

## Neuerungen in der Gewichtung des DEAS

*FDZ-DZA, März 2023*

Die folgenden Abschnitte gehen detailliert auf Änderungen in der Gewichtung ein, die sich aus drei Gründen ergeben haben:

- A) Zum einen muss die Kurzbefragung aus dem Sommer 2020 in das Gewichtungsschema integriert werden. Die Kurzbefragung 2020 enthält aber nicht alle Merkmale, die normalerweise in den Ausfallmodellen der regulären Erhebungen berücksichtigt werden. In diesem Dokument werden die Abweichungen dargestellt.
- B) Zum anderen hatte das DEAS-Team in Zusammenarbeit mit dem FDZ geprüft, ob es sinnvoll ist, die Ausfallmodelle geringfügig zu erweitern, um systematische Verzerrungen aufgrund von omitted-variable-bias zu vermeiden. Die Anpassungen, auch wenn nur geringfügig, finden für die Erhebung 2020/21 und für alle folgenden Erhebungen Anwendung und sind hier ebenfalls dokumentiert.
- C) Es ist in der DEAS Welle 2020 und in der anschließenden Welle 2020/21 zum ersten Mal möglich gewesen, die 91-100-jährigen Befragten in der Postratifizierung zu berücksichtigen. Aus diesem Grund gibt es die Querschnittsgewichtungsfaktoren ab 2020 in zwei Ausführungen: `qsps_2020`, `qsps_21` sowie `qspsdrop_20` und `qspsdrop_21` umfassen die volle Altersrange der bis zu 100-jährigen Befragten. Die Gewichtungsfaktoren `qsps_20_u91`, `qsps_21_u91` und `qspsdrop_21_u91` umfassen die gleichen Gewichte, enthalten aber keine Werte für die Befragten die 91 Jahre oder älter sind.

*Die folgenden Ausführungen basieren zu großen Teilen wörtlich auf dem Methodenbericht von Schiel et al. 2021.<sup>1</sup> Veränderungen und Abweichungen im Vergleich zu den Vorwellen des DEAS wurden aber durch zusätzliche Tabellen und Erläuterungen durch das FDZ des DZA ergänzt.*

<sup>1</sup> Schiel, S., Ruiz Marcos, J., Schulz, S., Dickmann, C. & Fahrenholz, M. (2021). Methodenbericht. Deutscher Alterssurvey (DEAS): Durchführung der 7. Erhebungswelle 2020/21. Bonn: infas. URL: <https://www.dza.de/forschung/fdz/deutscher-alterssurvey/deas-dokumentation>.

## 1 Querschnittsgewichte – ab 2020 inklusive der 91- bis 100-Jährigen

Aufgrund der Alterung der Bevölkerung in Deutschland ist nun auch die sehr alte Bevölkerungsgruppe der 91-100-Jährigen in der amtlichen Statistik in ausreichender Zahl repräsentiert, so dass sie für die Postratifizierung der DEAS-Daten herangezogen werden können. Während dies für die vorherigen Wellen nicht möglich war, ist es ab der Kurzbefragung 2020 möglich geworden. Das hat zwei Konsequenzen: 1) die Querschnittsgewichte `qsps` und `qspsdrop` decken bis inklusive 2017 die Bevölkerung unter 91 Jahren ab. Ab 2020 bilden `qsps_20` und `qsps_21` sowie `qspsdrop_21` die Bevölkerung bis inklusive 100 Jahren ab. Aus diesem Grund gibt es ab der Welle 2020 die `qsps`-Querschnittsgewichte in doppelter Ausführung

Querschnittsgewichtungsfaktoren für:

<u>Welle</u>	<u>Befragte unter 91 Jahre:</u>	<u>Befragte bis 100 Jahre</u>
2002	<code>qsps_02, qspsdrop_02,</code>	
2008	<code>qsps_08, qspsdrop_08,</code>	
2011	<code>qsps_11, qspsdrop_11,</code>	
2014	<code>qsps_14, qspsdrop_14,</code>	
2017	<code>qsps_17, qspsdrop_17,</code>	
2020	<code>qsps_20_u91,</code>	<code>qsps_20</code>
2021	<code>qsps_21_u91, qspsdrop_21_u91</code>	<code>qsps_21, qspsdrop_21</code>

Bei Trendanalysen die keine explizite Altersbegrenzungen definieren (z.B. auf die bis 90-Jährigen mit Hilfe von `if`-Bedingungen), müssen Nutzer:innen auf die korrekte Wahl der Querschnittsgewichte achten.

