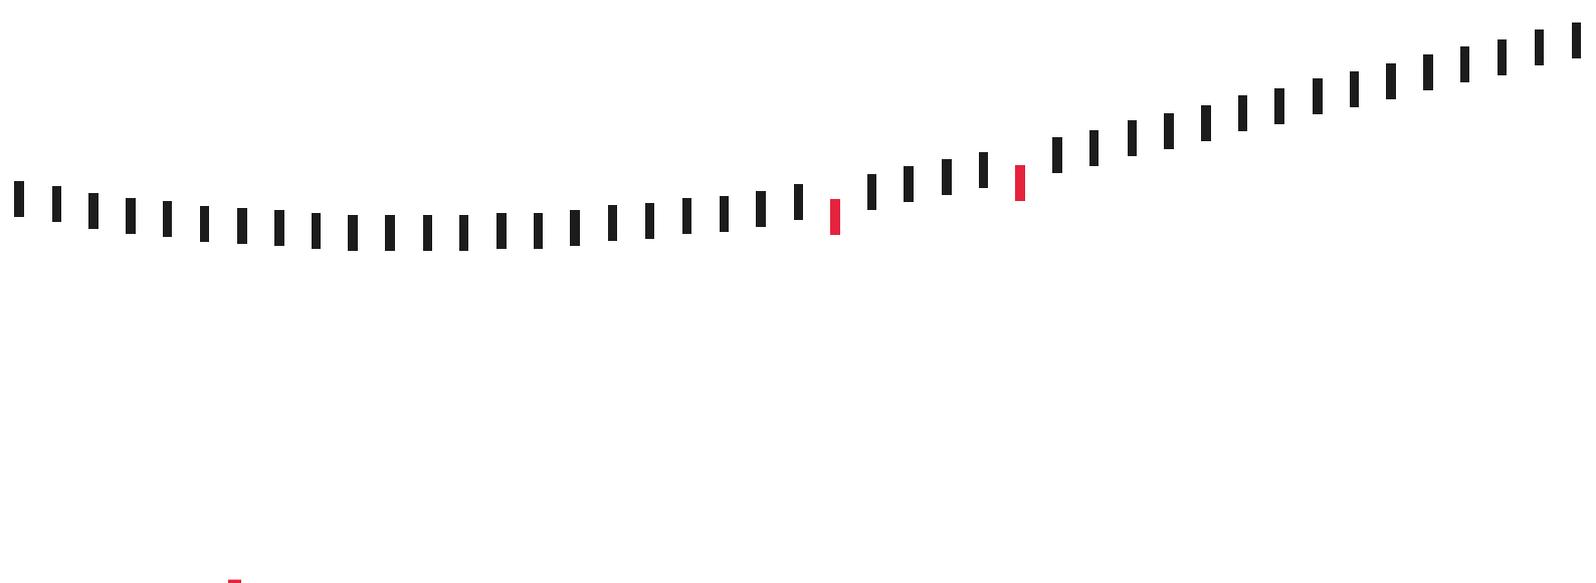


Schlussbericht

Berechnung der Sonderlasten im Lastenausgleich der NFA

Basel | 30.06.2022



Impressum

Berechnung der Sonderlasten im Lastenausgleich der NFA

V3

30.06.2022

Auftraggeber/in: Eidgenössische Finanzverwaltung EFV

Autorinnen/Autoren: Michael Lobsiger, Florentin Krämer

Verantwortlich seitens Auftraggeber/in: Pascal Utz (EFV)

Projektleitung seitens Auftragnehmer/in: Michael Lobsiger

Projektbearbeitung: Michael Lobsiger, Florentin Krämer, Miriam Frey, Boris Kaiser

BSS Volkswirtschaftliche Beratung AG

Aeschengraben 9

4051 Basel

T +41 61 262 05 55

contact@bss-basel.ch

www.bss-basel.ch

Dieses Dokument ist vertraulich. Die Weitergabe sowie die Verwendung der Inhalte der Offerte, auch nur auszugsweise, sind nur nach Rücksprache mit BSS Volkswirtschaftliche Beratung AG gestattet.

© 2022 BSS Volkswirtschaftliche Beratung AG

Inhalt

Tabellen	iii
Abbildungen.....	v
1. Ausgangslage und Ziele	1
2. Vorgehen	2
2.1 Methodische Ansätze	2
2.2 Daten	8
3. Ergebnisse	16
3.1 Selektionsmethoden	16
3.2 Quadratische Minimierung.....	26
3.3 Gewichte	27
3.4 Bewertung	32
3.5 Simulation.....	35
4. Schlussfolgerungen und Empfehlungen	48
A. Daten	51
A.1 Indikatoren.....	51
A.2 Nettoausgaben	61
B. Methoden.....	63
B.1 Quadratische Minimierung.....	63
B.2 LASSO Regression	63
B.3 Best Subset Selection	65
C. Zusätzliche Ergebnisse.....	65
C.1 Entwicklung der Koeffizienten	65
C.2 Simulation.....	69
D. Alternativer Indikator für «Steilheit»	77
E. Ergänzungen im Nachgang zur Fachgruppensitzung	87
E.1 Einschätzung zur Bewertung der Modelle / Methoden bei Verwendung des alternativen Indikators für die Steilheit des Geländes.....	87
E.2 Schätzung der absoluten Sonderlasten mit der Quadratischen Minimierung	88
F. Software.....	89
F.1 Software-Bibliographie	89

Tabellen

Tabelle 1: Indikatoren	13
Tabelle 2: Sonderlasten, Sonderlasten pro Kopf und Anteil Sonderlasten an den Nettoausgaben nach Kanton, LASSO	22
Tabelle 3: Sonderlasten, Sonderlasten pro Kopf und Anteil Sonderlasten an den Nettoausgaben nach Kanton, Best Subset Selection	23
Tabelle 4: Gewichte der Indikatoren innerhalb der Indikatorengruppen	31
Tabelle 5: Bewertung der Methoden	35
Tabelle 6: Dotationen Lastenausgleich 2021 (in CHF)	36
Tabelle 7: Ausgleichsvarianten	36
Tabelle 8: Funktionale Gliederung der Nettoausgaben	61
Tabelle 9: Veränderung Ausgleichszahlungen (in CHF), Total	69
Tabelle 10: Veränderung Ausgleichszahlungen (in CHF), GLA	70
Tabelle 11: Veränderung Ausgleichszahlungen (in CHF), GLA 1	71
Tabelle 12: Veränderung Ausgleichszahlungen (in CHF), GLA 2	72
Tabelle 13: Veränderung Ausgleichszahlung (in CHF), GLA 3	73
Tabelle 14: Veränderung Ausgleichszahlungen (in CHF), GLA 4	74
Tabelle 15: Veränderung Ausgleichszahlungen (in CHF), SLA A-C	75
Tabelle 16: Veränderung Ausgleichszahlungen (in CHF), SLA F	76
Tabelle 17: Gewichte der Indikatoren innerhalb der Indikatorengruppen (alternativer Indikator «Steilheit»)	77
Tabelle 18: Veränderung Ausgleichszahlungen (in CHF), Total (alternativer Indikator «Steilheit»)	79
Tabelle 19: Veränderung Ausgleichszahlungen (in CHF), GLA (alternativer Indikator «Steilheit»)	80
Tabelle 20: Veränderung Ausgleichszahlungen (in CHF), GLA 1 (alternativer Indikator «Steilheit»)	81
Tabelle 21: Veränderung Ausgleichszahlungen (in CHF), GLA 2 (alternativer Indikator «Steilheit»)	82
Tabelle 22: Veränderung Ausgleichszahlungen (in CHF), GLA 3 (alternativer Indikator «Steilheit»)	83

Tabelle 23: Veränderung Ausgleichszahlungen (in CHF), GLA 4 (alternativer Indikator «Steilheit»)	84
Tabelle 24: Veränderung Ausgleichszahlungen (in CHF), SLA A-C (alternativer Indikator «Steilheit»)	85
Tabelle 25: Veränderung Ausgleichszahlungen (in CHF), SLA F (alternativer Indikator «Steilheit»)	86
Tabelle 26: Bewertung der Methoden bei Verwendung des alternativen Indikators für die Steilheit des Geländes	88

Abbildungen

Abbildung 1: Veranschaulichung Berechnung der Sonderlasten I.....	6
Abbildung 2: Veranschaulichung Berechnung Sonderlasten II.....	7
Abbildung 3: Summe der Nettoausgaben über alle Kantone nach Funktionen, Mittelwert 2012-2019.....	10
Abbildung 4: Verteilung Nettoausgaben pro Kopf nach Funktionen, Mittelwert 2017-2019	12
Abbildung 5: Korrelationsmatrix, Mittelwert 2017-2019	15
Abbildung 6: Geschätzte Koeffizienten reduziertes Regressionsmodell (OLS), Indikatorenselektion gemäss LASSO, Mittelwert der Jahre 2017-2019.....	18
Abbildung 7: Geschätzte Koeffizienten reduziertes Regressionsmodell (OLS), Indikatorenselektion gemäss Best Subset Selection, Mittelwert der Jahre 2017-2019	19
Abbildung 8: Sonderlasten nach Methoden, Funktionen und Indikatoren, Mittelwert der Jahre 2017-2019	20
Abbildung 9: Gegenüberstellung geschätzte Sonderlasten pro Kopf und effektive Nettoausgaben pro Kopf, Mittelwert der Jahre 2017-2019.....	21
Abbildung 10: Sonderlasten pro Kopf nach Kanton und Ausgleichsgefäss.....	24
Abbildung 11: Sonderlasten nach Methoden und Indikatoren, Mittelwert der Jahre 2017-2019	25
Abbildung 12: Geschätzte Koeffizienten Quadratische Minimierung, Mittelwert der Jahre 2017-2019.....	27
Abbildung 13: Anteil der Indikatoren an den Sonderlasten, Mittelwert der Jahre 2017-2019.....	28
Abbildung 14: Anteil der Indikatorengruppen an den Sonderlasten, Mittelwert der Jahre 2017-2019.....	29
Abbildung 15: Anteil der Indikatoren an den Sonderlasten der Indikatorgruppen	30
Abbildung 16: Anteil der Indikatoren an den Sonderlasten der Indikatorgruppen, Mittelwerte30	
Abbildung 17: Veränderung Ausgleichszahlungen (absolut) SLA A-C, Variantenvergleich	40
Abbildung 18: Veränderung Ausgleichszahlungen (pro Kopf) SLA A-C, Variantenvergleich	40
Abbildung 19: Veränderung Ausgleichszahlungen (absolut) SLA F, Variantenvergleich	41
Abbildung 20: Veränderung Ausgleichszahlungen (pro Kopf) SLA F, Variantenvergleich	41
Abbildung 21: Veränderung der Ausgleichszahlungen mit neuer Gewichtung, Total und differenziert nach Ausgleichsgefässen.....	43
Abbildung 22: Veränderung der Ausgleichszahlungen pro Kopf mit neuer Gewichtung, Total und differenziert nach Ausgleichsgefässen.....	44

Abbildung 23: Veränderung der Ausgleichszahlungen mit neuer Gewichtung, GLA.....	45
Abbildung 24: Veränderung der Ausgleichszahlungen pro Kopf mit neuer Gewichtung, GLA ...	46
Abbildung 25: Siedlungshöhe.....	51
Abbildung 26: Steilheit des Geländes	52
Abbildung 27: Siedlungsstruktur.....	53
Abbildung 28: Geringe Bevölkerungsdichte	54
Abbildung 29: Armutsindikator	55
Abbildung 30: Altersstruktur	56
Abbildung 31: Ausländerintegration	57
Abbildung 32: Ständige Wohnbevölkerung	58
Abbildung 33: Beschäftigungsquote.....	59
Abbildung 34: Siedlungsdichte	60
Abbildung 35: Entwicklung der Koeffizienten über die Zeit, LASSO	66
Abbildung 36: Entwicklung der Koeffizienten über die Zeit, Best Subset Selection	67
Abbildung 37: Entwicklung der Koeffizienten über die Zeit, Quadratische Minimierung.....	68

1. Ausgangslage und Ziele

Der nationale Finanzausgleich kennt neben einem Ressourcen- auch einen Lastenausgleich. Dieser dient dazu, strukturell bedingte, von den Kantonen weitgehend unbeeinflussbare Sonderlasten abzugelten. Es wird zwischen geografisch-topografischen Lasten und soziodemografischen Lasten unterschieden. Die Ausgleichszahlungen werden aufgrund von insgesamt zehn Indikatoren berechnet: Vier Indikatoren für den geografisch-topografischen Lastenausgleich (GLA) und sechs Indikatoren für den soziodemografischen Lastenausgleich (SLA), wobei drei für den Ausgleich für Sonderlasten der Bevölkerungsstruktur (SLA-A-C) und drei für den Ausgleich für Sonderlasten der Kernstädte (SLA-F) verwendet werden.

Um die Ausgleichszahlungen zu bestimmen, müssen die Indikatoren gewichtet werden. Die Gewichtungsfaktoren des GLA sind in der Verordnung über den Finanz- und Lastenausgleich (FiLaV) festgeschrieben und seit dem Jahr 2008 (Einführung NFA) unverändert geblieben. Die Gewichte der Indikatoren im SLA-A-C und im SLA-F werden jährlich neu berechnet. Hierzu wird jeweils eine Hauptkomponentenanalyse (HKA) durchgeführt. Die HKA weist allerdings verschiedene Schwächen auf. U.a. werden die Gewichte mit der HKA unabhängig von den effektiven Sonderlasten der Kantone bestimmt. Aus diesem Grund soll im Rahmen dieses Mandats eine neue Methode zur Bestimmung der Gewichte der Indikatoren erarbeitet werden. Diese soll sich an den effektiven Sonderlasten orientieren.

Bei der Erarbeitung der Methode sind folgende Bedingungen zu berücksichtigen:

- Diese zehn Indikatoren wie auch die Gesamtdotation des GLA und des SLA sind als gegeben zu betrachten.
- Die Methode zur Schätzung der Gewichte der Indikatoren soll sich an den effektiven Sonderlasten orientieren.
- Die Gewichtung der Indikatoren im SLA sollen neu ebenfalls in der FiLaV festgeschrieben werden.
- Die Methode soll eine regelmässige Überprüfung, und, falls angezeigt, eine Anpassung der Gewichte ermöglichen.

2. Vorgehen

2.1 Methodische Ansätze

2.1.1 Vorbemerkungen

Im bisherigen Lastenausgleich wird keine Selektion der Indikatoren vorgenommen. Mit der Hauptkomponentenanalyse (HKA) wird eine Methode zur Dimensionsreduktion angewendet. Hierbei wird die ursprüngliche Liste von Indikatoren in eine kleiner dimensionierte Liste von Indikatorkombinationen transformiert. Konkret wird mit Hilfe der HKA aus den Indikatoren ein Index berechnet. Die Indikatoren fliessen dabei mit Gewichten in diesen Index ein, die durch die HKA geschätzt werden. Der Vorteil der HKA ist, dass die Gewichtung der Indikatoren bereits über die Dimensionsreduktion ermittelt wird. Der Nachteil ist allerdings, dass die Gewichtung unabhängig von der Zielgrösse (hier: durchschnittliche Nettoausgaben pro Kopf und Kanton) geschätzt wird.¹

Für die Schätzung der Sonderlasten und darauf basierend der Gewichtung der zehn Indikatoren des Lastenausgleichs verfolgen wir einen regressionsbasierten Ansatz, wie er im Methodenpapier der EFV («Gewichtung der Indikatoren im Lastenausgleich») vom 28. Oktober 2021 bereits zur Anwendung kommt. Dieser Ansatz erlaubt es, den Einfluss der zehn Indikatoren auf die Nettoausgaben pro Kopf der Kantone² zu schätzen und basierend auf dieser Schätzung die Gewichte der einzelnen Indikatoren zu berechnen. Im Unterschied zur HKA berücksichtigen wir bei der Schätzung der Sonderlasten als abhängige Grösse die Nettoausgaben pro Kopf. Wir gehen im Kapitel 2.1.2 noch im Detail auf die Berechnung der Sonderlasten ein.

