

Anonymisierung von Einzeldaten aus dem Datenbestand der integrierten Lohn- und Einkommenssteuerstatistik 2020

Bernhard Meindl

Juni 2023

Inhaltsverzeichnis

| | | |
|----------|--|----------|
| 1 | Einleitung | 1 |
| 2 | Besonderheiten des Datensatzes | 2 |
| 2.1 | Originaldaten | 2 |
| 2.2 | Modifikation der Originaldaten | 2 |
| 3 | Geheimhaltung | 2 |
| 3.1 | Software | 2 |
| 3.2 | Direkte Identifikationsvariablen | 2 |
| 3.3 | Indirekte Identifikationsvariablen | 3 |
| 3.4 | Die Stichprobe | 3 |
| 3.5 | Schlüsselvariablen für die Geheimhaltung | 3 |
| 3.6 | Lokale Unterdrückung | 4 |
| 3.7 | Mikroaggregation | 5 |
| 4 | Zusammenfassung | 5 |
| 5 | Anhang (Datenbeschreibung) | 6 |
| 5.1 | Im SDS enthaltene Variablen | 6 |
| 6 | Referenzen | 9 |

1 Einleitung

Ein Ziel der Bundesanstalt STATISTIK AUSTRIA ist es, ausgewählte Mikrodatensätze der amtlichen Statistik für die wissenschaftlichen Forschung und Lehre aufzubereiten und in Form von Standardisierten Datensätzen (SDS) über die [Webseite der Statistik Austria](#) bereitzustellen. Als Standardisierte Datensätze werden in diesem Rahmen Einzeldatensätze bezeichnet, die insbesondere in Bezug auf die Wahrung des Datenschutzes angepasst wurden. Die Wahrung der Interessen der Respondenten wird dabei durch die Anwendung statistischer Anonymisierungsverfahren gewährleistet. Durch gezielte Reduktion des Informationsgehalts des entsprechenden Datensatzes wird erreicht, dass das Risiko einer erfolgreichen Identifikation einer konkreten statistischen Einheit sehr gering ausfällt. Weiters müssen Datennutzer Nutzungsbestimmungen akzeptieren, in denen etwa festgehalten wird, dass keine De-Anonymisierungsversuche durchgeführt werden dürfen.

In dieser Arbeit wird die Erstellung eines anonymisierten Datensatzes aus der integrierten Lohn- und Einkommenssteuerstatistik 2020 beschrieben. Der anonymisierte Datensatz enthält insgesamt 74015 Beobachtungen und besteht aus 14 Variablen. Die Anonymisierung wurde in mehreren Schritten durchgeführt und lehnt sich methodisch stark an die von der Statistik Austria bereits durchgeführte Erstellung von standardisier-

ten Datensätzen der Lohnsteuerstatistik 2006-2019 - sowie der Erstellung eines SDS aus dem Bestand der Einkommenssteuer für 2005 an.

Der anonymisierte Datensatz kann sowohl als reine Text-Datei (csv-File zum einfachen Import etwa in Microsoft Excel) als auch als **R-Datensatz** bezogen werden.

2 Besonderheiten des Datensatzes

2.1 Originaldaten

Der SDS der integrierten Lohn- und Einkommenssteuer 2020 basiert auf dem entsprechenden authentischen Datenbestand. Aus den umfangreichen Informationen dieses Datensatzes wurden schließlich insgesamt 14 Variablen ausgewählt, die - zusammen mit den durchgeführten Datenmodifikationen - in Anhang (5) beschrieben sind.

2.2 Modifikation der Originaldaten

Es wird nun kurz beschrieben, auf welche Art und Weise bestehende Variablen aus dem authentischen Datenbestand für den SDS modifiziert wurden, um der Geheimhaltung Rechnung zu tragen.

Die Variable *gebjahr* im authentischen Datenbestand zeigt das Geburtsjahr einer Person. Die Angabe des Geburtsjahres könnte unter Umständen - zusammen in Verbindung mit zusätzlicher Information - die Reidentifikation einer Person ermöglichen. Deshalb wurde das Geburtsjahr in eine neue Variable *ALTER* - bestehend aus 8 Altersgruppen - umkodiert. Aus Anhang (5) ist die Definition der Altersgruppen ersichtlich.