## 2 Längsschnittgewichtung 2017-2021

### 2.1 Mündliche Interviews

Zur Berechnung der Längsschnittgewichte werden Ausfallmodelle (Logistische Regression) zur Bestimmung der Teilnahmewahrscheinlichkeit von Welle 2017 zu Welle 2021 berechnet. Grundgesamtheit des Modells sind Teilnehmer (Panelfälle) mit gültigen Interviews in der Ausgangswelle 2017 abzüglich Personen, von denen bekannt wurde, dass sie zwischen den beiden Wellen verstorben sind. Berechnet wird die individuelle Wahrscheinlichkeit einer Teilnahme in der aktuellen Welle. Prädiktoren eines jeden Modells sind die folgenden im vom DZA editierten Datensatz der Erhebung 2017 enthaltenen Merkmale, die vom DZA bereitgestellt wurden:

- Landesteil: West (Früheres Bundesgebiet und Berlin-West), Ost (Neue Bundesländer und Berlin-Ost)

- Kreistypen, gruppiert: kreisfreie Großstädte, städtische Kreise, ländliche Kreise
- Alter, gruppiert nach Quartilen (d.h. Aufteilung in vier etwa gleich stark besetzte Altersgruppen)
- Geschlecht: männlich, weiblich
- Bildungsabschluss (ISCED), gruppiert: niedrig, mittel, hoch (mit Zuordnung der Fälle mit fehlender Angabe zu der Kategorie „niedrig“)
- Netzwerkgröße, gruppiert: bis zwei Personen, drei bis fünf Personen, sechs und mehr Personen
- Äquivalenzeinkommen, gruppiert nach Terzilen (mit Zuordnung der Fälle mit fehlender Angabe zum mittleren Terzil)
- Subjektiver Gesundheitsstatus, gruppiert: sehr gut/gut, mittel, schlecht/sehr schlecht (inkl. missing)
- Drop-Off-Status: in Ausgangswelle kein DO/ in Ausgangswelle mit DO

Berücksichtigt werden die Ausprägungen der jeweiligen Variablen in der Welle 2017. Das Geschlecht ist konstant, Informationen zu Bildung und Landesteil werden aus der jeweils ersten DEAS-Teilnahmejahrwelle übernommen.

Für eine multiplikative Verknüpfung der Teilnahmewahrscheinlichkeiten als Gewichtungsfaktor wird die reziproke Teilnahmewahrscheinlichkeit (1/Teilnahmewahrscheinlichkeit) benötigt.

## 2.2 Drop-Off

Zur Berechnung der Längsschnittgewichte der Drop-Off-Interviews wird ein Ausfallmodell (logistische Regression) zur Bestimmung der Teilnahmewahrscheinlichkeit am Drop-Off gerechnet. Grundgesamtheit des Modells sind Panelfälle mit Teilnahme in der Ausgangswelle 2017 sowie Teilnahme am Interview in der Betrachtungswelle 2021. Prädiktoren der Modelle sind:

- Landesteil: West (Früheres Bundesgebiet und Berlin-West), Ost (Neue Bundesländer und Berlin-Ost)
- Geschlecht: männlich, weiblich
- Bildungsabschluss (ISCED), gruppiert: niedrig, mittel, hoch (mit Zuordnung der Fälle mit fehlender Angabe zu der Kategorie „niedrig“)
- Alter, gruppiert nach Quartilen (d.h. Aufteilung in vier etwa gleich stark besetzte Altersgruppen)
- Drop-Off-Status: in Ausgangswelle kein DO/ in Ausgangswelle mit DO.