Die Auswahl von Indikatoren, die für die Berechnung der Sonderlasten einer Funktion relevant sind, kann – abgesehen von der bereits angesprochenen Dimensionsreduktion mittels HKA – grundsätzlich auf verschiedene Arten erfolgen:

- Anhand statistischer Signifikanz
- Anhand eines Vorhersagekriteriums
- Durch Koeffizientenschrumpfung
- Durch Optimierung unter Nebenbedingungen

Wir gehen nachfolgend kurz darauf ein, warum wir die Auswahl anhand des Kriteriums der statistischen Signifikanz im vorliegenden Kontext für ungeeignet halten. Die weiteren Möglichkeiten zur Variablenselektion werden in den Abschnitten 2.1.2 und 2.1.3 beschrieben.

Erstens gilt es zu berücksichtigen, dass die Daten als Vollerhebung vorliegen. Das Konzept der statistischen Signifikanz hingegen setzt eine Stichprobe voraus. Zweitens möchten wir betonen, dass «statistische Signifikanz» nicht gleichbedeutend mit «Relevanz» oder «Wichtigkeit» ist. Der Terminus hat eine enge technische Interpretation: Mittels einer Teststatistik wird die Hypothese

¹ Weitere Nachteile werden im Methodenpapier der EFV («Gewichtung der Indikatoren im Lastenausgleich») vom 28. Oktober 2021 erwähnt.

² Hier wie im Folgenden bedeutet «Kantone» immer Kantone und ihre Gemeinden.

getestet, ob ein Koeffizient von 0 verschieden ist, sprich: ob die Regressionsgerade einer linearen Regression eine positive Steigung annimmt. Diese Teststatistik wird als p -Wert bezeichnet. Je kleiner der p -Wert, desto unwahrscheinlicher die Nullhypothese. Dies sagt jedoch nichts über die «Relevanz» aus.³ Eine Auswahl der Indikatoren basierend auf deren statistischer Signifikanz in einem Regressionsmodell erscheint uns aus diesem Grund als nicht zielführend. Drittens erschwert die Datenlage für die vorliegende Aufgabenstellung die Analyse: Für die Schätzung der Koeffizienten der 10 Indikatoren stehen pro Funktion lediglich 26 Beobachtungen (die durchschnittlichen Nettoausgaben pro Kopf und Kanton) zur Verfügung. Die geringe Zahl von Beobachtungen führt zu einer geringen Trennschärfe des statistischen Signifikanztests. Indikatoren, deren Koeffizienten bei einem grösseren Stichprobenumfang als statistisch signifikant verschieden von 0 identifiziert würden, können daher möglicherweise als nicht signifikant (im statistischen Sinne) ausgewiesen werden. Als problematisch kann sich auch die hohe Korrelation zwischen einzelnen Indikatoren erweisen, da sie zu einer Erhöhung der Varianz der geschätzten Koeffizienten führt.⁴

Aus diesen Gründen erachten wir das Konzept der statistischen Signifikanz für die Auswahl von Indikatoren nicht als zielführend. Die nachfolgend vorgestellten Methoden zur Dimensionsreduktion beruhen auf anderen Mechanismen und umgehen die oben beschriebene Problematik. Da die Selektion der Indikatoren jahresweise vorgenommen wird und sich die modellgetriebene Auswahl von Jahr zu Jahr unterscheiden kann, bleibt das Problem der Instabilität über die Zeit jedoch bestehen. Dies gilt es bei der Interpretation der Ergebnisse zu berücksichtigen.

2.1.2 Selektionsmethoden

Die Selektionsmethoden beinhalten ein dreistufiges Vorgehen.⁵ In einem ersten Schritt werden für die Nettoausgaben pro Kopf jeder Funktion die relevanten Variablen ausgewählt.⁶ Anschliessend wird in einem zweiten Schritt wiederum für die Nettoausgaben pro Kopf jeder Funktion ein Regressionsmodell (OLS) mit den selektierten Indikatoren geschätzt. Im abschliessenden dritten Schritt werden die Sonderlasten pro Indikator berechnet und auf dieser Grundlage das Gewicht jedes Indikators bestimmt. Die einzelnen Schritte werden nachfolgend näher erläutert.

Schritt 1: Selektion der Indikatoren

Im ersten Schritt geht es darum, die relevanten Indikatoren pro Funktion zu bestimmen. Im Rahmen der Studie haben wir zwei Ansätze getestet:⁷

- *LASSO / Elastic Net (Methoden mit Koeffizientenschrumpfung)*: Im Kern handelt es sich bei diesen Methoden um lineare Regressionen des vollständigen Modells, in welcher die geschätz-

³ Bspw. Relevanz eines bestimmten Indikators in Bezug auf die Nettoausgaben pro Kopf.

⁴ Die beschriebene hohe Korrelation entspricht nicht dem Problem der Kollinearität, das mit einer exakten linearen Beziehung zwischen zwei oder mehr Variablen einhergeht. Bei (Multi)kollinearität verfügen die geschätzten Koeffizienten über keine Aussagekraft; bei hoher Korrelation einzelner erklärender Variablen ist die Aussagekraft aufgrund der unpräzisen Schätzung noch vorhanden, aber eingeschränkt.

⁵ Das Vorgehen wurde im Methodenbericht der EFV («Gewichtung der Indikatoren im Lastenausgleich») vom 28. Oktober 2021 bereits skizziert.

⁶ Nach welchem Kriterium wir die Relevanz der Indikatoren festlegen, wird weiter unten noch ausgeführt.

⁷ Die folgenden technischen Ausführungen basieren auf James, G., Witten, D., Hastie, T. and Tibshirani, R. (2021). *An Introduction to Statistical Learning, with Applications in R*. Second Edition.

ten Koeffizienten für Variablen, die eine relativ geringe Erklärungskraft aufweisen, geschrumpft werden. Bei der LASSO-Regression werden gewisse Koeffizienten auf exakt null geschrumpft; in diesem Sinne erfolgt somit eine Selektion der Indikatoren. LASSO tendiert bei Gruppen hoch korrelierter Indikatoren dazu, jeweils *eine* Variable aus dieser Gruppe zu selektieren. Elastic Net schwächt diese Eigenschaft ab. Eine ausführlichere Darstellung der Methode findet sich im Kapitel B.2 im Anhang.

- *Best Subset Selection*: Mithilfe dieser Methode wird diejenige Kombination von Indikatoren identifiziert, welche die abhängige Variable am «besten» vorherzusagen vermag. Dabei wird für jede mögliche Kombination der Indikatoren ein Modell mit OLS geschätzt und aufgrund eines Vorhersagekriteriums das beste Modell bzw. die darin berücksichtigten Variablen ausgewählt.⁸ Eine ausführlichere Darstellung der Methode findet sich im Kapitel B.3 im Anhang.

Schritt 2: Schätzung des reduzierten Regressionsmodells mit OLS

Sei P die Gesamtmenge der Indikatoren. Im vorhergehenden Schritt wird daraus je Methode m und Jahr t eine Teilmenge $P_{m,t}^S \subseteq P$ ausgewählt. Mit den selektierten Indikatoren führen wir im Anschluss eine OLS Regression durch:

$$y_{f,k} = \alpha + \sum_{p \in P_{m,t}^S} \beta_p \tilde{x}_{p,k} + \varepsilon_k \quad (1)$$

Hier bezeichnet $y_{f,k}$ die Nettoausgaben pro Kopf für die Funktion f und den Kanton k und $\tilde{x}_{p,k}$ die standardisierten Indikatoren auf kantonaler Ebene.⁹ ε_k ist das Residuum.

Schritt 3: Berechnung der Sonderlasten und der Gewichte der Indikatoren

Im abschliessenden dritten Schritt werden die Sonderlasten für jeden Kanton differenziert nach Funktion und Indikator berechnet. Die Sonderlasten pro Funktion und Indikator lassen sich anschliessend über alle Kantone zu den Sonderlasten pro Indikator und zu den Sonderlasten insgesamt aggregieren. Werden die Sonderlasten pro Indikator zu den Sonderlasten insgesamt in Beziehung gesetzt, lassen sich die Gewichte für die einzelnen Indikatoren bestimmen.

Auf Grundlage der geschätzten Koeffizienten $\hat{\alpha}$ und $\hat{\beta}$ (s. Modell 1) lassen sich die prognostizierten Nettoausgaben pro Kopf bezogen auf die Indikatoren $p \in P_{m,t}^S$ für die Methode m , das Jahr t , die Funktion f und den Kanton k schätzen.

In Abbildung 1 ist die Berechnung der Sonderlasten pro Kopf für den Fall eines Indikators dargestellt. In diesem Fall reduziert sich die Regressionsgleichung aus (1) auf

$$y_{f,k} = \alpha + \beta \tilde{x}_k + \varepsilon_k. \quad (2)$$

In diesem Beispiel sei der geschätzte Koeffizient $\hat{\beta} > 0$, die Steigung der Geraden also positiv. Der Datenpunkt A in der linken Hälfte der Abbildung weist einen Indikatorwert von x_A und effektive Nettoausgaben pro Kopf von y_A auf. Aufgrund der geschätzten Regressionsgerade prognostizieren wir für den Indikatorwert x_A Nettoausgaben pro Kopf von \hat{y}_A . Wir stellen nun den Vergleich mit

⁸ Werden alle möglichen Kombinationen von Variablen getestet, ergibt dies bei 10 Indikatoren bereits 1'024 (2^{10}) mögliche Kombinationen.

⁹ Zur Standardisierung des Indikators wird der Mittelwert von der jeweiligen Ausprägung des Indikators abgezogen und durch die Standardabweichung geteilt.

den prognostizierten Nettoausgaben pro Kopf her, die bei einem Indikatorwert von Null resultieren würden. Aufgrund der Standardisierung entspricht dies dem Durchschnitt des Indikators. Die prognostizierten Nettoausgaben pro Kopf können am Schnittpunkt der Regressionsgeraden und der Ordinate abgelesen werden und werden mit \hat{y}_0 bezeichnet. Die Höhe der prognostizierten Nettoausgaben pro Kopf bei einem Indikatorwert von Null entspricht gerade \hat{a} . Die Sonderlasten pro Kopf ergeben sich nun aus der Differenz zwischen \hat{y}_A und \hat{y}_0 . Die Differenz zwischen effektiven Nettoausgaben pro Kopf y_A und den prognostizierten Nettoausgaben pro Kopf \hat{y}_A ist auf Grundlage des Modells nicht erklärbar. Dabei kann es sich um Wahlbedarf¹⁰ handeln oder aber um Sonderlasten, die durch andere strukturelle Faktoren als jene, die über den Indikator x abgebildet werden, bedingt sind.

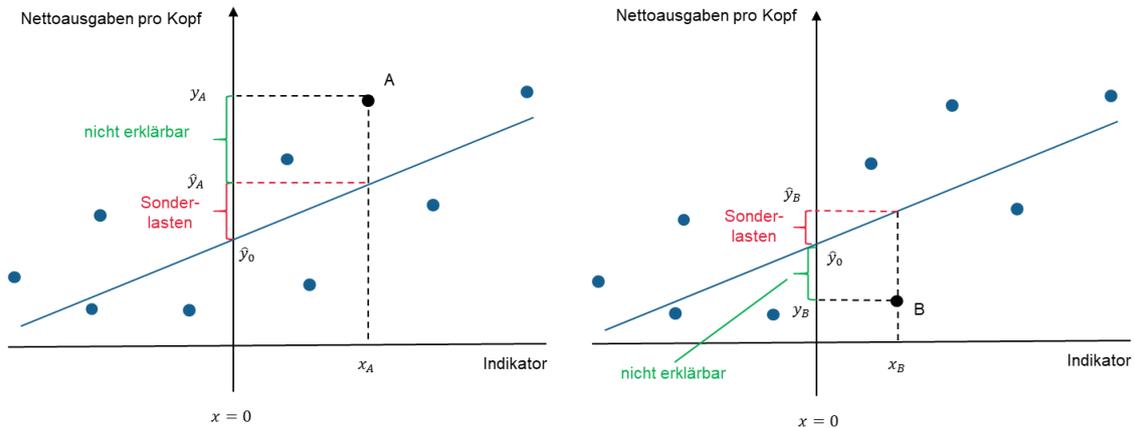
Der Datenpunkt B in der rechten Hälfte der Abbildung weist einen Indikatorwert von x_B und effektive Nettoausgaben pro Kopf von y_B auf. Aufgrund der geschätzten Regressionsgerade prognostizieren wir für den Indikatorwert x_B Nettoausgaben pro Kopf von \hat{y}_B . Die Sonderlasten pro Kopf ergeben sich wiederum aus der Differenz zwischen \hat{y}_B und \hat{y}_0 . Im Vergleich zum Datenpunkt A liegen die effektiven Nettoausgaben pro Kopf y_B *unterhalb* der prognostizierten Nettoausgaben pro Kopf \hat{y}_B . Die Differenz zwischen diesen beiden Werten kann durch das Modell nicht erklärt werden. Gemäss Modell ist für den Indikatorwert x_B mit Nettoausgaben pro Kopf von \hat{y}_B zu rechnen. Eine Erklärung für die tieferen effektiven Nettoausgaben pro Kopf liefert das Modell nicht. Zu beachten ist, dass nur Datenpunkte mit einem Indikatorwert $x > 0$ Sonderlasten aufweisen. Datenpunkte mit einem Indikatorwert $x < 0$ weisen demgegenüber «Minderlasten» auf.

Es gilt zu beachten, dass die Nettoausgaben pro Kopf auch einen sog. Wahlbedarf enthalten können, Ausgaben also, die nicht auf strukturelle Faktoren zurückzuführen sind. Dies beeinträchtigt unsere Vorgehensweise dann, wenn sich der relative Ausgabenanteil des Wahlbedarfs über Kantone hinweg systematisch unterscheidet.¹¹ In diesem Fall würde sich die Steigung der Regressionsgerade in Abbildung 1 verändern und zu höheren oder niedrigeren Sonderlasten führen. Bei einem homogen angenommenen Anteil des Wahlbedarfs an den Nettoausgaben pro Kopf würde eine vertikale Verschiebung der Regressionsgeraden resultieren. Die berechneten Sonderlasten ändern sich dadurch nicht. Bei unserer Analyse gehen wir implizit davon aus, dass die letztere Variante zutrifft.

¹⁰ Dabei handelt es sich um Nettoausgaben pro Kopf, die nicht auf strukturelle Faktoren zurückgeführt werden können.

¹¹ D.h. wenn der Ausgabenanteil des Wahlbedarfs mit dem Indikator zur Abbildung von Sonderlasten (im Falle der Einfachregression in Abbildung 1) bzw. mit mindestens einem Indikator zur Abbildung der Sonderlasten (falls mehrere Indikatoren verwendet werden) korreliert ist. In diesem Fall werden die Koeffizienten verzerrt geschätzt. Dabei kann es zu einer über- wie auch einer Unterschätzung kommen. Ist die Korrelation positiv, werden die Sonderlasten tendenziell überschätzt, ist die Korrelation negativ, werden die Sonderlasten tendenziell unterschätzt.

Abbildung 1: Veranschaulichung Berechnung der Sonderlasten I



Quelle: Eigene Darstellung

Im obigen Beispiel wurde von einem positiven Koeffizienten ausgegangen. Grundsätzlich können die Koeffizienten auch negativ ausfallen. In diesem Fall gehen mit hohen Indikatorwerten tiefe Nettoausgaben pro Kopf einher. Wie Abbildung 2 zeigt, können grundsätzlich vier Fälle unterschieden werden:

- Fall 1: Koeffizient und Indikatorwert sind positiv. In diesem Fall weisen Datenpunkte mit positiven Indikatorwerten überdurchschnittliche Nettoausgaben pro Kopf auf.
- Fall 2 / Fall 3: Koeffizienten positiv / negativ und Indikatorwert negativ / positiv. In diesem Fall weisen entsprechende Datenpunkte unterdurchschnittliche Nettoausgaben pro Kopf auf.
- Fall 4: Koeffizient und Indikatorwert sind negativ. In diesem Fall weisen Datenpunkte mit negativen Indikatorwerten überdurchschnittliche Nettoausgaben pro Kopf auf.