Die im authentischen Datenbestand existierende tiefe Gliederung der Wirtschaftsklassifikation ÖNACE (2008) ist für den anonymisierten Datensatz zu detailliert. Angreifer könnten durch Kombination dieser Information mit anderen (kategoriellen) Variablen unter Umständen einzelne Einheiten korrekt identifizieren. Aus diesem Grund war es notwendig, die ursprüngliche Gliederung der Wirtschaftsklassifikation zu vergrößern und in eine neue Variable *OENACE* umzukodieren. In dieser Variable wurden verschiedene ÖNACE 2-Steller zu 1-Stellern aggregiert. Die exakte Gliederung der neu erstellten Variable *OENACE* geht aus Anhang (5) hervor.

3 Geheimhaltung

Es wird nun die Anonymisierungsprozedur beschrieben, die durchgeführt wurde um aus dem authentischen Datenbestand der integrierten Lohn- und Einkommenssteuerstatistik 2020 einen SDS-File zu erzeugen.

3.1 Software

Nach dem Vorbereiten des Rohdatensatzes mit SAS wurde die weitergehende Anonymisierungsprozedur mit der freien Statistiksoftware **R** (R Core Team, 2023) sowie dem von Statistik Austria entwickelten und frei verfügbaren Zusatzpaket **sdcMicro** (Templ, Kowarik, and Meindl, 2015) (statistical disclosure control for **micro**data) durchgeführt. Das Package kann von den Servern des R Comprehensive Archive Network (**CRAN**) heruntergeladen werden. **sdcMicro** weist wesentliche Vorteile gegenüber der für Geheimhaltung von Mikrodaten empfohlenen ‘Standardsoftware’ μ -Argus auf. Außerdem wird **sdcMicro** ständig aktualisiert, verbessert und weiterentwickelt.

3.2 Direkte Identifikationsvariablen

Direkte Identifikationsvariablen ermöglichen es einem Datenangreifer, bestimmte Personen in einem Datensatz eindeutig zu identifizieren. Solche Variablen müssen daher aus einem Standardisierten Datensatz entfernt werden um den Geheimhaltungsanforderungen gerecht werden zu können. Ein Beispiel für eine direkte Identifikationsvariable wäre die Sozialversicherungsnummer, die von einem Angreifer dazu genutzt werden könnte, eine Person im Standardisierten Datensatz eindeutig zu identifizieren.

In den Datenbeständen der Lohn- und Einkommensteuerstatistiken ist als eindeutige Kennung für eine Person (= Personenschlüssel) nur das *“bereichsspezifische Personenkennzeichen - Amtliche Statistik” (bPK AS)* enthalten, das aber insofern keine *“richtige”* Identifikationsvariable darstellt, als daraus ein Rückschluss auf die zugehörige Person nicht möglich ist. Das *bPK AS* wurde nicht in den SDS aufgenommen.

3.3 Indirekte Identifikationsvariablen

Kann durch Kombination mehrerer (meist kategorialer) Variablen eine Person eindeutig im Datensatz identifiziert werden, so werden diese Variablen als indirekte Identifikationsvariablen bezeichnet. In diesem Zusammenhang ist es jedoch wichtig festzustellen, dass keine der indirekten Identifikationsvariablen für sich selbst zur eindeutigen Identifizierung einer Person im Datensatz ausreichen muss.

Indirekte Identifikationsvariablen in den Variablen der integrierten Lohn- und Einkommenssteuer, die für die Erstellung des SDS vorgesehen sind, sind etwa das Geburtsdatum (*VGEBDAT*), das Bundesland (*BLD*) oder Information über den Schwerpunkt der Tätigkeit (*SP8*) einer Person. Kategorielle Variablen können vergrößert oder umkodiert werden um das Risiko einer Reidentifikation einer Person gering zu halten. Letztlich kann es sein, dass in den indirekten Identifikationsvariablen wenige Werte unterdrückt bzw. gelöscht werden müssen um weitestgehende Anonymität gewährleisten zu können. Die an den im anonymisierten Datensatz vorhandenen Variablen durchgeführten Umkodierungen und Vergrößerungen sind in Anhang (5) aufgelistet.

3.4 Die Stichprobe

Der erste Schritt bei der Erstellung eines Standardisierten Datensatzes für die integrierte Lohn- und Einkommenssteuerstatistik 2020 besteht darin, eine Stichprobe aus dem vollständigen, authentischen Datensatz zu ziehen. Hinsichtlich der Geheimhaltung bietet eine Stichprobe den Vorteil, dass nicht alle Objekte der Grundgesamtheit im veröffentlichten Mikrodatsatz enthalten sind. Daher kann sich ein Angreifer selbst bei einer vermeintlichen Identifikation einer Person nicht sicher sein, dass die identifizierte Person die ist, an der er interessiert ist. Durch die Auswahl einer Teilmenge für den Standardisierten Datensatz kann ein Angreifer nicht wissen, ob eine Zielperson in der Stichprobe enthalten ist.