Der Landesteil und die Bildung beziehen sich auf die erste Erhebungswelle eines Falls, das Geschlecht ist konstant. Das Alter ist das Alter zum Zeitpunkt der Betrachtungswelle. DO-Status bezieht sich auf die Ausgangswelle (2017).

Die so berechnete individuelle Teilnahmewahrscheinlichkeit wird als reziproke Teilnahmewahrscheinlichkeit (1/Teilnahmewahrscheinlichkeit) multiplikativ mit dem berechneten Längsschnittgewicht verknüpft. Die so entstehenden Längsschnittgewichte für die Drop-Offs passen die Verteilungen für die am Drop-Off teilnehmenden

Panelfälle an die Verteilungen in der Vorwelle (Ausgangswelle) an. Sie beziehen sich somit auf den Betrachtungszeitraum von der Ausgangswelle 2017 zum Drop-Off der Betrachtungswelle 2021.

### 3 Besonderheit 2021: Längsschnittgewichtung 2020-2021

Im Sommer des Jahres 2020 hat eine ausschließlich schriftliche Kurzbefragung stattgefunden. Diese Erhebung diente der schnellen Erfassung der Folgen der Corona-Pandemie und basierte auf der Bruttoseinsatzstichprobe des DEAS. Die Wahrscheinlichkeit, dass die Befragten im Jahr 2020/21 an der regulären DEAS-Befragung teilnahmen, ist mit sehr hoher Wahrscheinlichkeit nicht unabhängig von deren (Nicht-) Teilnahme an der Kurzbefragung im Sommer 2020. Je nach gewählten längsschnittlichen Studiendesign können daher Längsschnittgewichte auch von der Kurzbefragung auf die aktuelle Befragung erforderlich sein. Aus diesem Grund wird zusätzlich zur Längsschnittgewichtung für den Zeitraum von 2017 zu 2021 eine Gewichtung von der Kurzbefragung 2020 zur regulären Panelbefragung 2021 durchgeführt. Diese erfolgt analog zum oben skizzierten Vorgehen auf Basis von Daten aus der Kurzbefragung 2020 und bezieht sich auf den Betrachtungszeitraum von der Ausgangswelle 2020 zur Betrachtungswelle 2020/21. Allerdings sind zwei Prädiktoren, die für die Berechnung des Längsschnittgewichts 2017-2021 verwendet werden, nicht in der Kurzbefragung 2020 enthalten: in der Kurzbefragung wird die Netzwerkgröße nicht erfasst und es ist auch nicht möglich, das Äquivalenzeinkommen zu bestimmen. Aus diesem Grund werden zwei alternative Maße verwendet: Haushaltsgröße und das ungewichtete Haushaltsnettoeinkommen pro Kopf. Die Variable DO-Status wird für die Längsschnittgewichtung ausgehend von der Kurzbefragung 2020 nicht berücksichtigt. Die Teilnahme an der Kurzbefragung war de facto bereits ein Drop-Off, nämlich ein Papierfragebogen zum Selbstausfüllen. Für das Drop-Off-Gewichtungsmodell Kurzbefragung 2020 auf CATI 2021 ergaben sich keine Abweichungen vom in Punkt 1.2. beschriebenen Verfahren. Die Ausnahme ist die Variable Drop-Off Status, die sich nicht auf die Ausgangswelle, sondern auf die letzte Teilnahmewelle vor der Ausgangswelle 2020 bezieht.