Für die folgenden Berechnungen gilt, dass nur Indikatoren mit positiven Koeffizienten und positiven Indikatorwerten Sonderlasten darstellen (Fall 1). Die Fälle 2 und 3 mit «Minderlasten» werden nicht berücksichtigt, d.h. Sonder- und Minderlasten werden bei diesem Berechnungsschritt nicht miteinander verrechnet. Auch aus Fall 4 ergeben sich für die folgenden Berechnungen keine Sonderlasten. Diese Vorgehensweise ist in der Definitionslogik der Indikatoren begründet: Sie sind so gewählt, dass höhere Werte eines Indikators mit höheren Sonderlasten einhergehen sollten. Es ist jedoch denkbar, dass ein Indikator dieser Anforderung nicht (oder nicht mehr) genügt.

Als Beispiel kann der Anteil der über 80-jährigen Bevölkerung an der ständigen Wohnbevölkerung dienen. Nehmen wir an, der Koeffizient dieses Indikators ist für eine bestimmte Ausgabenfunktion negativ. Dies würde bedeuten, dass Kantone mit einem unterdurchschnittlichen Anteil von über 80-Jährigen an der ständigen Wohnbevölkerung überdurchschnittliche Nettoausgaben pro Kopf aufweisen würden. In diesem Fall wäre es möglich, den Indikator umzudefinieren und den Anteil der *unter* 80-Jährigen in der Analyse zu berücksichtigen. In diesem Fall würde der Koeffizient positiv ausfallen, der umdefinierte Indikator würde also wie in Fall 1 auf Sonderlasten hindeuten. Die Berücksichtigung des Falls 4 würde allerdings zentrale Rahmenbedingung dieser Studie sprengen, nämlich, dass die zehn Indikatoren als gegeben zu betrachten sind. Sollten sich negative Koeffizienten häufen, gäbe das einen Hinweis darauf, dass die bestehenden Indikatoren nicht in jedem Fall optimal sind.

Abbildung 2: Veranschaulichung Berechnung Sonderlasten II

		Vorzeichen Koeffizient	
		$\hat{\beta} > 0$	$\hat{\beta} < 0$
Vorzeichen standardisierter Indikator	$\tilde{x}_k > 0$	<p>Fall 1: Sonderlasten</p>	<p>Fall 3</p>
	$\tilde{x}_k < 0$	<p>Fall 2</p>	<p>Fall 4</p>

Quelle: Eigene Darstellung

Die Berechnung der Sonderlasten pro Kopf bei Berücksichtigung von mehr als einem Indikator läuft grundsätzlich analog zur oben skizzierten Berechnung. Die Sonderlasten pro Kopf für die Funktion f und den Kanton k , die auf den Indikator \tilde{x}_p zurückzuführen sind, ergeben sich folgendermassen:

$$s_{f,k,p} = \hat{\beta}_{f,p} \tilde{x}_{p,k} \quad (\text{mit } \tilde{x}_{p,k} > 0 \text{ und } \hat{\beta}_{f,p} > 0) \quad (3)$$

Falls $\tilde{x}_{p,k} \leq 0$ und/oder $\hat{\beta}_{f,p} \leq 0$, dann sind die Sonderlasten pro Kopf für die Funktion f und den Kanton k , die auf den Indikator \tilde{x}_p zurückzuführen sind ($s_{f,k,p}$) gleich Null. Die Sonderlasten für die Funktion f und den Kanton k , die auf den Indikator \tilde{x}_p zurückzuführen sind, ergeben sich aus der Multiplikation der Sonderlasten pro Kopf mit der ständigen Wohnbevölkerung:

$$S_{f,k,p} = s_{f,k,p} \cdot BEV_k \quad (4)$$

Die Sonderlasten pro Indikator lassen sich nun über die Funktionen und Kantone summieren. Der Anteil der Sonderlasten, die auf den Indikator \tilde{x}_p zurückzuführen sind, ergibt sich dann wie folgt:

$$\pi_p = \frac{\sum_{k \in K} \sum_{f \in F} S_{f,k,p}}{\sum_{k \in K} \sum_{f \in F} \sum_{p \in P} S_{f,k,p}}$$

Die berechneten π_p sind die gesuchten Gewichte für die Indikatoren.

2.1.3 Quadratische Minimierung

Bei dieser Methode wird für jede Funktion ein lineares Regressionsmodell mit den Nettoausgaben pro Kopf als abhängige Variable und den zehn Indikatoren als unabhängige Variablen unter Berücksichtigung von Nebenbedingungen geschätzt. Konkret werden die Modelle mit der Methode der Kleinstquadrate (OLS) unter folgenden Bedingungen geschätzt: 1) keine Konstante, 2) Koeffizienten dürfen nicht negativ sein, 3) Koeffizienten müssen sich auf eins summieren. Aufgrund der Restriktionen können die geschätzten Koeffizienten direkt als Gewichte interpretiert werden. Aus diesem Grund entfallen die Schritte 2 und 3, die wir bei den Selektionsmethoden (vgl. Kapitel 3.1) skizziert haben. In der Praxis liefert der Algorithmus für einige Koeffizienten exakt null, wenn diese nichts zur Erklärung der Nettoausgaben pro Kopf beisteuern. Im Ergebnis liegen für jede Funktion Schätzergebnisse vor. Diese Ergebnisse können mit den Nettoausgaben pro Funktion gewichtet und so zu einem Gesamtergebnis aggregiert werden. Eine ausführlichere Beschreibung der Methode findet sich im Kapitel B.1 im Anhang.

2.2 Daten

2.2.1 Nettoausgaben

Daten zu den Nettoausgaben wurde von der EFV für diese Analyse zur Verfügung gestellt. Es handelt sich dabei um die Nettoausgaben der Kantone und ihrer Gemeinden. Damit kann sichergestellt werden, dass kantonale Unterschiede in der Aufgabenteilung die Analyse nicht beeinflussen. Im Folgenden werden wir der Einfachheit halber nur von Kantonen sprechen. Gemeint sind aber immer die Kantone und ihre Gemeinden. Die Daten zu den Nettoausgaben der Kantone stammen aus der Finanzstatistik der EFV. Die Nettoausgaben liegen nach funktionaler Gliederung (2-Steller, 1-Steller) der öffentlichen Buchhaltung vor (vgl. Tabelle 8 im Anhang A.2). Für die Analyse wurden die Jahre 2012-2019 berücksichtigt. Ab dann werden alle Indikatoren jährlich neu berechnet. Die Analysen wurden auf der Ebene der 2-Steller Funktionen durchgeführt. Nachfolgend legen wir dar, wie wir die Nettoausgaben pro Kopf aufbereitet haben.

Ausschlusskriterien

Es wurden verschiedene Ausschlusskriterien angewendet. Es gilt zu beachten, dass der Ausschluss einer Funktion in einem Jahr auch den Ausschluss für die anderen Jahre bedingt. Diese zusätzliche Restriktion haben wir eingeführt, damit die Ergebnisse über die Zeit nicht durch Unterschiede in Bezug auf die berücksichtigten Funktionen getrieben werden. Falls eine Restriktion nicht für alle Jahre greift, haben wir diejenigen Jahre in Klammern angegeben, für welche das Ausschlusskriterium erfüllt ist. Wir haben folgende Kriterien angewendet:

- Ausschluss von Funktionen mit negativen Nettoausgaben oder Nettoausgaben = 0 in allen Kantonen. Die aufgeführten Funktionen tragen nichts zur Identifikation von Sonderlasten bei. Für alle Jahre wurden die Funktionen, die den «Finanzen und Steuern» (1-Steller: 9) zugeordnet werden können, ausgeschlossen. Diese Funktionen weisen grundsätzlich Nettoeinnahmen auf. Aus dem gleichen Grund wurden für die Analyse auch die Funktionen 28 («Forschung»), 63 («Verkehr, übrige») (2014, 2016-2019), 64 («Nachrichtenübermittlung») (2012-2014), 86 («Banken und Versicherungen») (2012, 2014, 2016-2019), 87 («Brennstoffe und Energie») und 89 («Sonstige gewerbliche Betriebe») ausgeschlossen. Aufgrund von Nettoausgaben = 0 für alle Kantone wurden die Funktionen 08 («F&E in allgemeine Verwaltung»), 18 («F&E in

Öffentliche Ordnung und Sicherheit, Verteidigung»), 35 («Kirchen und religiöse Angelegenheiten») (2013, 2017, 2019), 38 («F&E in Kultur, Sport und Freizeit, Kirche»), 48 («F&E in Gesundheit»), 58 («F&E in soziale Sicherheit»), 68 («F&E in Verkehr und Nachrichtenübermittlung»), 78 («F&E in Umweltschutz») (2012, 2013) und 88 («F&E in Volkswirtschaft») (2012, 2013) ausgeschlossen.

- Je Funktion: Ausschluss von Kantonen mit Nettoausgaben = 0. Es erscheint sehr unwahrscheinlich, dass Kantone Nettoausgaben von exakt null aufweisen. Wir gehen davon aus, dass die entsprechenden Kantone entweder keine Leistungen in dieser Funktion erbracht haben oder die Ausgaben und Einnahmen für diese Leistungen in einer anderen Funktion verbucht wurden. Beides spricht aus unserer Sicht dafür, die entsprechenden Datensätze für die Analyse auszuschliessen, um die Analyse nicht zu verzerren.¹²
- Aufgrund des vorangehenden Ausschlusskriteriums können in einer Funktion auch weniger als 26 Kantone inkludiert sein. Da bereits 26 Kantone (= Beobachtungen) eine geringe Datenbasis darstellen, werden nur Funktionsgruppen betrachtet, für die min. 20 Kantone verfügbar sind. Aufgrund dieses Kriteriums werden folgende Funktionen ausgeschlossen: 03 («Beziehungen zum Ausland»), 42 («Ambulante Krankenpflege»), 56 («Sozialer Wohnungsbau») und 59 («Soziale Wohlfahrt n.a.g.»).¹³

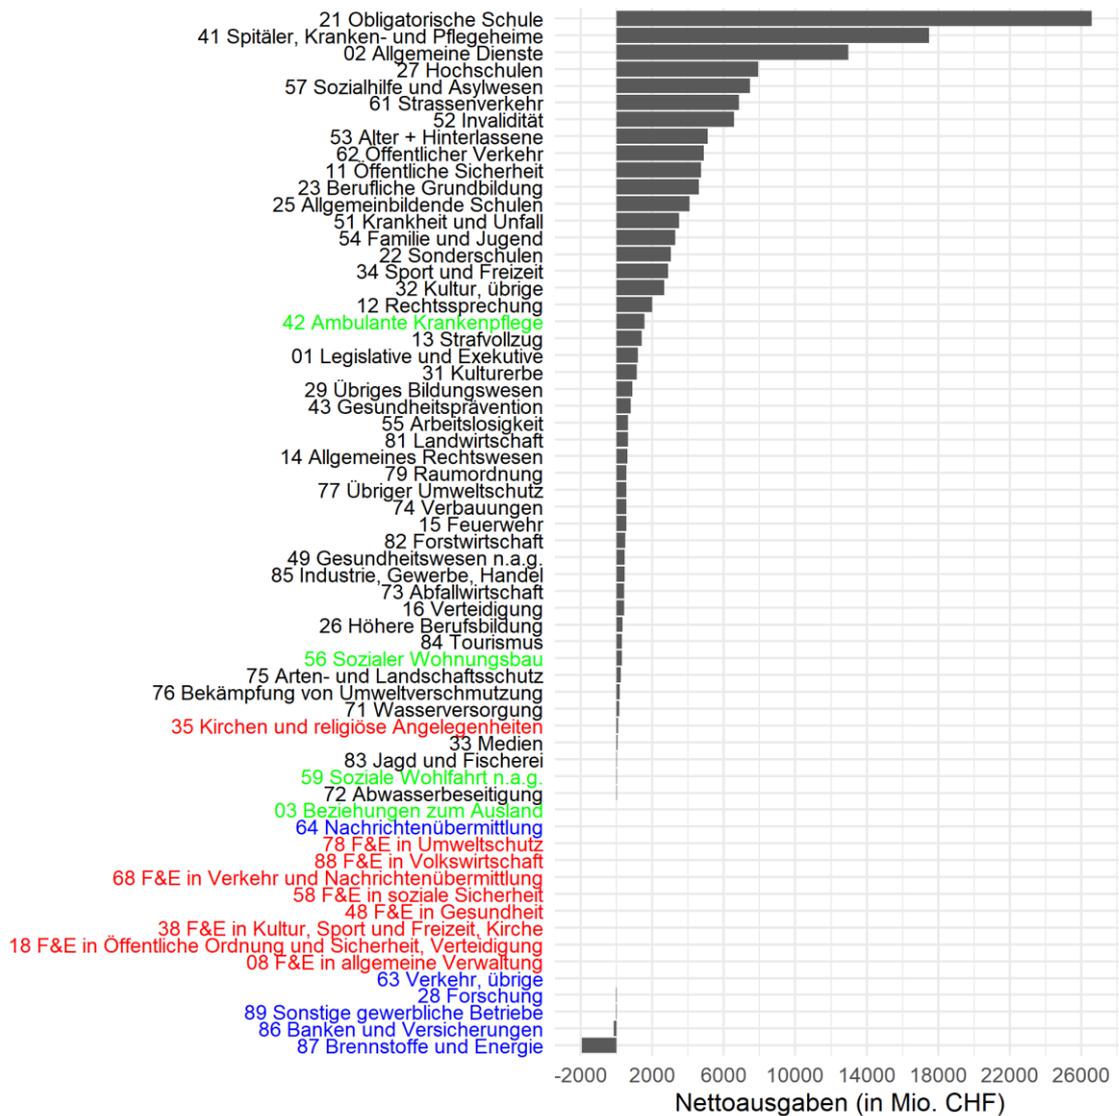
Weitere Ausschlüsse von Funktionen oder Kantonen innerhalb von Funktionen wurden nicht vorgenommen. Insbesondere haben wir darauf verzichtet, Funktionen bereits vor der Analyse dahingehend zu beurteilen, ob diese überhaupt Sonderlasten enthalten können und darauf basierend Ausschlüsse vorzunehmen.

Abbildung 3 bildet den Mittelwert (2012-2019) der Summe der Nettoausgaben über alle Kantone nach Funktionen ab. Die Funktionen sind nach Höhe der Nettoausgabe in absteigender Reihenfolge geordnet. Die ausgeschlossenen Funktionen sind farblich markiert: Blau markierte Funktionen werden aufgrund von Nettoausgaben < 0 für alle Kantone, rot markierte Funktionen aufgrund von Nettoausgaben = 0 für alle Kantone und grün markierte Funktionen aufgrund von geringer Beobachtungszahl ($n < 20$) aus der Analyse ausgeschlossen. Abbildung 3 zeigt auf, dass die ausgeschlossenen Funktionen mit Ausnahme der Funktion 42 («Ambulante Krankenpflege») gemessen an den Nettoausgaben relativ unbedeutend sind. Die Funktion 42 vereint im Schnitt der Jahre 2012-2019 Nettoausgaben von rund 1,5 Mrd. Franken. Im Jahr 2019 weisen allerdings nur 18 Kantone in dieser Funktion Nettoausgaben von null verschieden auf. Aus diesem Grund haben wir diese Funktion aus der Analyse ausgeschlossen.

¹² Die betreffenden Kantone werden auch bei der folgenden Schätzung der Sonderlasten nicht berücksichtigt.

¹³ In den betreffenden Funktionen sind in den Jahren 2012-2019 folgende Anzahl Kantone inkludiert: 03 (2012: 1, 2013: 2, 2014: 2, 2015: 2, 2016: 2, 2017: 2, 2018: 2, 2019: 2), 42 (2012: 21, 2013: 20, 2014: 22, 2015: 22, 2016: 20, 2017: 20, 2018: 19, 2019: 18), 56 (2012: 19, 2013: 20, 2014: 18, 2015: 18, 2016: 18, 2017: 20, 2018: 20, 2019: 16), 59 (2012: 5, 2013: 2, 2014: 3, 2015: 6, 2016: 6, 2017: 5, 2018: 6, 2019: 6).

