einhält
 - ▶ Welches Schätzverfahren wird zu Grunde gelegt?
 - ▶ Wie werden die Zielvorgaben präzisiert?
 - ▶ Wo werden *tatsächlich* Stichproben gezogen?

Welche Besonderheiten müssen berücksichtigt werden?

- ▶ Welche gesetzlichen Bestimmungen sind zu beachten?
 - ▶ Ziehung von Adressen
 - ▶ Etwa 10% der Bevölkerung
- ▶ Weitere zu beachtende Besonderheiten
 - ▶ Effizienz versus Machbarkeit
 - ▶ Berücksichtigung der hierarchischen Struktur (Ziel 2)
 - ▶ Beurteilungskriterien: RRMSE
 - ▶ Multikriterielle Betrachtung
- ▶ Wahl eines Designs, das die Präzisionsanforderungen einhält
 - ▶ Welches Schätzverfahren wird zu Grunde gelegt?
 - ▶ Wie werden die Zielvorgaben präzisiert?
 - ▶ Wo werden *tatsächlich* Stichproben gezogen?

Wie erfolgt die Einteilung in Stichprobenbasiseinheiten

- Typ 0 (SDT): Stadtteile ab 200.000 Einwohner (EW) aus Gemeinden mit mindestens 400.000 EW
- Typ 1 (GEM): Gemeinden mit mindestens 10.000 EW, sofern sie nicht zum Typ 0 gehören
- Typ 2 (VBG): Kleine Gemeinden (unter 10.000 EW) innerhalb eines Gemeindeverbands beziehungsweise einer Verbandsgemeinde werden zusammengefasst, sofern sie in der Summe mindestens 10.000 EW betragen
- Typ 3 (KRS): Zusammenfassung aller Gemeinden eines Kreises, die bis dahin noch keinem Typ zugeordnet wurden


SMPs in Deutschland

SMP 0

SMP 1

SMP 2

SMP 3



Der Optimierungsalgorithmus

- ▶ Ausgangspunkt: Neyman-Optimierung
- ▶ Unter- und Obergrenzen der Entnahmeanteile der Anschriften in jeder Schicht und in jedem Sampling Point
 - ▶ Berücksichtigung von Anschriftengröße als Schichtmerkmal
 - ▶ Variierende Grenzen nach Gemeindegrößenklasse
 - ▶ Einschränkung der Variabilität der Gewichte (Gelman)
- ▶ Obergrenze des Entnahmeanteils an Personen in Deutschland
- ▶ Ziel: Simultane Minimierung des RRMSE-Vektors:
$$\|\mathbf{RRMSE}_{\langle \cdot \rangle}(\hat{\tau})\|_2 = \sqrt[2]{\sum_{g=1}^G \mathbf{RRMSE}(\tau_{\langle g \rangle})^2}$$
- ▶ Lösung durch iterativen Algorithmus:
Gabler, Ganninger und Münnich (2010), Metrika (on-line first)
Münnich, Sachs und Wagner (2011)

Referenz-Schätzer $\hat{\tau}_{Y,\text{GREG}}$ (je SMP)

$$\hat{\tau}_{Y,\text{GREG}} = \sum_{h=1}^H N_h \cdot \left(\bar{y}_h + (\bar{\mathbf{X}}_h - \bar{\mathbf{x}}_h)' \cdot \hat{\beta} \right)$$

Notation:

- N_h Anzahl der Adressen in der h -ten Schicht
- \bar{y}_h Stichprobenmittel von y in der h -ten Schicht
- $\bar{\mathbf{X}}_h$ Vektor der Mittelwerte von x in der h -ten Schicht
- $\bar{\mathbf{x}}_h$ Vektor der Stichprobenmittel von x in der h -ten Schicht
- $\hat{\beta}$ geschätzter Regressionsparameter

mit
$$V(\hat{\tau}_y) = \sum_{h=1}^H N_h^2 \cdot \frac{S_{h,Y}^2}{n_h} \cdot \left(1 - \frac{n_h}{N_h} \right) \cdot (1 - \varrho^2)$$

Referenz-Schätzer $\hat{\tau}_{Y,\text{GREG}}$ (je SMP)


$$\hat{\tau}_{Y,\text{GREG}} = \sum_{h=1}^H N_h \cdot \left(\bar{y}_h + (\bar{\mathbf{X}}_h - \bar{\mathbf{x}}_h)' \cdot \hat{\beta} \right)$$