Für die Erstellung eines SDS aus der integrierten Lohn- und Einkommenssteuerstatistik des Jahres 2020 wurde eine geschichtete Zufallsstichprobe mit einheitlichem Auswahlatz von 1% innerhalb der Schichten gezogen. Als Schichtungsvariablen wurden folgende Merkmale verwendet:

- **BLD**: 10 Ausprägungen
- **GESCHL**: 2 Ausprägungen
- **ALTER**: 9 Ausprägungen

Die gezogene Stichprobe besteht aus insgesamt 74015 Beobachtungen und enthält zu den 14 ausgewählten Variablen auch noch das resultierende Hochrechnungsgewicht.

3.5 Schlüsselvariablen für die Geheimhaltung

Indirekte Identifikationsvariablen, deren Ausprägungskombinationen ein Angreifer verwenden könnte, um eine eindeutige Identifikation einer Person im Datensatz vorzunehmen, werden als Schlüsselvariablen bezeichnet. Für diesen Datenbestand wurden folgende Schlüsselvariablen definiert.

- **BLD**: 10 Ausprägungen
- **ALTER**: 9 Ausprägungen
- **OENACE**: 12 Ausprägungen
- **GESCHL**: 2 Ausprägungen
- **SP8**: 3 Ausprägungen

Zu bemerken ist, dass die Variable *SP8* für den Vorgang der Anonymisierung mit nur 3 Ausprägungen verwendet wurde. Im finalen SDS ist diese Variable jedoch mit 7 Ausprägungen (siehe Anhang 5) enthalten.

Im Zuge der Anonymisierungsprozedur werden einzelne Schlüsselvariablen modifiziert, indem sie entweder

vergrößert oder umkodiert werden. Eine weitere Möglichkeit besteht darin, einzelne Werte in den Schlüsselvariablen zu löschen um schließlich einen sicheren SDS mit hohem Analysepotential zu erhalten.

3.6 Lokale Unterdrückung

Für jede Merkmalskombination der Schlüsselvariablen wird ein individuelles Reidentifikationsrisiko berechnet. Dabei ist neben der Anzahl an Personen, die eine spezifische Ausprägungskombination der Schlüsselvariablen aufweist auch das Hochrechnungsgewicht wesentlich. Der Einfluss des Hochrechnungsgewichtes ergibt sich aus der Tatsache, dass Personen mit einem hohen Hochrechnungsgewicht grundsätzlich ein höheres Reidentifikationsrisiko aufweisen. Diese Personen müssen besonders geschützt werden.

Basierend auf der gezogenen Stichprobe und den ausgewählten (und gegebenenfalls modifizierten) Schlüsselvariablen weisen 588 Beobachtungen eine einzigartige (unique) Ausprägungskombination in den Schlüsselvariablen auf. Außerdem gibt es weitere 650 Personen, deren Ausprägungskombination der Schlüsselvariablen genau zweimal vorkommen. Im Zuge der Anonymisierungsprozedur soll durch gezielte Sperrungen in den Schlüsselvariablen erreicht werden, dass jeder Ausprägungskombination zumindest 3 Personen zugeordnet werden kann. Dies wird auch als *3-Anonymity* bezeichnet.

Reidentifikationsrisiko (BLD x ALTER x OENACE x GESCHL x SP8)




Abbildung 1: Individuelles Identifikationsrisiko in den Originaldaten.

Abbildung (1) zeigt das individuelle Reidentifikationsrisiko vor der Unterdrückung von Werten in den Schlüsselvariablen. Man erkennt, dass das Reidentifikationsrisiko für die allermeisten Beobachtungen sehr gering ist. Personen mit hohem Reidentifikationsrisiko müssen zusätzlich geschützt werden. Dies geschieht indem schrittweise Sperrungen in Schlüsselvariablen durchgeführt werden. Es ergeben sich folgende Sperrungen:

- Variable **SP8**: 963 Sperrungen (1.301 %)
- Variable **OENACE**: 269 Sperrungen (0.363 %)
- Variable **GESCHL**: 9 Sperrungen (0.012 %)
- Variable **BL**: 2 Sperrungen (0.003 %)

Durch das Sperren dieser Werte im Datensatz kann *3-Anonymität* gewährleistet werden. Das bedeutet, dass jede Ausprägungskombination der Schlüsselvariablen im Datensatz zumindest dreimal existiert.