Abbildung 3: Summe der Nettoausgaben über alle Kantone nach Funktionen, Mittelwert 2012-2019



Quelle: EFV. Anmerkungen: blau markierte Funktionen: Ausschluss aufgrund von Nettoausgaben < 0 für alle Kantone, rot markierte Funktionen: Ausschluss aufgrund von Nettoausgaben = 0 für alle Kantone, grün markierte Funktionen: Ausschluss aufgrund von zu geringer Beobachtungszahl (n < 20).

Für die Selektionsmethoden werden als abhängige Variable die Nettoausgaben pro Kopf verwendet. Die Nettoausgaben werden durch die ständige Wohnbevölkerung der Kantone geteilt. Für die quadratische Minimierung und LASSO/Elastic Net werden die Nettoausgaben pro Kopf standardisiert, d.h. der Mittelwert abgezogen und durch die Standardabweichung dividiert.¹⁴

¹⁴ Es hat sich gezeigt, dass die quadratische Minimierung sehr sensitiv auf die Spezifikation der Variablen reagiert hat. Werden die Nettoausgaben pro Kopf verwendet, ergeben sich fast ausnahmslos Randlösungen, d.h. der Koeffizient eines Indikators ist 1, die Koeffizienten der anderen Indikatoren sind entsprechend null. Für Schritt 2 (OLS Regression) nach LASSO/Elastic Net werden die nicht-standardisierten Nettoausgaben pro Kopf verwendet.

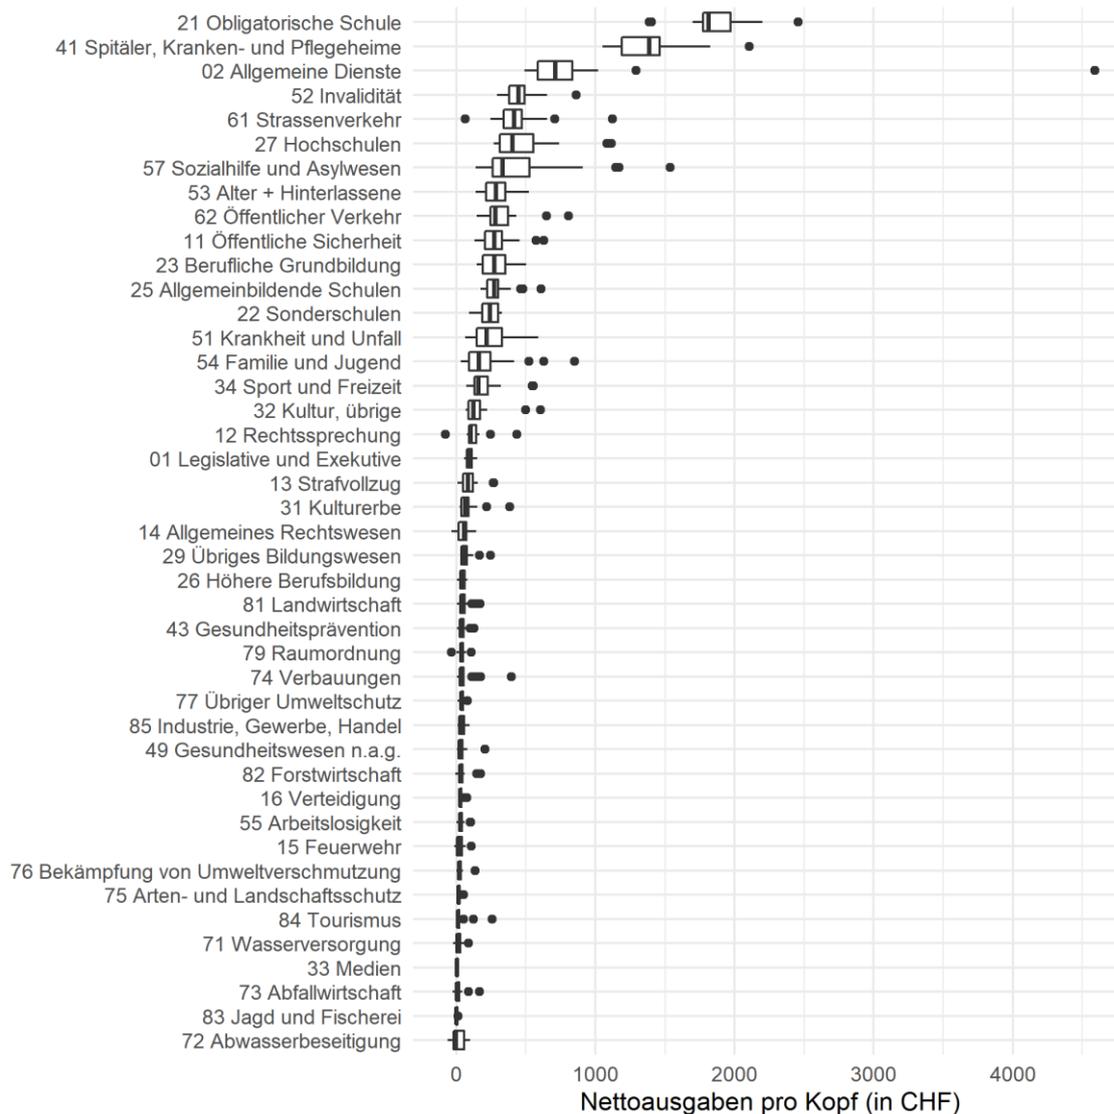
Es wurden jeweils Mittelwerte über drei Jahre gebildet. Grund dafür sind jährliche Schwankungen in den Nettoausgaben der Kantone, die über die Bildung eines Mittelwerts geglättet werden können. Damit fallen Ausreisser (bspw. Sonderausgaben oder Sondereinnahmen in einem Jahr) weniger stark ins Gewicht. Abbildung 4 zeigt die Verteilung der Nettoausgaben pro Kopf nach Funktionen für den Mittelwert der Jahre 2017-2019 anhand von sogenannten Box-Plots. Die Box wird durch das 25%-Quantil und das 75%-Quantil begrenzt.¹⁵ Die Distanz zwischen diesen beiden Quantilen wird Interquartilsabstand (IQA) genannt. Innerhalb der Box befinden sich entsprechend 50% der Kantone. Der vertikale Strich in der Box stellt den Median dar. 50% der Kantone weisen Nettoausgaben pro Kopf tiefer als der Median auf, 50% Nettoausgaben pro Kopf über dem Median. Die horizontalen Linien rechts und links der Box werden Antennen («Whisker») genannt. Die äusseren Begrenzungen der Antennen werden durch Nettoausgaben pro Kopf von $1.5 \cdot IQA$ bzw. $-1.5 \cdot IQA$ gebildet. Kantone mit Nettoausgaben ausserhalb dieser Begrenzungen werden als Punkte dargestellt und als Ausreisser bezeichnet. Auffallend ist, dass die Nettoausgaben pro Kopf zwischen den Kantonen je nach betrachteter Funktion auch nach der Bildung eines Mittelwerts über drei Jahre relativ stark schwanken. Auffallend ist dies bspw. für die Funktion 02 («Allgemeine Dienste»)¹⁶. Ausreisser können auch durch die Bildung eines Mittelwerts nicht vollständig ausgeschlossen werden und die Ergebnisse (zumindest auf Stufe der Funktionen) beeinflussen.

Für die Analyse haben wir die Mittelwerte der Jahre 2017-2019, 2016-2018, 2015-2017, 2014-2016, 2013-2015 verwendet. Im Folgenden sprechen wir der Einfachheit halber jeweils nur von Nettoausgaben pro Kopf. Gemeint sind aber immer die über drei Jahre gemittelten Nettoausgaben pro Kopf.

¹⁵ Beim 25%-Quantil weisen 25% der Kantone Nettoausgaben pro Kopf tiefer respektive 75% der Kantone Nettoausgaben pro Kopf höher als das 25% Quantil auf.

¹⁶ Den Ausreisser nach oben bildet der Kanton Genf. Während die Nettoausgaben in dieser Ausgabenfunktion in den Jahren 2017 und 2018 rund 548 Mio. Franken bzw. 743 Mio. Franken betragen (rund 1100 bzw. 1500 Franken pro Kopf), betragen die Nettoausgaben im Jahr 2019 rund 5,6 Mrd. Franken (rund 11'000 Franken pro Kopf). Derartige Sondereffekte können durch die Bildung eines Mittelwerts nur bedingt abgefangen werden.

Abbildung 4: Verteilung Nettoausgaben pro Kopf nach Funktionen, Mittelwert 2017-2019



Quelle: EFV.

2.2.2 Indikatoren

Die Daten zu den Indikatoren wurden für diese Studie von der EFV zur Verfügung gestellt. Es wurden Daten der Jahre 2012-2019 einbezogen. Ab dem Rechnungsjahr 2015 werden alle Indikatoren jährlich neu berechnet (d.h. ab 2012 bzw. 2011). Für die Analyse wurden die zehn besthenden Indikatoren des Lastenausgleichs berücksichtigt (vgl. Tabelle 1):¹⁷

¹⁷ Wir haben die Analyse auch mit einem alternativen Indikator für die Abbildung der Steilheit des Geländes durchgeführt. Nähere Angaben zum Indikator und die Ergebnisse finden sich im Anhang D dieses Berichts.

Tabelle 1: Indikatoren

Indikator	Beschreibung
<i>Geografisch-topografische Lasten</i>	
Siedlungshöhe	Anteil der ständigen Wohnbevölkerung des Kantons k mit einer Wohnhöhe von über 800 m ü. M. (Spezifische Lasten: Winterdienst, Investitions- und Unterhaltskosten für Infrastruktur)
Steilheit des Geländes	Höhenmedian der produktiven Fläche des Kantons k. (Spezifische Lasten: Schutz vor Naturgefahren in Bergregionen (Waldbewirtschaftung, Gewässerbau, Lawinenverbauungen))
Siedlungsstruktur	Anteil der ständigen Wohnbevölkerung des Kantons k in Siedlungen mit weniger als 200 Einwohnern
(Geringe) Bevölkerungsdichte	Gesamtfläche in Hektaren pro Kopf (ständige Wohnbevölkerung) des Kantons k (Spezifische Lasten: Feingliedrige Besiedlung; Kosten bei der Infrastruktur und bei der Bereitstellung von öffentlichen Dienstleistungen (bspw. Schul- und Gesundheitswesen))
<i>Lasten der Bevölkerungsstruktur</i>	
Armut	Armut Indikator ARMIN des Bundesamts für Statistik (BFS). Quote der Sozialhilfe im weiteren Sinn des Kantons k
Alter	Anteil der Personen über 80 Jahre an der ständigen Wohnbevölkerung des Kantons k
Ausländerintegration	Anteil der ausländischen Wohnbevölkerung aus nicht-Nachbarstaaten und weniger als 12 Jahren Aufenthaltsdauer in der Schweiz an der ständigen Wohnbevölkerung des Kantons k
<i>Kernstadtlasten</i>	
Bevölkerung	Ständige Wohnbevölkerung der Gemeinde g
Beschäftigungsquote	Anzahl Erwerbstätige im Verhältnis zur ständigen Wohnbevölkerung der Gemeinde g
Siedlungsdichte	Summe der ständigen Wohnbevölkerung und der Beschäftigung im Verhältnis zur produktiven Fläche der Gemeinde g

Während die Indikatoren zur Abbildung der geografisch-topografischen Lasten und der Lasten der Bevölkerungsstruktur auf Kantonsebene vorliegen, liegen die Indikatoren zur Abbildung der Kernstadtlasten auf Ebene der Gemeinden vor. Diese werden für die Schätzung der Gewichte auf der Ebene der Kantone aggregiert.¹⁸ Grund dafür ist, dass die Nettoausgaben ebenfalls auf Kan-

¹⁸ Für die Berechnung der Ausgleichszahlungen im SLA F (vgl. Kapitel 3.5) werden wie bis anhin die Gemeindedaten verwendet.

tonsebene vorliegen (vgl. Kapitel 2.2.1). Hierzu werden Zähler und Nenner der Beschäftigungsquote und der Siedlungsdichte über die Gemeinden auf die Ebene der Kantone summiert. Die beiden Indikatoren werden anschliessend auf Basis dieser Aggregate gebildet.

Abbildung 25 bis Abbildung 34 im Anhang A.1 zeigen die Werte der Indikatoren im Querschnitt (Vergleich der Kantone, Mittelwert 2017-2019) und in der zeitlichen Entwicklung (2012-2019, kein Mittelwert). Während die vier Indikatoren des geografisch-topografischen Lastenausgleichs über die Jahre relativ stabil sind, weisen die ersten drei Indikatoren des soziodemografischen Lastenausgleichs (Lasten der Bevölkerungsstruktur: Armutsquote, Altersstruktur und Ausländerintegration) in den meisten Kantonen eine Zunahme über die Zeit auf.

Abbildung 5 zeigt die Korrelationsmatrix der zehn Indikatoren (jeweils Mittelwerte 2017-2019). Der Korrelationskoeffizient gibt dabei den linearen statistischen Zusammenhang zwischen zwei Variablen an und bewegt sich zwischen -1 und 1. Je grösser der Korrelationskoeffizient (absoluter Betrag), desto stärker ist der (positive oder negative) lineare Zusammenhang. Ein positiver linearer Zusammenhang zwischen zwei Variablen x_1 und x_2 bedeutet, dass mit hohen Werten der Variable x_1 hohe Werte der Variable x_2 einhergehen. Ein negativer linearer Zusammenhang bedeutet, dass mit hohen Werten der Variable x_1 tiefe Werte der Variable x_2 einhergehen.

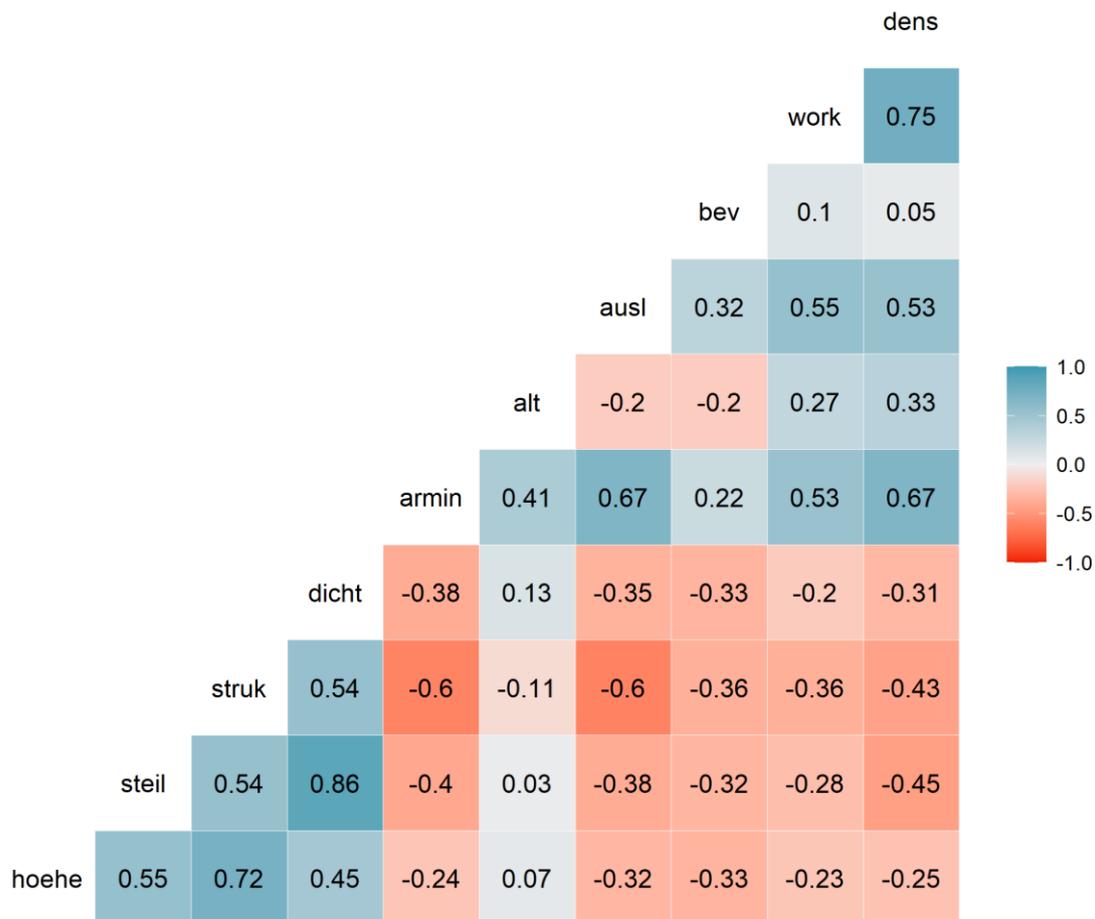
Zwischen den Indikatoren des geografisch-topografischen Lastenausgleichs (Siedlungshöhe, Steilheit des Geländes, Siedlungsstruktur, Bevölkerungsdichte) sind hohe bis sehr hohe positive Korrelationskoeffizienten zwischen 0,5 und 0,9 zu beobachten.