Notation:

- N_h Anzahl der Anschriften in der h -ten Schicht
- \bar{y}_h Stichprobenmittel von y in der h -ten Schicht
- $\bar{\mathbf{X}}_h$ Vektor der Mittelwerte von x in der h -ten Schicht
- $\bar{\mathbf{x}}_h$ Vektor der Stichprobenmittel von x in der h -ten Schicht
- $\hat{\beta}$ geschätzter Regressionsparameter

mit
$$V(\hat{\tau}_y) = \sum_{h=1}^H N_h^2 \cdot \frac{S_{h,Y}^2}{n_h} \cdot \left(1 - \frac{n_h}{N_h} \right) \cdot (1 - \rho^2)$$


Wie funktioniert der Referenz-Schätzer



Y: Anzahl der (Zensus-) Personen in einer Anschrift

X: Anzahl der registrierten Personen in einer Anschrift


Wie funktioniert der Referenz-Schätzer



Y: Anzahl der (Zensus-) Personen in einer Anschrift

X: Anzahl der registrierten Personen in einer Anschrift


Wie funktioniert der Referenz-Schätzer



Y: Anzahl der (Zensus-) Personen in einer Anschrift

X: Anzahl der registrierten Personen in einer Anschrift


RRMSE bei SMP-optimaler Allokation




Verwendung von BA-Daten

- ▶ Schätzung *überwiegender Lebensunterhalt* (UBS)
- ▶ Hilfsvariablen:
 - ▶ Anzahl der Personen unter der Anschrift (ADN)
 - ▶ Altersklassen (15-24, 25-39, 40-64)
 - ▶ Geschlecht
 - ▶ Registervariable: Erwerbstätigkeit (EWT; Daten der BA)
- ▶ Schätzmethoden:
 - GREG**: Referenzschätzverfahren
 - YOURAO**: Modernes Small Area-Verfahren
 - SYNTHA**: Synthetisches Verfahren (Modell)

Schätzung UBS in Baden-Württemberg



Schätzung UBS in Rheinland-Pfalz



Zusammenfassung

- ▶ Die Stichprobe reicht aus, um die gegebenen (a priori) Qualitätskriterien zu erfüllen
- ▶ Optimierung der Stichprobenumfänge als multikriterielles Ziel (über alle SMPs) ist gelungen
- ▶ Ziel 1 kann *klassisch* geschätzt werden
- ▶ Ziel 2: in tieferen Tabellen werden erweiterte Methoden benötigt
- ▶ Veröffentlichungen
 - ▶ Statistisches Bundesamt: Haushaltebefragung beim Zensus 2011, <http://www.zensus2011.de>
 - ▶ MGGBK: Stichprobendesign und Schätzmethodik im registergestützten Zensus (provisorischer Titel)
- ▶ Wir sind schon ganz gespannt auf den Zensus 2011!

Zusammenfassung

- ▶ Die Stichprobe reicht aus, um die gegebenen (a priori) Qualitätskriterien zu erfüllen
- ▶ Optimierung der Stichprobenumfänge als multikriterielles Ziel (über alle SMPs) ist gelungen
- ▶ Ziel 1 kann *klassisch* geschätzt werden
- ▶ Ziel 2: in tieferen Tabellen werden erweiterte Methoden benötigt
- ▶ Veröffentlichungen
 - ▶ Statistisches Bundesamt: Haushaltebefragung beim Zensus 2011, <http://www.zensus2011.de>
 - ▶ MGGBK: Stichprobendesign und Schätzmethodik im registergestützten Zensus (provisorischer Titel)
- ▶ Wir sind schon ganz gespannt auf den Zensus 2011!

Zusammenfassung

- ▶ Die Stichprobe reicht aus, um die gegebenen (a priori) Qualitätskriterien zu erfüllen
- ▶ Optimierung der Stichprobenumfänge als multikriterielles Ziel (über alle SMPs) ist gelungen
- ▶ Ziel 1 kann *klassisch* geschätzt werden
- ▶ Ziel 2: in tieferen Tabellen werden erweiterte Methoden benötigt
- ▶ Veröffentlichungen
 - ▶ Statistisches Bundesamt: Haushaltebefragung beim Zensus 2011, <http://www.zensus2011.de>
 - ▶ MGGBK: Stichprobendesign und Schätzmethodik im registergestützten Zensus (provisorischer Titel)
- ▶ Wir sind schon ganz gespannt auf den Zensus 2011!