Abbildung (2) zeigt das individuelle Reidentifikationsrisiko im Datensatz nach Durchführen der lokalen

Unterdrückung in den Schlüsselvariablen. Man erkennt, dass für die im SDS vorhandenen Personen ein sehr geringes Reidentifikationsrisiko besteht. Insbesondere sei auf die unterschiedliche Skalierung der x -Achsen in Abbildung (1) und (2) hingewiesen.




Abbildung 2: Individuelles Reidentifikationsrisiko im anonymisierten Datensatz.

3.7 Mikroaggregation

Unter Umständen besteht die Möglichkeit dass ein Datenangreifer ihm bekannte Informationen über einen (Prozent)Wert einer numerischen Variable heranzieht, um eine Person im Datensatz erfolgreich zu identifizieren. Insbesondere *Ausreißer* in numerischen Variablen können in Verbindung mit Informationen über andere Schlüsselvariablen dazu verwendet werden, eine positive Identifizierung zu erreichen.

Mikroaggregation numerischer Variablen bietet zusätzlichen Schutz gegen Reidentifizierungsversuche. Mikroaggregation bedeutet grundsätzlich, dass möglichst *ähnliche* Objekte in einem ersten Schritt gruppiert werden. In einem zweiten Schritt werden schließlich die Ausprägungen einer numerischen Variablen der gewählten Personen durch eine Statistik ersetzt. Bei der verwendeten Statistik handelt es sich oftmals um den Mittelwert. Durch die Mikroaggregation numerischer Variable wird sichergestellt, dass jede einzelne Ausprägung mehrfach im Datensatz auftritt.

Aus Anhang (5) geht hervor, welche Variablen des Standardisierten Datensatzes der integrierten Lohn- und Einkommenssteuerstatistik 2020 mikroaggregiert wurden. Bei diesen Variablen werden grundsätzlich mehrere ähnliche Werte durch ein Aggregat ersetzt. Die Anwendung von Mikroaggregation schützt die Einzeldaten vor direktem Matching.

4 Zusammenfassung

Die Aufbereitung und Bereitstellung sensibler Mikrodaten - wie etwa Steuerdaten - für wissenschaftliche Forschung und Lehre ist ein komplexer Prozess. Insbesondere muss Hauptaugenmerk auf die Anonymisierung der Daten gelegt werden um die gegebenen rechtlichen Anforderungen zu erfüllen.

Da nur eine 1% Stichprobe des vollständigen authentischen Datenbestands für die Veröffentlichung als Standardisierter Datensatz aufbereitet wurde, kann sich ein Datenangreifer auch bei vermeintlicher positiver

Identifizierung einer Person aufgrund mehrerer Variablen nicht sicher sein, ob die identifizierte Person überhaupt für die Stichprobe ausgewählt wurde. Durch die weiters angewandten Anonymisierungsverfahren wie die Aggregation beziehungsweise das Umkodieren kategorialer Variablen, dem Ersetzen kritischer Werte in den Schlüsselvariablen durch *missings* und durch Mikroaggregation numerischer Variablen wurde erreicht, dass das Reidentifikationsrisiko aller im SDS verbleibenden Daten sehr gering ist. Allerdings ist anzumerken, dass es 100%-igen Schutz vor Reidentifizierung nicht geben kann. Ein sehr geringes Restrisiko bleibt bestehen.

Die gewählte Methodik zur Erstellung des Standardisierten Datensatzes für die integrierte Lohn- und Einkommenssteuerstatistik 2020 gleicht in vielen Bereichen der Erstellung standardisierter Datensätze aus dem Datenbestand der Lohnsteuerstatistik bzw. der Einkommenssteuerstatistik. Der Anonymisierungsprozess wurde mit der hausintern entwickelten Software **sdcMicro** durchgeführt. Beim Erstellen des SDS wurde immer darauf geachtet, trotz der notwendigen Anonymisierung der Daten das hohe Analysepotential der Daten bestmöglich zu erhalten. Der vorliegende standardisierte Datensatz wird diesem Anspruch gerecht.