Die ersten drei Indikatoren des soziodemografischen Lastenausgleichs (Lasten der Bevölkerungsstruktur: Armutsquote, Altersstruktur und Ausländerintegration) sind untereinander teilweise positiv, teilweise negativ korreliert. Die Armutsquote ist positiv mit der Altersstruktur und der Ausländerintegration korreliert. Die Altersstruktur und die Ausländerintegration sind demgegenüber negativ korreliert. Während die Armutsquote und die Ausländerintegration negativ mit den Indikatoren des geografisch-topografischen Lastenausgleichs korreliert sind, findet sich nur eine schwache negative (Bevölkerungsstruktur) und eine schwache positive Korrelation (Siedlungshöhe, Steilheit des Geländes, geringe Bevölkerungsdichte) zwischen der Altersstruktur und den Indikatoren des geografisch-topografischen Lastenausgleichs.

Die drei weiteren Indikatoren des soziodemografischen Lastenausgleichs (Kernstadtlasten: Bevölkerung, Beschäftigungsquote, Siedlungsdichte) sind untereinander positiv korreliert, wobei die Korrelation zwischen der Beschäftigungsquote und der Siedlungsdichte mit 0,8 relativ hoch ausfällt. Mit einer Ausnahme (Altersstruktur und Bevölkerung) sind die sechs Indikatoren des soziodemografischen Lastenausgleichs untereinander positiv korreliert. Demgegenüber sind die Korrelationen zwischen den drei Kernstadtindikatoren und den Indikatoren des geografisch-topografischen Lastenausgleichs untereinander alle negativ korreliert.

Bei den Korrelationskoeffizienten gilt es zu beachten, dass diese nur den linearen Zusammenhang zwischen zwei Variablen abbilden. Insbesondere werden dabei mögliche Einflüsse von Drittvariablen nicht berücksichtigt. Mit den regressionsbasierten Modellen, die wir im Anschluss schätzen werden, können die partiellen Zusammenhänge der Indikatoren und den Nettoausgaben pro Kopf geschätzt werden, d.h. den Zusammenhang zwischen einem Indikator und den Nettoausgaben pro Kopf, wenn für die anderen Indikatoren kontrolliert wird.

Abbildung 5: Korrelationsmatrix, Mittelwert 2017-2019



Quelle: EFV, eigene Berechnungen. Anmerkungen: *hoehe*: Siedlungshöhe, *steil*: Steilheit des Geländes, *struk*: Siedlungsstruktur, *dicht*: Bevölkerungsdichte, *armin*: Armutsindikator, *alt*: Altersstruktur, *ausl*: Ausländerintegration, *bev*: Bevölkerung, *work*: Beschäftigungsquote, *dens*: Siedlungsdichte. Mittelwerte 2017-2019

Standardisierung

Die zehn Indikatoren werden für die Analyse standardisiert. D.h. bei jedem Indikator wird der Mittelwert vom jeweiligen Indikatorwert abgezogen und der um den Mittelwert bereinigte Indikatorwert wird durch die Standardabweichung des Indikators dividiert. Durch die Bereinigung um den Mittelwert können die überdurchschnittlichen Indikatorwerte und damit auch die Sonderlasten (vgl. Kapitel 2.1.2) ohne weiteren Rechnungsschritt identifiziert werden. Die Standardisierung bietet folgende weiteren Vorteile:

- Die Indikatoren werden in unterschiedlichen Einheiten gemessen. Die Varianz der Indikatoren wird dadurch zu einem gewissen Grad durch die Einheit getrieben. Durch die Normierung mit der Standardabweichung verschwindet dieser Einfluss.
- Durch die Standardisierung haben die Indikatoren keine Einheit mehr. Die Größen der geschätzten Koeffizienten können innerhalb der Modelle und über die Modelle hinweg miteinander verglichen werden.

- Die Standardisierung der Indikatoren ist zudem für LASSO/Elastic Net notwendig, da die Bestrafungsgrösse von der Skalierung der Koeffizienten abhängt. Es würde in diesem Fall zum Beispiel einen Unterschied machen, ob die ständige Wohnbevölkerung einer Gemeinde in 1000 Personen oder in Personen gemessen wird. Um zu vermeiden, dass das Modell die Koeffizienten von Indikatoren aufgrund dieser arbiträren Skalierung auf null schrumpft, erfolgt vorgängig eine Standardisierung.

3. Ergebnisse

In diesem Kapitel stellen wir die Ergebnisse der Analysen vor. Wir beginnen in Kapitel 3.1 mit den Ergebnissen der beiden Selektionsmethoden. Anschliessend präsentieren wir in Kapitel 3.2 die Ergebnisse der quadratischen Minimierung. In Kapitel 3.4 nehmen wir sodann eine Bewertung der drei Methoden vor und schlagen eine Methode vor. Im abschliessenden Kapitel 3.5 verwenden wir die geschätzten Gewichte der ausgewählten Methode dazu, die Verteilung der Dotation des Lastenausgleichs zu berechnen und allfällige Unterschiede zur heutigen Verteilung aufzuzeigen.

3.1 Selektionsmethoden

3.1.1 Schritt 1: Selektion der Indikatoren

Im ersten Schritt nutzen wir die Selektionsmethoden, um aus den zehn Indikatoren diejenigen mit der grössten Erklärungskraft auszuwählen. Abbildung 6 und Abbildung 7 zeigen die selektierten Indikatoren basierend auf LASSO bzw. Best Subset Selection.¹⁹ Die Abbildungen zeigen die Ergebnisse für den Mittelwert der Jahre 2017-2019. Für 9 von insgesamt 43 Funktionen favorisiert LASSO ein Modell, das nur eine Konstante, aber keine Indikatoren berücksichtigt.²⁰ Als beste Prognose für die Nettoausgaben pro Kopf und Kanton favorisiert LASSO in diesen Fällen den Mittelwert der Nettoausgaben pro Kopf. Von diesen Funktionen gehen somit keine Sonderlasten aus. Best Subset Selection favorisiert für 4 von insgesamt 43 Funktionen ein Modell mit nur einer Konstante.²¹

Bei beiden Ansätzen am häufigsten selektiert werden die Indikatoren Armutsquote und Ausländerintegration. Demgegenüber werden die Indikatoren aus dem geografisch-topografischen Lastenausgleich deutlich weniger häufig selektiert.

Die Abbildung 35 und Abbildung 36 im Anhang C zeigen die selektierten Indikatoren pro Funktion für die beiden Selektionsmethoden auch für die anderen Dreijahres-Mittelwerte (2013-2015,

¹⁹ Die Verwendung von Elastic Net (mit $\alpha = 0,5$) an Stelle von LASSO ergibt in Bezug auf die Auswahl der Indikatoren keine grossen Differenzen. Aus diesem Grund wird Elastic Net im Folgenden nicht weiterverfolgt.

²⁰ Es handelt sich um folgende neun Funktionen: 02 (Allgemeine Dienste), 14 (Allgemeines Rechtswesen), 27 (Hochschulen), 33 (Medien), 61 (Strassenverkehr), 73 (Abfallwirtschaft), 75 (Arten- und Landschaftsschutz), 76 (Bekämpfung von Umweltverschmutzung), 79 (Raumordnung).

²¹ Es handelt sich um folgende vier Funktionen: 02 (Allgemeine Dienste), 75 (Arten- und Landschaftsschutz), 76 (Bekämpfung von Umweltverschmutzung), 79 (Raumordnung).

2014-2016, 2015-2017, 2016-2018, 2017-2019) auf. Die Abbildungen veranschaulichen, dass für einige Funktionen je nach betrachtetem Jahr unterschiedliche Indikatoren selektiert werden. Bspw. selektiert LASSO für die Funktion 21 (Obligatorische Schule) für alle betrachteten Jahre die Siedlungsdichte als relevanten Indikator. Im Jahr 2019 werden daneben aber auch die Indikatoren Steilheit des Geländes, Armutsindikator, Altersstruktur, Bevölkerung und Beschäftigungsquote ausgewählt, nicht aber für das Jahr 2018. Dies ist eine Quelle für Schwankungen in den geschätzten Sonderlasten über die Jahre und damit auch für die Gewichte, die basierend darauf berechnet werden.

3.1.2 Schritt 2: Schätzung des reduzierten Regressionsmodells mit OLS

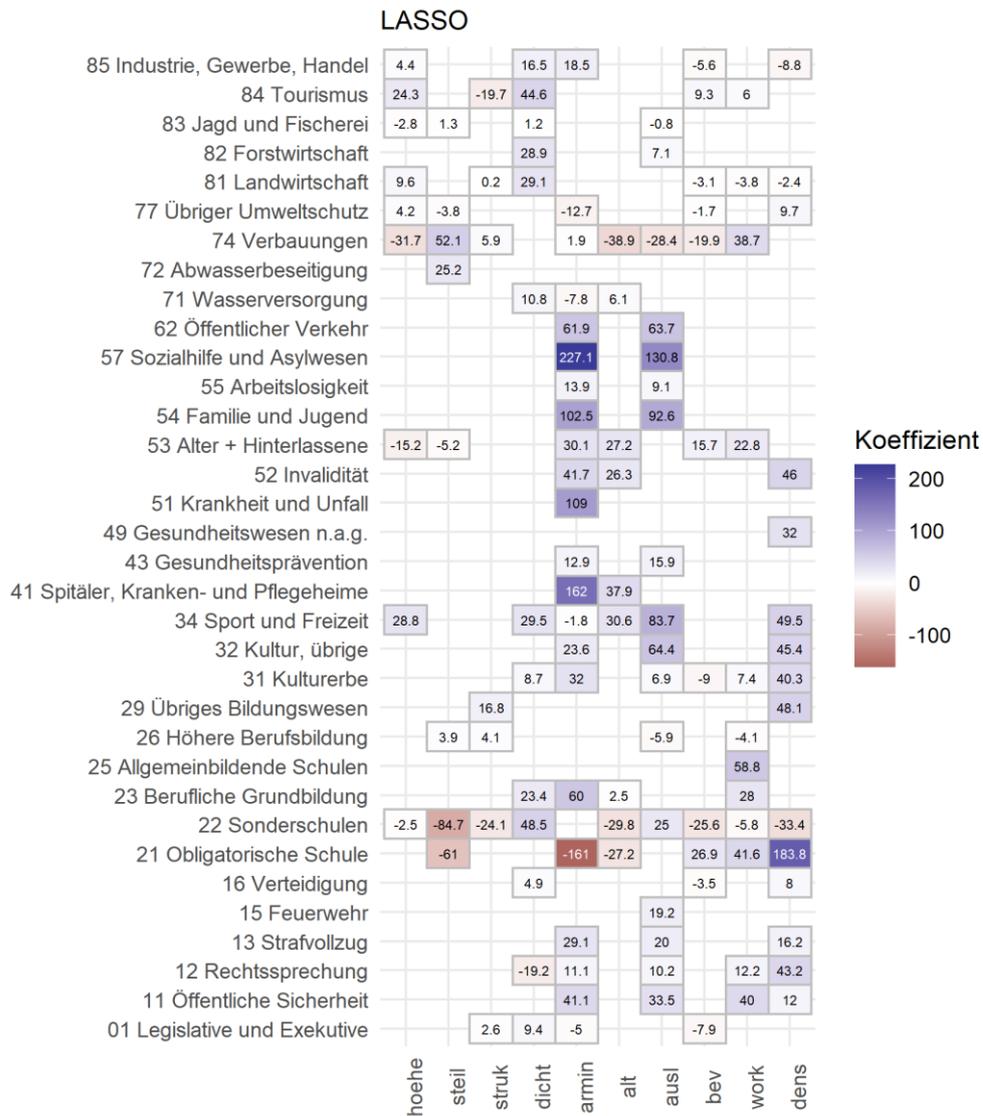
Abbildung 6 und Abbildung 7 zeigen für die selektierten Indikatoren auch die mit OLS geschätzten Koeffizienten (für den Mittelwert der Jahre 2017-2019). Da die Indikatoren standardisiert sind, kann die Grösse der Koeffizienten zwischen den Indikatoren sowohl innerhalb wie auch über die Funktionen hinweg miteinander verglichen werden.

Nachfolgend greifen wir drei Funktionen heraus, um die Ergebnisse zu diskutieren. Dabei fokussieren wir uns auf Funktionen, die gemessen an den aggregierten Nettoausgaben pro Kopf (vgl. Abbildung 4) relativ bedeutend sind.

- *21: Obligatorische Schule*: LASSO und Best Subset Selection wählen die Indikatoren Steilheit des Geländes, Armutsindikator und Siedlungsdichte (LASSO überdies auch Altersstruktur, Bevölkerung und Beschäftigungsquote). Die Siedlungsdichte trägt gemessen an der Grösse des Koeffizienten am meisten zum Erklärungsgehalt des Modells bei. Mit steigender Siedlungsdichte gehen steigende Nettoausgaben pro Kopf im Bereich der obligatorischen Schule einher. Auffallend sind die negativen Koeffizienten für die Indikatoren Steilheit des Geländes und Armutsindikator. Je steiler das Gelände und je höher der Armutsindikator, desto tiefer sind die Nettoausgaben pro Kopf.²²
- *41: Spitäler, Kranken- und Pflegeheime*: LASSO selektiert sowohl die Armutsquote wie auch die Altersstruktur, während Best Subset Selection nur die Armutsquote selektiert. Die Koeffizienten der ausgewählten Indikatoren sind positiv, wobei der Koeffizient der Armutsquote relativ gross ist.
- *61: Strassenverkehr*: Während LASSO ein Modell ohne Indikatoren bevorzugt, selektiert Best Subset Selection die Indikatoren Siedlungshöhe, Siedlungsstruktur, Beschäftigungsquote und Siedlungsdichte. Dabei weisen die Siedlungshöhe und die Beschäftigungsquote positive Koeffizienten auf. Demnach gehen mit einem überdurchschnittlichen Anteil der Wohnbevölkerung mit einer Wohnhöhe von über 800 m ü. M. und einer überdurchschnittlichen Beschäftigungsquote höhere Nettoausgaben pro Kopf im Bereich Strassenverkehr einher.