**Abgleich der Prädiktoren der Längsschnittgewichtung 2017-2021 und 2020-2021**

Prädiktoren	Ausprägungen/Codierung	2017 auf CATI 2021	Kurzbefragung 2020 auf CATI 2021
Landesteil	West (Früheres Bundesgebiet und Berlin-West), Ost (Neue Bundesländer und Berlin-Ost), bezogen auf Erstbefragung	√	√
Kreistypen	gruppiert: kreisfreie Großstädte, städtische Kreise, ländliche Kreise	√	√
Alter	gruppiert nach Quartilen (d.h. Aufteilung in vier etwa gleich stark besetzte Altersgruppen)	√	√
Geschlecht	männlich, weiblich	√	√
Bildungsabschluss	gruppiert (ISCED): niedrig, mittel, hoch (mit Zuordnung der Fälle mit fehlender Angabe zu der Kategorie „niedrig“)	√	√
Netzwerkgröße	gruppiert: bis zwei Personen, drei bis fünf Personen, sechs und mehr Personen	√	<i>Nicht möglich</i>
Haushaltsgröße	gruppiert: 1 Person, 2 Personen, 3 oder mehr Personen, missing/keine Angabe	-	√
Äquivalenzeinkommen	gruppiert nach Terzilen (mit Zuordnung der Fälle mit fehlender Angabe zum mittleren Terzil)	√	<i>Nicht möglich</i>
ungewichtetes HH-Einkommen pro Kopf	gruppiert nach Terzilen (mit Zuordnung der Fälle mit fehlender Angabe zum mittleren Terzil)	-	√
subjektive Gesundheit	gruppiert: sehr gut/gut, mittel, schlecht/sehr schlecht (inkl. missing)	√	√
DO-Status	in Ausgangswelle kein DO/ in Ausgangswelle mit DO	√	

## 4 Querschnittsgewichtung/ Integration der Stichproben in einen gemeinsamen Querschnitt

### 4.1 Mündliche Interviews

Für die Bildung von Querschnittsgewichten müssen alle Teilnehmenden der aktuellen Welle in eine gemeinsame Querschnittstichprobe integriert werden. Diese Teilstichproben sind in der aktuellen Befragung:

- Panelfälle mit Teilnahme in der Vorwelle 2017 (Wiederteilnehmende)
- Panelfälle ohne Teilnahme in der Vorwelle 2017 (Temporäre Ausfälle)

Das Ausgangsgewicht für die Integration ist bei den wiederteilnehmenden Panelfällen das Längsschnittgewicht in der Betrachtungswelle. Für die temporären Ausfälle wurde ein Hilfsgewicht erstellt. Basis für dieses Hilfsgewicht war das Querschnittgewicht der Welle, in dem die Befragten das letzte Mal teilgenommen haben. Dieses Gewicht wurde anhand der Ergebnisse zweier Ausfallmodelle adjustiert: (1) Die individuelle Wahrscheinlichkeit einer Nicht-Teilnahme in der Folgewelle nach der letzten Teilnahme (1-Teilnahmewahrscheinlichkeit) wurde in den Ausfallmodellen der Längsschnittgewichtung berechnet. (2) Zur Bestimmung der individuellen Wahrscheinlichkeit in der Betrachtungswelle teilzunehmen, unter der Voraussetzung in der Vorwelle (bzw. in den Vorwellen) nicht teilgenommen zu haben (Rückkehrwahrscheinlichkeit), wurden separate logistische Regressionen gerechnet. Grundgesamtheit der jeweiligen Modelle sind alle Panelfälle ohne Teilnahme in der Ausgangswelle (Vorwelle der Betrachtungswelle). Prädikatoren eines jeden Modells sind:

- Landesteil: West (Früheres Bundesgebiet und Berlin-West), Ost (Neue Bundesländer und Berlin-Ost)
- Geschlecht: männlich, weiblich
- Alter, gruppiert nach Quartilen
- Bildungsabschluss ISCED gruppiert: niedrig, mittel, hoch (mit Zuordnung der Fälle mit fehlender Angabe zu der Kategorie „niedrig“)

Der Landesteil und die Bildungsangaben beziehen sich auf die erste DEAS-Teilnahme der Befragten, das Geschlecht ist konstant. Das Alter ist das Alter zum Zeitpunkt der Ausgangswelle des Modells.

Zur Bildung des Hilfsgewichts für die Integration in den Querschnitt werden folgende Elemente multiplikativ verknüpft: Querschnittgewicht der Welle in dem die Befragten das letzte Mal teilgenommen haben, reziproke Wahrscheinlichkeit der Nicht-Teilnahme in der Folgewelle nach der letzten Teilnahme (1-Teilnahmewahrscheinlichkeit aus den Ausfallmodellen zur Berechnung der Längsschnittgewichte), reziproke Rückkehrwahrscheinlichkeit in der Betrachtungswelle.