5 Anhang (Datenbeschreibung)

5.1 Im SDS enthaltene Variablen

Hier werden die Variablen beschrieben, die im SDS für 2020 enthalten sind. Für jede Variable ist gegebenenfalls die Art der Modifikation (vergrößert, mikroaggregiert, ...) angegeben. Außerdem wird noch einmal aufgelistet, ob eine Variable als Schlüsselvariable für die Geheimhaltung betrachtet wurde. Weiters wurden die Variablennamen verschiedenfärbig markiert, wobei Variablen, die in schwarzer Schrift aufscheinen, nicht verändert wurden. Variablen, die mit **blau** gekennzeichnet sind wurden modifiziert oder neu erzeugt. Ist eine Variable **rot** eingefärbt bedeutet dies, dass die Variable mikroaggregiert wurde.

5.1.1 **ID** (Modifikation: neu erstellt)

generierte Identifikationsvariable.

Codes: fortlaufend

5.1.2 **BL** (Modifikation: Schlüsselvariable | Vergrößerung)

Bundesland des Wohnsitzes.

Codes:

- 0: Ausland/unbekannt
- 1: Burgenland
- 2: Niederösterreich
- 3: Wien
- 4: Kärnten
- 5: Steiermark
- 6: Oberösterreich
- 7: Salzburg
- 8: Tirol
- 9: Vorarlberg
- NA: fehlend

5.1.3 GESCHL (Modifikation: Schlüsselvariable)

Geschlecht.

Codes:

- 1: männlich
- 2: weiblich

5.1.4 ALTER (Modifikation: Schlüsselvariable | Vergrößerung)

Altersklassen, erstellt aus dem Geburtsdatum.

Codes:

- 1: 15 Jahre und jünger
- 2: 16-25 Jahre
- 3: 26-35 Jahre
- 4: 36-45 Jahre
- 5: 46-55 Jahre
- 6: 56-60 Jahre
- 7: 61-65 Jahre
- 8: 66 Jahre und älter
- NA: fehlend

5.1.5 SP8 (Modifikation: Schlüsselvariable)

Schwerpunkt der Beschäftigung.

Codes:

- 1: Arbeitnehmer ausschließlich
- 2: Arbeitnehmer schwerpunktmäßig
- 3: Arbeitnehmer nicht schwerpunktmäßig
- 4: Pensionisten ausschließlich
- 5: Pensionisten schwerpunktmäßig
- 6: Pensionisten nicht schwerpunktmäßig
- 7: Bezieher von übrigen Einkünften

5.1.6 OENACE (Modifikation: Schlüsselvariable | Vergrößerung)

ÖNACE 1-Steller, aggregiert aus 2-Stellern der ÖNACE 2008.

Codes:

- 0: unbekannt
- 1: 2-Steller < 15
- 2: 2-Steller ≥ 15 und < 40

- 3: 2-Steller ≥ 40 und < 45
- 4: 2-Steller ≥ 45 und < 50
- 5: 2-Steller ≥ 50 und < 55
- 6: 2-Steller ≥ 55 und < 60
- 7: 2-Steller ≥ 60 und < 65
- 8: 2-Steller ≥ 65 und < 70
- 9: 2-Steller ≥ 70 und < 75
- 10: 2-Steller ≥ 75 und < 90
- 11: 2-Steller ≥ 90
- NA: fehlend

5.1.7 **GESEIN1** (Modifikation: Mikroaggregation)

Gesamteinkommen mit Transfereinkünften.

Codes: numerisch

5.1.8 **STEUGES** (Modifikation: Mikroaggregation)

Gesamtsteuer.

Codes: numerisch

5.1.9 **NETTO** (Modifikation: Mikroaggregation)

Nettoeinkommen.

Codes: numerisch

5.1.10 **KZ0210A** (Modifikation: Mikroaggregation)

Lohneinkünfte (inkl. Pensionseinkünfte).

Codes: numerisch

5.1.11 **EINK** (Modifikation: Mikroaggregation)

übrige Einkünfte.

Codes: numerisch

5.1.12 **TRANSGES** (Modifikation: Mikroaggregation)

Transfereinkünfte insgesamt.

Codes: numerisch

5.1.13 **STBEMGR** (Modifikation: Mikroaggregation)

Steuerbemessungsgrundlage.

Codes: numerisch

5.1.14 SAMPWEIGHT

Stichprobengewicht.

Codes: numerisch

6 Referenzen

[1] R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria, 2023. <https://www.R-project.org/>.

[2] M. Templ, A. Kowarik, and B. Meindl. “Statistical Disclosure Control for Micro-Data Using the R Package sdcMicro”. In: *Journal of Statistical Software* 67.4 (2015), pp. 1-36. DOI: 10.18637/jss.v067.i04.