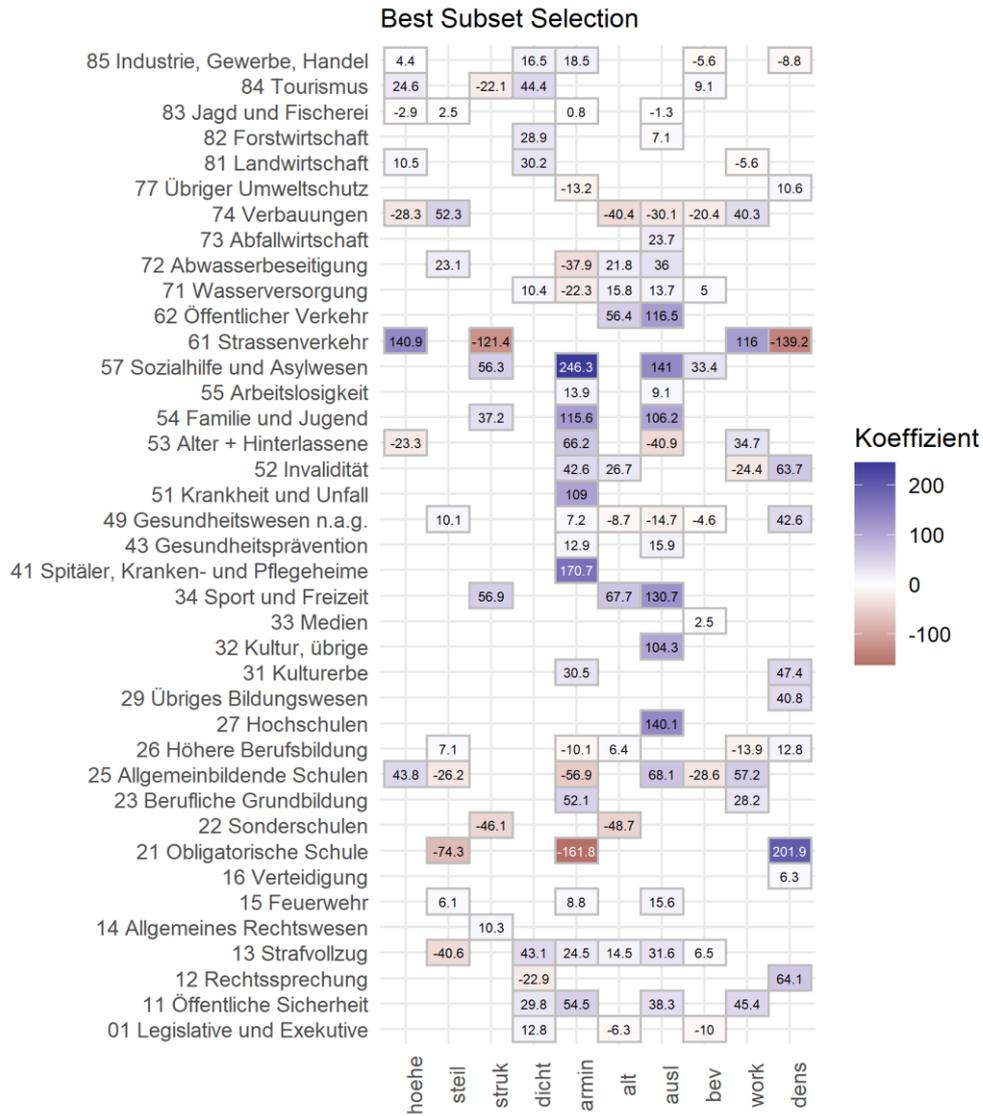
²² Beide Indikatoren weisen somit für Kantone, die überdurchschnittlich steil sind oder eine überdurchschnittliche Armutsquote aufweisen, auf «Minderlasten» hin. Oder umgekehrt: Sonderlasten hätten jene Kantone, die unterdurchschnittlich steil sind oder eine unterdurchschnittliche Armutsquote aufweisen. Wie in Kapitel 2.1.2 beschrieben, werden negative Koeffizienten bei der Berechnung von Sonderlasten nicht berücksichtigt. Vor dem Hintergrund, dass die zehn Indikatoren mit Sonderlasten in Verbindung gebracht werden und entsprechend positive Koeffizienten zu erwarten sind, zeigen die Ergebnisse, dass die so definierten Indikatoren je nach Funktion nicht immer optimal sind.

Abbildung 6: Geschätzte Koeffizienten reduziertes Regressionsmodell (OLS), Indikatorselektion gemäss LASSO, Mittelwert der Jahre 2017-2019



Quelle: EFV, eigene Berechnungen.

Abbildung 7: Geschätzte Koeffizienten reduziertes Regressionsmodell (OLS), Indikatorenselektion gemäss Best Subset Selection, Mittelwert der Jahre 2017-2019



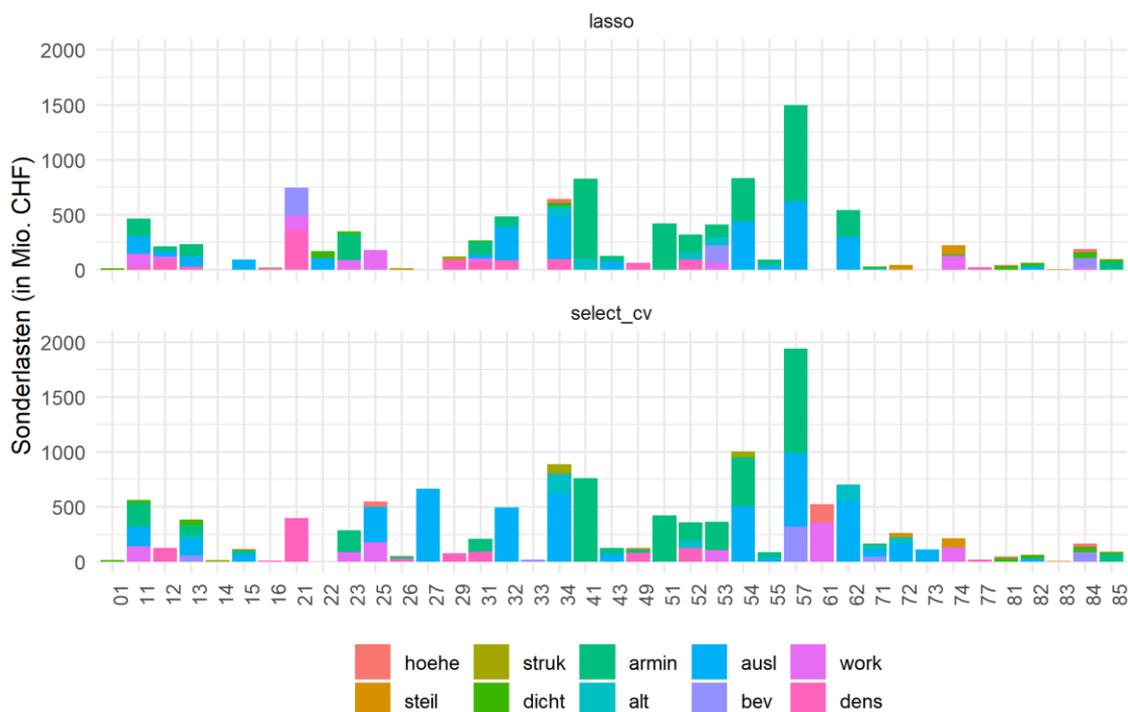
Quelle: EFV, eigene Berechnungen.

3.1.3 Schritt 3: Berechnung der Sonderlasten

Auf Basis der geschätzten Koeffizienten werden die Sonderlasten geschätzt. Wie in Kapitel 2.1.2 ausgeführt, werden nur Indikatoren mit positiven Koeffizienten für die Schätzung der Sonderlasten verwendet. Da bei der Quadratischen Minimierung die Gewichte der Indikatoren direkt geschätzt und somit keine Sonderlasten berechnet werden, beziehen sich die folgenden Ergebnisse nur auf die Selektionsmethoden.

Abbildung 8 führt die berechneten Sonderlasten für den Mittelwert der Jahre 2017-2019 differenziert nach Selektionsmethode, Funktion und Indikator auf.

Abbildung 8: Sonderlasten nach Methoden, Funktionen und Indikatoren, Mittelwert der Jahre 2017-2019



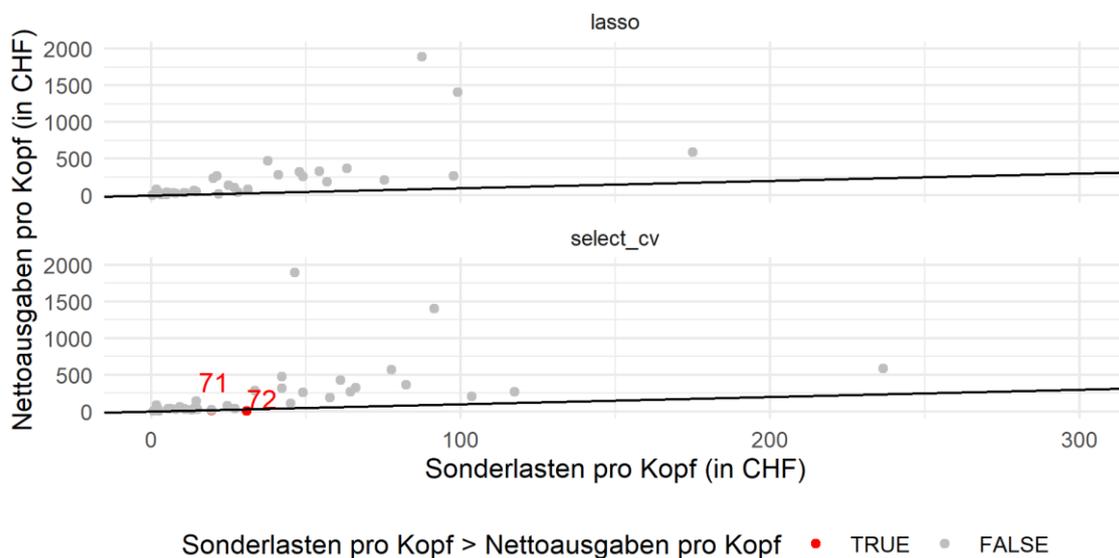
Quelle: EFV, eigene Berechnungen.

Bei LASSO fallen die Funktionen 21 (Obligatorische Schule), 41 (Spitäler, Alters- und Pflegeheime), 54 (Familie und Jugend) und 57 (Sozialhilfe und Asylwesen) mit den höchsten Sonderlasten auf. Während bei der Funktion 21 (Obligatorische Schule) die Indikatoren Siedlungsdichte, Bevölkerung und Beschäftigungsquote dominieren, sind dies bei den Funktionen 41, 54 und 57 die Armutsquote und die Ausländerintegration. Im Vergleich dazu fallen bei Best Subset Selection die Sonderlasten der Funktion 21 (Obligatorische Schule) etwas weniger stark, dafür die Sonderlasten in der Funktion 34 (Sport und Freizeit) etwas stärker aus.

Die Selektionsmodelle wählen die Indikatoren so aus, dass der Unterschied zwischen effektiven Nettoausgaben pro Kopf und den prognostizierten Nettoausgaben pro Kopf im Durchschnitt

möglichst gering ausfallen. Im Einzelfall (Funktion und Kanton) wird es Abweichungen nach unten und oben geben, d.h. die prognostizierten Nettoausgaben pro Kopf können über oder unterhalb der effektiven Nettoausgaben pro Kopf liegen. Bei dieser Gegenüberstellung werden alle Koeffizienten und Indikatoren berücksichtigt. Da wir bei der Berechnung der Sonderlasten nur die Indikatoren mit Koeffizienten mit positiven Vorzeichen verwenden, ist im Einzelfall nicht ausgeschlossen, dass die geschätzten Sonderlasten pro Kopf die effektiven Nettoausgaben pro Kopf übertreffen. Neben der Annahme, dass nur Indikatoren mit Koeffizienten mit positivem Vorzeichen für die Berechnung der Sonderlasten aufgenommen werden, begünstigt auch eine schlechte Qualität der Schätzung (die geschätzten Nettoausgaben pro Kopf weichen stark von den effektiven Nettoausgaben pro Kopf ab) das Auftreten von geschätzten Sonderlasten pro Kopf, die über den effektiven Nettoausgaben pro Kopf liegen. Wir haben daher analysiert, wie sich die geschätzten Sonderlasten pro Kopf zu den effektiven Nettoausgaben pro Kopf verhalten. In der Abbildung 9 sind die effektiven Nettoausgaben pro Kopf (y-Achse) den geschätzten Sonderlasten pro Kopf (x-Achse) pro Funktion gegenübergestellt. In der Abbildung ist die 45-Grad Linie eingezeichnet. Für Punkte über dieser Linie gilt: Effektive Nettoausgaben pro Kopf > geschätzte Sonderlasten pro Kopf, für Punkte unterhalb dieser Linie gilt: Effektive Nettoausgaben pro Kopf < geschätzte Sonderlasten pro Kopf. Bei LASSO (oben) gibt es keine Funktion, für welche die geschätzten Sonderlasten pro Kopf die effektiven Nettoausgaben pro Kopf übertreffen. Bei Best Subset Selection (unten) gibt es zwei Funktionen (72: Abwasserbeseitigung, 73: Abfallwirtschaft), bei welchen dies der Fall ist. Gemessen an den Nettoausgaben pro Kopf handelt es sich hierbei um relativ kleine Funktionen.

Abbildung 9: Gegenüberstellung geschätzte Sonderlasten pro Kopf und effektive Nettoausgaben pro Kopf, Mittelwert der Jahre 2017-2019



Quelle: EFV, eigene Berechnungen.

Tabelle 2 (LASSO) und Tabelle 3 (Best Subset Selection) bilden die Sonderlasten, die Sonderlasten pro Kopf und den Anteil der Sonderlasten an den Nettoausgaben nach Kanton und Methode ab. Absolut und pro Kopf betrachtet weisen die Kantone Basel-Stadt, Genf und Waadt für beide

Methoden die höchsten Sonderlasten auf. Der Anteil der Sonderlasten an den Nettoausgaben beträgt über alle Kantone betrachtet 11,5% (LASSO) bzw. 14,6% (Best Subset Selection), wobei die Werte zwischen rund 1% und 48% (LASSO) / 54% (Best Subset Selection) schwanken.

Tabelle 2: Sonderlasten, Sonderlasten pro Kopf und Anteil Sonderlasten an den Nettoausgaben nach Kanton, LASSO

Kanton	Geschätzte Sonderlasten (in Mio. CHF)	Bevölkerung (in Mio.)	Nettoausgaben (in Mio. CHF)	Sonderlasten pro Kopf	Anteil Sonderlasten an Nettoausgaben
Zürich	1'275	1.522	15'896	838	8.0%
Bern	621	1.035	9'576	600	6.5%
Luzern	26	0.410	3'104	62	0.8%
Uri	27	0.036	279	733	9.6%
Schwyz	8	0.159	1'189	48	0.6%
Obwalden	11	0.038	283	291	3.9%
Nidwalden	1	0.043	320	33	0.4%
Glarus	18	0.040	338	445	5.3%
Zug	167	0.127	1'274	1'317	13.1%
Freiburg	122	0.319	2'985	382	4.1%
Solothurn	199	0.273	2'283	729	8.7%
Basel-Stadt	1'305	0.195	2'741	6'696	47.6%
Basel-Landschaft	56	0.288	2'892	193	1.9%
Schaffhausen	21	0.082	681	261	3.1%
Appenzell A.Rh.	12	0.055	454	215	2.6%
Appenzell I.Rh.	7	0.016	122	432	5.7%
St. Gallen	16	0.508	4'488	32	0.4%
Graubünden	278	0.198	1'994	1'401	13.9%
Aargau	35	0.678	4'824	51	0.7%
Thurgau	2	0.277	2'198	8	0.1%
Tessin	496	0.353	3'390	1'407	14.6%
Waadt	2'084	0.799	9'405	2'607	22.2%
Wallis	392	0.344	2'960	1'142	13.3%
Neuenburg	323	0.177	1'852	1'822	17.4%
Genf	2'309	0.500	9'803	4'621	23.6%
Jura	48	0.073	706	654	6.8%
Total	9'858	8.545	86'036	1'154	11.5%

Quelle: EFV, eigenen Berechnungen.