Die Startgewichte aller Teilstichproben werden konvex zusammengefügt. Dieses Verfahren berücksichtigt die Tatsache, dass die Personen auch in den jeweils anderen Stichproben eine Auswahlwahrscheinlichkeit hatten.

Zusätzlich erfolgt eine Anpassung der Verteilungen Geburtsjahr\*Geschlecht\*Landesteil in der Stichprobe an bekannte Verteilungen in der Grundgesamtheit (Mikrozensus) mittels Iterative Proportional Fitting (IPF). Grundlage hierfür ist die vom DZA bereits übermittelte Referenztabelle mit den Verteilungszahlen aus dem Mikrozensus 2020<sup>2</sup>, differenziert nach Geburtsjahrgangsgruppen, Geschlecht und Landesteil.

## 4.2 Drop-Off

Zur Bestimmung der Querschnittgewichte des Drop-Offs werden auf Basis aller Befragten Ausfallmodelle (Logistische Regression) zur Bestimmung der Teilnahmewahrscheinlichkeit am Drop-Off-Interview in der gleichen Welle teilzunehmen gerechnet. Prädiktoren des Modells sind:

- Landesteil: West (Früheres Bundesgebiet und Berlin-West), Ost (Neue Bundesländer und Berlin-Ost)
- Geschlecht: männlich, weiblich
- Bildungsabschluss ISCED gruppiert: niedrig, mittel, hoch (mit Zuordnung der Fälle mit fehlender Angabe zu der Kategorie „niedrig“)
- Alter, gruppiert nach Quartilen
- DO-Status: in der letzten Welle kein DO/ in der letzten Welle mit DO.

Der Landesteil und die Bildungsangaben beziehen sich auf den Zeitpunkt der Ersterhebung, das Geschlecht ist konstant. Das Alter ist das Alter zum Zeitpunkt der Betrachtungswelle. Der Drop-Off Status bezieht sich auf die Welle, in der die Befragten vor der aktuellen Befragung zuletzt teilgenommen haben. Die Kurzbefragung 2020 zählt nicht mit, da in dieser Welle kein zusätzlicher Drop-Off möglich war.

Das Querschnittgewicht für den Drop-Off wurde gebildet, indem das Querschnittgewicht der Betrachtungswelle mit der reziproken Teilnahmewahrscheinlichkeit am Drop-Off ( $1/\text{Teilnahmewahrscheinlichkeit}$ ) multipliziert wurde. Zusätzlich erfolgt eine Anpassung der Verteilungen Geburtsjahr\*Geschlecht\*Landesteil in der Stichprobe an bekannte Verteilungen in der Grundgesamtheit (Mikrozensus) mittels Iterative Proportional Fitting (IPF). Grundlage hierfür ist die vom DZA bereits übermittelte Referenztabelle mit den Verteilungszahlen aus dem Mikrozensus 2020, differenziert nach Geburtsjahrgangsgruppen, Geschlecht und Landesteil.

## 5 Ergänzung der Ausfallmodelle

Grundsätzlich sollten die Ausfallmodelle nicht im großen Stil verändert werden, um weiterhin die Vergleichbarkeit zwischen den Wellen zu gewährleisten. Eine moderate Erweiterung zur weiteren Bias-Reduktion kann aber vertretbar sein. Die Voraussetzung dafür war, dass zusätzliche Prädiktorvariablen einen signifikanten und insbesondere substantiellen Effekt auf Vorhersage der (Wieder-)Teilnahmewahrscheinlichkeit haben. Dies war für das Merkmal Drop-Off-Status der Fall, also die Tatsache, ob die Person in der vorherigen Welle nach dem mündlichen Interview auch den zusätzlichen schriftlichen Fragenbogen ausgefüllt hat. Daher wurde in fast allen

<sup>2</sup> Das FDZ des DZA bedankt sich bei Peter Krause vom Statistischen Bundesamt für die Bereitstellung der Referenztabelle auf der Basis des Mikrozensus.