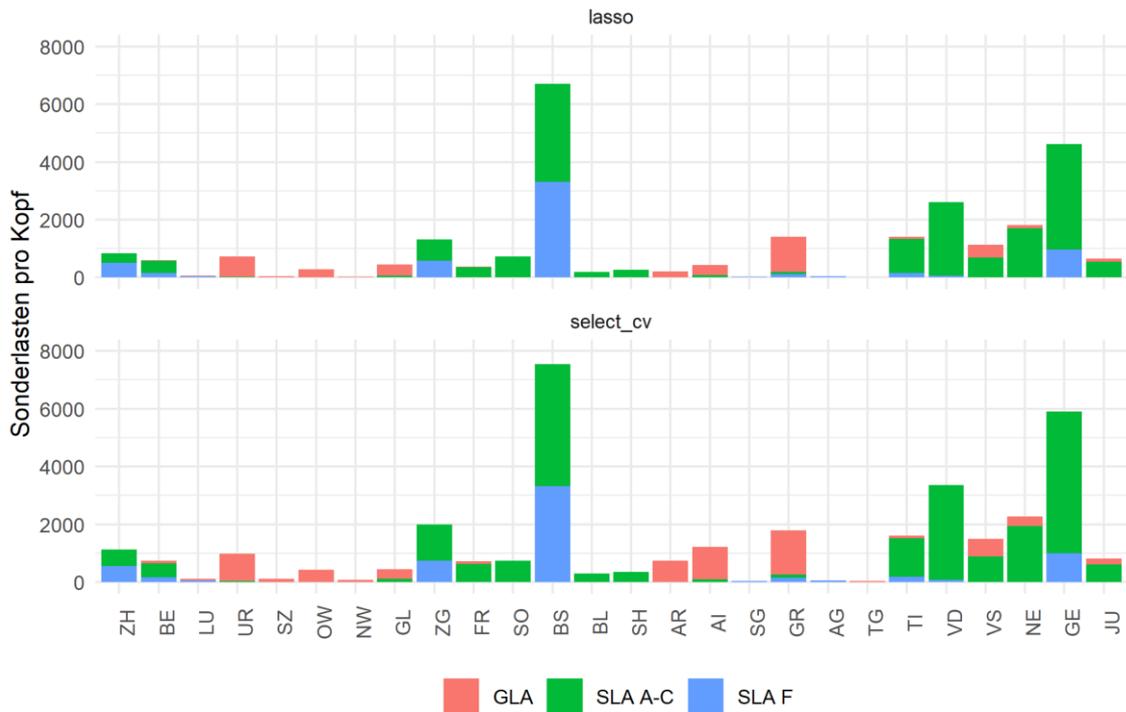
Tabelle 3: Sonderlasten, Sonderlasten pro Kopf und Anteil Sonderlasten an den Nettoausgaben nach Kanton, Best Subset Selection

Kanton	Geschätzte Sonderlasten (in Mio. CHF)	Bevölkerung (in Mio.)	Nettoausgaben (in Mio. CHF)	Sonderlasten pro Kopf	Anteil Sonderlasten an Nettoausgaben
Zürich	1'711	1.522	15'896	1'124	10.8%
Bern	768	1.035	9'576	742	8.0%
Luzern	49	0.410	3'104	119	1.6%
Uri	35	0.036	279	972	12.7%
Schwyz	17	0.159	1'189	108	1.4%
Obwalden	16	0.038	283	428	5.7%
Nidwalden	3	0.043	320	75	1.0%
Glarus	18	0.040	338	448	5.4%
Zug	253	0.127	1'274	1'994	19.8%
Freiburg	228	0.319	2'985	716	7.6%
Solothurn	202	0.273	2'283	740	8.9%
Basel-Stadt	1'470	0.195	2'741	7'544	53.6%
Basel-Landschaft	86	0.288	2'892	298	3.0%
Schaffhausen	29	0.082	681	349	4.2%
Appenzell A.Rh.	41	0.055	454	736	9.0%
Appenzell I.Rh.	20	0.016	122	1'227	16.2%
St. Gallen	17	0.508	4'488	34	0.4%
Graubünden	357	0.198	1'994	1'797	17.9%
Aargau	37	0.678	4'824	55	0.8%
Thurgau	12	0.277	2'198	44	0.5%
Tessin	564	0.353	3'390	1'598	16.6%
Waadt	2'687	0.799	9'405	3'362	28.6%
Wallis	514	0.344	2'960	1'494	17.4%
Neuenburg	401	0.177	1'852	2'267	21.7%
Genf	2'952	0.500	9'803	5'909	30.1%
Jura	60	0.073	706	812	8.4%
Total	12'545	8.545	86'036	1'468	14.6%

Quelle: EFV, eigenen Berechnungen.

Abbildung 10 zeigt die Sonderlasten pro Kopf differenziert nach Kanton und Ausgleichsgefäss. Die Sonderlasten der drei Kantone mit den höchsten Sonderlasten pro Kopf (BS, VD und GE) werden durch die Indikatoren des SLA A-C und des SLA F geprägt.

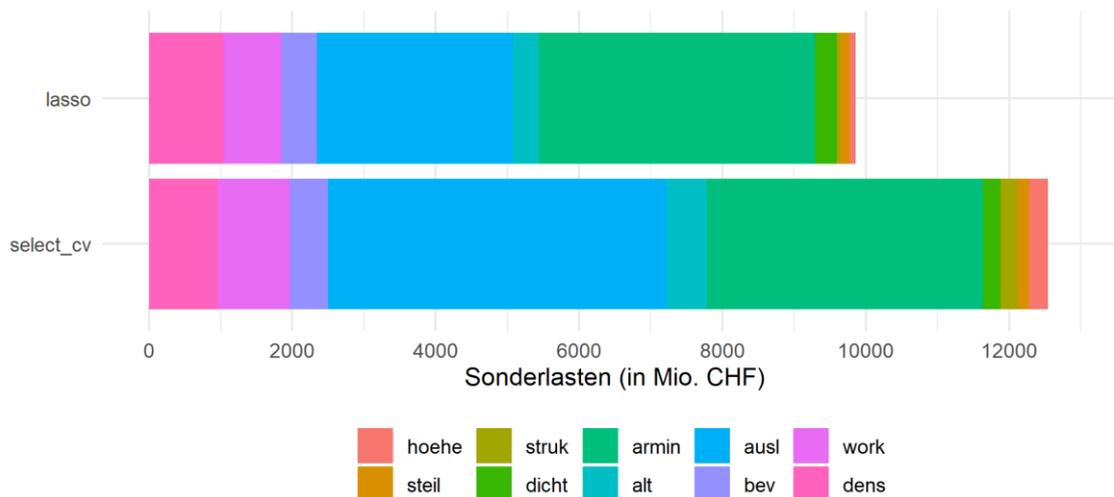
Abbildung 10: Sonderlasten pro Kopf nach Kanton und Ausgleichsgefäss



Quelle: EFV, eigenen Berechnungen.

Abbildung 11 bildet die geschätzten Sonderlasten differenziert nach Methoden und Indikatoren ab. Werden die Indikatoren mit LASSO selektiert, belaufen sich die Sonderlasten für den Mittelwert der Jahre 2017-2019 auf rund 9,9 Mrd. CHF. Im Vergleich dazu belaufen sich die Sonderlasten bei Best Subset Selection auf rund 12,5 Mrd. CHF.

Abbildung 11: Sonderlasten nach Methoden und Indikatoren, Mittelwert der Jahre 2017-2019



Quelle: EFV, eigene Berechnungen.

Die hier ausgewiesenen geschätzten Sonderlasten fallen höher aus als die im Gutachten von Eco-plan²³ für die Jahre 2008-2011 ausgewiesen wurden. Nach unserer Einschätzung können für die Erklärung der Unterschiede folgende Gründe genannt werden:

- Im Gutachten von Eco-plan wurden Funktionen aus der Analyse ausgeschlossen, von denen a priori davon ausgegangen wird, dass sie nur Ausgaben für Wahlbedarf abdecken. Dabei handelt es sich um die Funktionen «Allgemeine Verwaltung» (0), «Militärische Landesverteidigung» (161), «Kultur, Sport und Freizeit, Kirche» (3), «Invalidenversicherung IV» (521), «Alters- und Hinterlassenenversicherung AHV» (531), «Nationalstrassen» (611), «Volkswirtschaft» (8) (mit Ausnahme «Forstwirtschaft» (820)) und «Finanzen und Steuern» (9). Bei unserer Analyse haben wir die Funktion «Finanzen und Steuern» (9) sowie vereinzelt Funktionen aus «Volkswirtschaft» (aufgrund von Nettoausgaben < 0 für alle Kantone) ausgeschlossen, die anderen oben genannten Funktionen aber nicht. Wir haben darauf verzichtet, Funktionen bereits vor der Analyse dahingehend zu beurteilen, ob diese überhaupt Sonderlasten enthalten können und basierend darauf Ausschlüsse vorzunehmen, da die Unterscheidung in Wahlbedarf und Sonderlasten nicht immer eindeutig ist.
- Im Gutachten von Eco-plan wurden die Sonderlasten anders definiert als im vorliegenden Bericht. Für die Berechnung der Sonderlasten pro Indikatorgruppe werden im Gutachten von Eco-plan jeweils die prognostizierten Nettoausgaben pro Kopf des Kantons mit dem tiefsten Indikatorwert (und damit den tiefsten prognostizierten Nettoausgaben pro Kopf) von den prognostizierten Nettoausgaben pro Kopf der anderen Kantone abgezogen. Die prognostizierten Nettoausgaben pro Kopf nach Abzug der prognostizierten Nettoausgaben pro Kopf des

²³ Eco-plan (2013). Kostenrelevanz und Gewichtung von Indikatoren im Lastenausgleich. Analyse für die Jahre 2008-2011. Gutachten im Auftrag des Eidgenössischen Finanzverwaltung. Bern. Das Gutachten weist im Durchschnitt der Jahre 2008-2011 Sonderlasten von CHF 5,585 Mrd. aus.

Kantons mit dem tiefsten Indikatorwert bilden die sog. Lasten ab. Lasten über einem bestimmten Schwellenwert²⁴ werden anschliessend als Sonderlasten bezeichnet. Diese Berechnungsweise führt dazu, dass die Sonderlasten in der Tendenz tiefer ausfallen als die Sonderlasten, die aufgrund der im vorliegenden Bericht vorgeschlagenen Methode berechnet werden.

- Wie bereits in Kapitel 2.1.2 angemerkt, haben wir für einen möglichen Wahlbedarf nicht kontrolliert. Dies kann zu einer Über- oder Unterschätzung der Sonderlasten führen.

3.2 Quadratische Minimierung

Bei der Quadratischen Minimierung bewegen sich die geschätzten Koeffizienten zwischen 0 und 1 und können direkt als Gewichte interpretiert werden. Abbildung 12 präsentiert die Ergebnisse für den Mittelwert der Jahre 2017-2019. Im Gegensatz zu den Selektionsmethoden (vgl. Kapitel 3.1.1) werden bei der Quadratischen Minimierung für alle Funktionen Modelle mit einer strikt positiven Menge von Indikatoren geschätzt.

Die Abbildung 37 im Anhang C zeigt die selektierten Indikatoren pro Funktion auch für die anderen Dreijahres-Mittelwerte (2013-2015, 2014-2016, 2015-2017, 2016-2018, 2017-2019) auf. Wie bei den Selektionsmethoden ist auch hier ersichtlich, dass für einige Funktionen je nach betrachtetem Jahr unterschiedliche Indikatoren selektiert werden.

Nachfolgend greifen wir wie bei der Diskussion zu den Selektionsmethoden (vgl. Kapitel 3.1.2) wiederum drei Funktionen heraus, um die Ergebnisse zu diskutieren. Dabei fokussieren wir uns auf Funktionen, die gemessen an den aggregierten Nettoausgaben pro Kopf (vgl. Abbildung 4) relativ bedeutend sind.

- *21: Obligatorische Schule*: Die Quadratische Minimierung schätzt für die Indikatoren Siedlungsstruktur, Bevölkerung, Beschäftigungsquote und Siedlungsdichte Koeffizienten > 0 . Die Koeffizienten der anderen Indikatoren werden auf null gesetzt. Die Siedlungsdichte wird dabei am stärksten gewichtet.
- *41: Spitäler, Kranken- und Pflegeheime*: Die Quadratische Minimierung schätzt für die Indikatoren Siedlungsstruktur, Bevölkerungsdichte, Armutsquote, Altersstruktur und Siedlungsdichte Koeffizienten > 0 . Die Koeffizienten der anderen Indikatoren werden wiederum auf null gesetzt. Die Armutsquote wird dabei am stärksten gewichtet.
- *61: Strassenverkehr*: Die Quadratische Minimierung schätzt für die Indikatoren Siedlungshöhe, Steilheit des Geländes, Bevölkerungsdichte, Ausländerintegration, Bevölkerung und Beschäftigungsquote Koeffizienten > 0 . Die Koeffizienten der anderen Indikatoren werden auf null gesetzt. Die Indikatoren mit Koeffizienten > 0 werden in dieser Funktion ähnlich stark gewichtet.

²⁴ Bevölkerungsgewichteter Durchschnitt der Lasten pro Kopf.

Abbildung 12: Geschätzte Koeffizienten Quadratische Minimierung, Mittelwert der Jahre 2017-2019



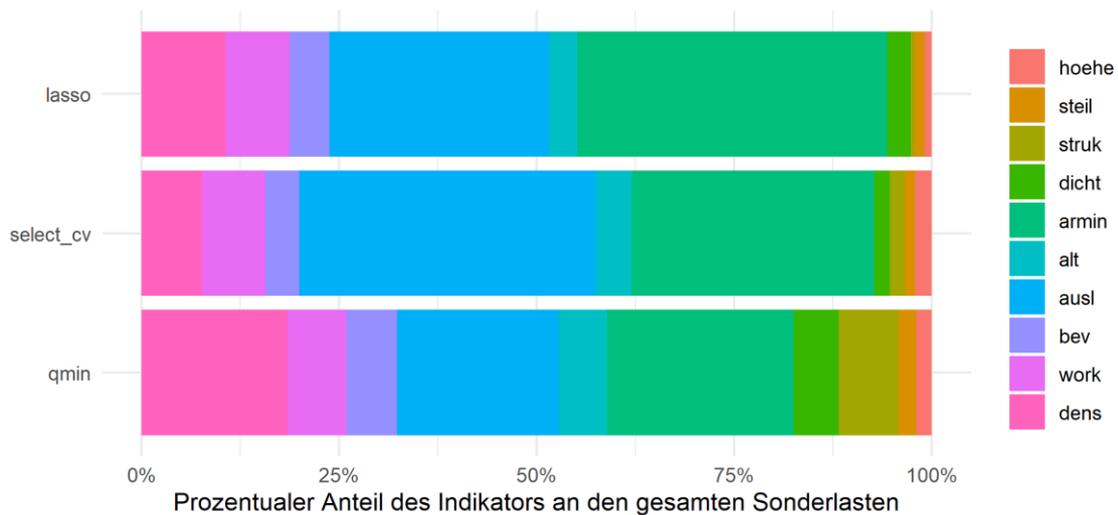
Quelle: EFV, eigene Berechnungen.

3.3 Gewichte

In diesem Kapitel präsentieren wir die Ergebnisse zu den Gewichten der einzelnen Indikatoren und Indikatorgruppen (Ausgleichsgefässen). Während die Gewichte bei den Selektionsmethoden über die geschätzten Sonderlasten berechnet werden, liefert die Quadratische Minimierung direkt die Gewichtung der Indikatoren pro Funktion. Für die Berechnung der Gewichte der Indikatoren über alle Funktionen wurden diese mit den Nettoausgaben der jeweiligen Funktion gewichtet. Abbildung 13 zeigt, dass bei LASSO und Best Subset Selection die Indikatoren Armutsquote (39,2% bzw. 30,7%) und Ausländerintegration (27,8% bzw. 37,6%) den grössten Anteil an den

Sonderlasten ausmachen. Bei der Quadratischen Minimierung weisen die Indikatoren Armutsquote, Ausländerintegration und Siedlungsdichte mit 23,6%, 20,5% und 18,5% die höchsten Anteile an den Sonderlasten auf. Auffallend ist, dass bei LASSO und Best Subset Selection die Indikatoren des GLA je höchstens 3% der Sonderlasten erklären. Bei der Quadratischen Minimierung erhalten die Indikatoren des geografisch-topografischen Lastenausgleichs insgesamt mehr Gewicht; einzeln betrachtet liegt kein Indikator des GLA aber über 8%.