Ausfallmodellen der DO-Status der Ausgangswelle bzw. der letzten Teilnahmewelle berücksichtigt. Das Ausfüllen des Drop-Offs weist auf eine höhere Motivation bzw. Loyalität gegenüber dem DEAS hin und erhöht die Wahrscheinlichkeit der erneuten Teilnahme bzw. erneut einen Drop-Off auszufüllen.

Das ISCED-Bildungsniveau war in den vorhergehenden Wellen bereits als Prädiktor für die längsschnittliche Panelteilnahme am mündlichen Interview verwendet worden. Als wichtiger Prädiktor wurde es nun auch in dem Querschnittmodell zur Vorhersage der Wiederteilnahme am mündlichen Interview verwendet (temporäre Ausfälle).

**Übersicht über die ergänzten Prädiktoren in den verschiedenen Ausfallmodellen**

Prädiktoren	Gewichtung					
	LS 2017 auf CATI 2020/21	LS 2020k auf CATI 2020/21	CATI 2020/21 (Quer- schnitt)	DO LS 2017 auf 2020/21	DO LS 2020k auf 2020/21	DO 2020/21 (Quer- schnitt)
Landesteil	✓	✓	✓	✓	✓	✓
Kreistypen	✓	✓				
Alter	✓	✓	✓	✓	✓	✓
Geschlecht	✓	✓	✓	✓	✓	✓
Bildung (ISCED)	✓	✓	✓	✓	✓	✓
Netzwerkgröße	✓					
Haushaltsgröße		✓				
Äquivalenzeinkommen	✓					
Ungewichtetes Haus- haltsprokopfeinkom- men		✓				
Subjektive Gesundheit	✓	✓				
<b>DO-Status</b>	<b>✓</b>			<b>✓</b>	<b>✓</b>	<b>✓</b>

Hinweis: Die Ergänzungen in den Ausfallmodellen wurden nicht retrospektiv angewendet und betreffen aktuell allein das Erhebungsjahr 2020/21. Um zu prüfen, ob die Inklusion des DO-Status eventuell zu Brüchen oder Verzerrungen führen, hat das FDZ des DZA Trendanalysen gerechnet und geprüft, ob sich Ergebnisse unterscheiden, wenn jenseits der Gewichtungsfaktoren auch das neue Merkmal DO-Status kontrolliert wird. Die Ergebnisse der Analysen unterschieden sich jedoch nicht.

## 6 Poststratifizierte Querschnittgewichtung

Die Querschnittgewichte der mündlichen Interviews und des Drop-Offs wurden mittels "iterative proportional fitting" (IPF) an die bekannten Verteilungen Geburtsjahr x Geschlecht x Landesteil laut Mikrozensus (2020) angepasst. Zusätzlich wurden zwei weiteres poststratifizierte Querschnittsgewichte erstellt, die Teilnehmer/innen mit einem Geburtsjahr vor 1930 nicht berücksichtigten, da diese Geburtsjahrgänge sehr geringe Fallzahlen aufweisen. Dies geschah sowohl für das CAPI-per-phone-Interview als auch für die Drop-Off-Interviews. Auch hier wurde eine geringfügige Anpassung vorgenommen: In den DEAS-Wellen 1996 bis 2020 wurde Berlin anhand der Postleitzahlen in Ost- und Westberlin aufgeteilt und jeweils getrennt den Landesteilen Ostdeutschland bzw. Westdeutschland bei der poststratifizierten Gewichtung zugeordnet. Für die poststratifizierte Querschnittgewichtung der Erhebung 2020/21 wurde Berlin vollständig dem Landesteil „Ost“ zugeordnet.

Bei Fragen, Problemen oder Hinweisen und Ideen wenden Sie sich bitte an:

Stefan Stuth

[stefan.stuth@dza.de](mailto:stefan.stuth@dza.de)