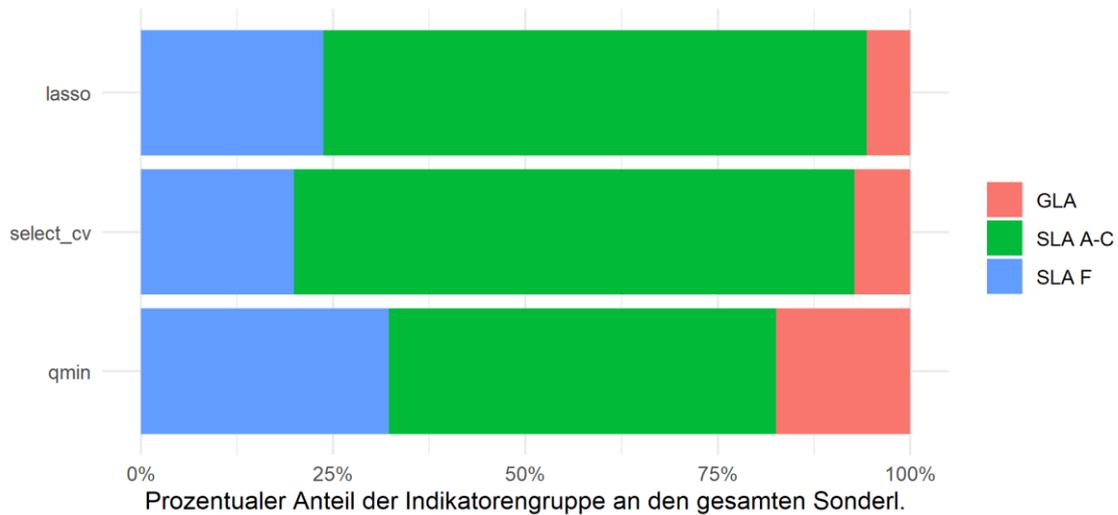
Abbildung 13: Anteil der Indikatoren an den Sonderlasten, Mittelwert der Jahre 2017-2019



Quelle: EFV, eigene Berechnungen.

In Abbildung 14 werden die Anteile der Indikatorengruppen an den Sonderlasten differenziert nach Methoden abgebildet. Wie die Ergebnisse in Abbildung 13 bereits vermuten lassen, machen die Indikatoren des SLA A-C zusammen den grössten Anteil der Sonderlasten aus. Bei LASSO und Best Subset Selection sind es rund 70%, bei der Quadratischen Minimierung rund 50%. Die Anteile der Indikatoren des SLA F und des GLA an den Sonderlasten belaufen sich auf rund 20% bzw. 10% (LASSO und Best Subset Selection) und auf 32% bzw. 18% (Quadratische Minimierung).

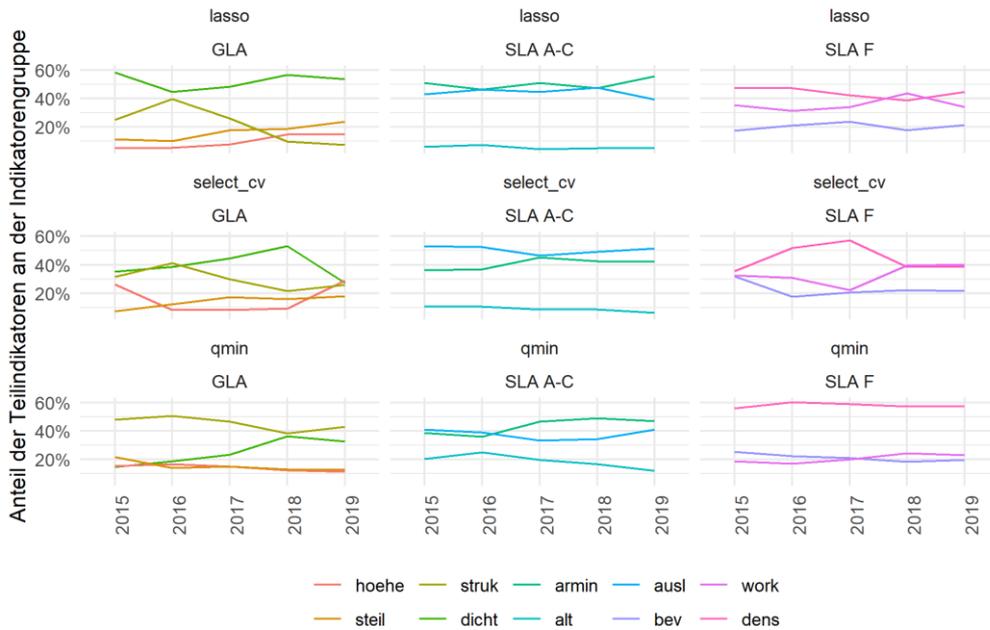
Abbildung 14: Anteil der Indikatorengruppen an den Sonderlasten, Mittelwert der Jahre 2017-2019



Quelle: EFV, eigene Berechnungen.

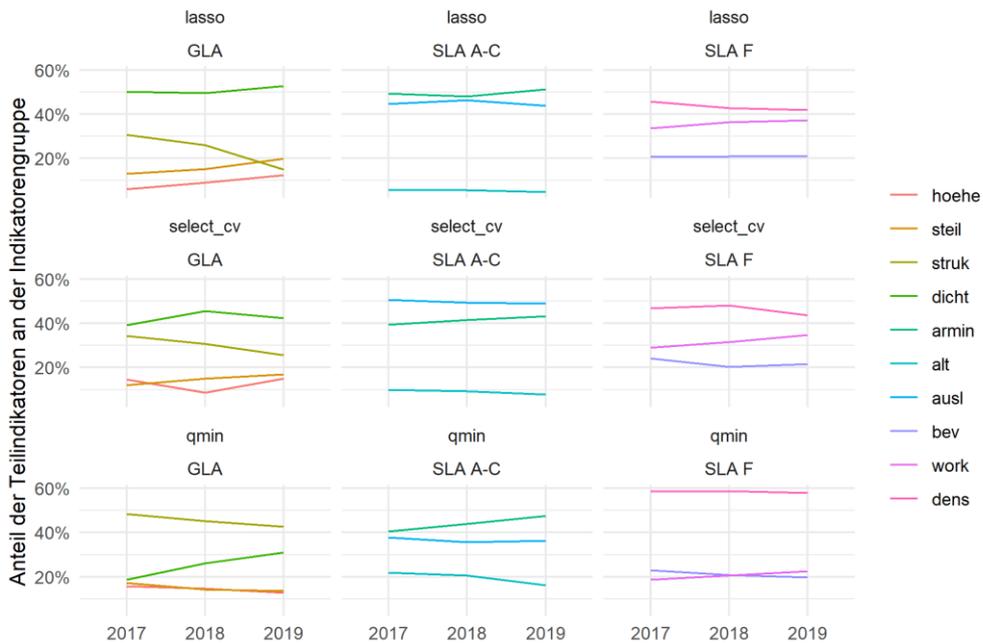
Für die Verteilung der Dotation des Lastenausgleichs von besonderer Bedeutung sind die Gewichte der Indikatoren innerhalb der Indikatorengruppen. In Abbildung 15 ist die Entwicklung der Gewichte der Indikatoren innerhalb der Indikatorgruppen über die Zeit abgebildet. Die Ergebnisse zeigen unabhängig von der verwendeten Methode, dass die berechneten Gewichte über die Zeit teilweise stark schwanken. Dies gilt vor allem für die Gewichte der Indikatoren des GLA. Die Gewichte der Indikatoren des SLA F und des SLA A-C sind dagegen über die Zeit stabiler. Um die Gewichte zu stabilisieren, haben wir eine Mittelung über jeweils drei Jahre vorgenommen. Abbildung 16 präsentiert die Ergebnisse. Das Jahr 2019 beinhaltet in diesem Fall den Durchschnitt aus den Gewichten der Mittelwerte der Jahre 2015-2017, 2016-2018, 2017-2019.

Abbildung 15: Anteil der Indikatoren an den Sonderlasten der Indikatorgruppen



Quelle: EFV, eigene Berechnungen. Anmerkungen: Die angegebenen Jahre weisen auf das jeweils letzte Jahr des betrachteten Dreijahresmittelwerts hin. Das Jahr 2019 bspw. steht für den Mittelwert aus den Jahren 2017-2019.

Abbildung 16: Anteil der Indikatoren an den Sonderlasten der Indikatorgruppen, Mittelwerte



Quelle: EFV, eigene Berechnungen. Anmerkungen: Die angegebenen Jahre weisen auf das jeweils letzte Jahr des betrachteten Dreijahresmittelwerts hin. Das Jahr 2019 bspw. steht für den Durchschnitt aus den Gewichten der Mittelwerte der Jahre 2015-2017, 2016-2018, 2017-2019.

Über die konkreten Gewichte gibt die Tabelle 4 Auskunft. Zum Vergleich sind in der letzten Spalte die effektiven Gewichte der Indikatoren abgebildet. Dabei handelt es sich um die über die letzten vier Ausgleichsjahre gemittelten Gewichte.²⁵ Pro Methode sind jeweils die Gewichte für den Mittelwert der Jahre 2017-2019 (2017-2019) und den Durchschnitt aus den Gewichten der Mittelwerte der Jahre 2015-2017, 2016-2018, 2017-2019 (Spalte *gemittelt*) aufgeführt. Bei den Gewichten der Indikatoren des GLA treten die grössten Unterschiede im Vergleich zu den effektiven Werten auf. Siedlungshöhe und Steilheit, die heute beide mit je einem Drittel gewichtet werden, erhalten aufgrund der vorliegenden Analyse zum Teil deutlich geringere Gewichte. Demgegenüber werden Siedlungsstruktur und Bevölkerungsdichte gegenüber heute stärker gewichtet. Besonders deutlich ist dies bei der Bevölkerungsdichte sichtbar. Bei der Siedlungsstruktur sind die Unterschiede je nach Methode etwas weniger stark ausgeprägt, bei LASSO fallen die Gewichte sogar etwas tiefer aus als die effektiven Werte. Die Veränderung der Gewichte der Indikatoren im SLA A-C ist weniger ausgeprägt als im GLA und beschränkt sich vornehmlich auf die Gewichte, die auf LASSO und Best Subset Selection basieren. Die Altersstruktur wird etwas weniger stark gewichtet, die Ausländerintegration etwas stärker. Die Veränderung der Gewichtung der Armutsquote ist abhängig von der Methode. LASSO gewichtet im Vergleich den Indikator etwas stärker, Best Subset Selection etwas weniger stark. Die Quadratische Minimierung liefert für alle drei Indikatoren des SLA A-C ähnliche Gewichte wie die effektiven Werte. Bei den Indikatoren des SLA F werden bei LASSO und Best Subset Selection die Siedlungsdichte und die Beschäftigungsquote auf Kosten der Bevölkerung stärker gewichtet. Bei der Quadratischen Minimierung ist es die Siedlungsdichte, die auf Kosten der Bevölkerung und der Beschäftigungsquote stärker gewichtet werden.

Tabelle 4: Gewichte der Indikatoren innerhalb der Indikatorengruppen

Ausgleichsgefäss	Indikator	LASSO		Best Subset Selection		Quadratische Minimierung		Effektiv*
		2017-2019	gemittelt	2017-2019	gemittelt	2017-2019	gemittelt	
GLA	Siedlungshöhe	15,1%	12,3%	29,0%	14,9%	11,3%	12,8%	33,3%
	Steilheit	23,8%	19,9%	18,0%	17,0%	12,9%	13,6%	33,3%
	Siedlungsstruktur	7,6%	15,0%	25,9%	25,6%	43,1%	42,7%	16,7%
	Bevölkerungsdichte	53,6%	52,8%	27,1%	42,4%	32,7%	30,9%	16,7%
SLA A-C	Armut	55,5%	51,3%	42,2%	43,3%	47,0%	47,6%	44,4%
	Alter	5,1%	4,8%	6,2%	7,7%	12,1%	16,1%	19,7%
	Ausländerintegration	39,4%	43,9%	51,6%	49,0%	40,8%	36,3%	35,9%
SLA F	Bevölkerung	21,3%	20,9%	21,4%	21,5%	19,8%	19,8%	36,2%
	Beschäftigungsquote	34,0%	37,2%	40,0%	34,8%	23,1%	22,4%	26,0%
	Siedlungsdichte	44,8%	41,8%	38,5%	43,7%	57,1%	57,8%	37,8%

Anmerkungen: * Vierjahresmittel. Blau: Gewicht < effektiver Wert, rot: Gewicht > effektiver Wert. Farbverlauf: Je dunkler die Farbe, desto grösser ist die Abweichung (in Prozentpunkten) vom effektiven Wert.

²⁵ Da die Gewichte der Indikatoren im GLA in der FiLaV festgeschrieben sind, ist der Mittelwert im Prinzip nur für die Indikatoren des SLA relevant.

3.4 Bewertung

Im vorangehenden Kapitel haben wir die Ergebnisse zu den Gewichten der Indikatoren innerhalb der Indikatorgruppen präsentiert. Es hat sich gezeigt, dass gewisse Ergebnisse über die betrachteten Methoden stabil sind, andere weniger. In diesem Kapitel bewerten wir die angewendeten Methoden nach verschiedenen Kriterien. Die Bewertung soll eine objektive Grundlage liefern, um die Ergebnisse im vorangehenden Kapitel noch besser einordnen zu können. Die Ergebnisse der Bewertung sind in Tabelle 5 zusammengefasst.

3.4.1 Korrekte Abbildung der Sonderlasten

Sonderlasten sind nicht beobachtbar, sondern können nur näherungsweise über Indikatoren definiert werden. Es handelt sich in diesem Sinne um ein latentes Konzept. Ob Sonderlasten korrekt abgebildet werden oder nicht, müsste anhand eines Benchmarks beurteilt werden – genau diese Vergleichsgröße existiert aber nicht. Es gilt darüber hinaus, die Rahmenbedingungen des Mandats zu beachten: Lediglich jene Sonderlasten, die über die vorgegebenen zehn Indikatoren identifiziert werden, können auch abgebildet werden.

Dies vorausgeschickt, sind alle untersuchten Methoden grundsätzlich geeignet, Sonderlasten zu schätzen. Zur Ermittlung der Gewichte wird dieser Schritt bei der quadratischen Minimierungsmethode zwar nicht benötigt. Es spricht aber nichts dagegen, nach erfolgter Variablenselektion analog zu LASSO und Best Subset Selection ein reduziertes Regressionsmodell zu schätzen und auf dieser Basis die Sonderlasten je Funktion zu ermitteln.

3.4.2 Robustheit der Ergebnisse

Für Zwecke der operativen Implementierung ist die Stabilität der ausgewählten Indikatoranteilmengen, die Stabilität der Koeffizientenhöhen sowie die Stabilität der Indikatorgewichte über die Zeit erstrebenswert. Wir definieren nachfolgend drei Unterkriterien, um diese Anforderungen abzubilden.

Selektion der Indikatoren über die Zeit

Der Lastenausgleich berücksichtigt *strukturelle* Lasten. Es ist daher plausibel festzulegen, dass die Sonderlasten einer Ausgabenfunktion in allen Jahren von denselben Indikatoren bestimmt werden sollen. Aufgrund von Schwankungen in den Nettoausgaben pro Kopf, die nicht durch die gegebenen Indikatoren erklärt werden können, wird dies nicht perfekt der Fall sein; es ist aber möglich, Abweichungen der selektierten Indikatorenteilmengen $P_{m,t}^S \subseteq P$ über die Zeit zu bestrafen. Als Mass bietet sich dafür die Levenshtein-Distanz an. Die Idee ist einfach: Die Zeichenkette «BCD» kann durch Wegnahme des Buchstaben «A» und Hinzufügen des Buchstaben «D» aus der Zeichenkette «ABC» erzeugt werden. Es werden also zwei Operationen benötigt, die Wegnahme von «A» und das Hinzufügen von «D». In diesem Beispiel beträgt die Levenshtein-Distanz 2. Vorliegend verfahren wir analog: Jede Indikatorteilmenge kann als Zeichenkette repräsentiert werden. Wir prüfen mittels der Levenshtein-Distanz, wie stark sich die selektierten Indikatoranteilmengen von Jahr zu Jahr unterscheiden. Daraus leiten wir mittlere Distanzmasse pro Ausgabenfunktion ab. Die Summe dieser Distanzmasse über alle Ausgabenfunktionen pro Methode soll möglichst klein sein. Am besten schneidet anhand dieses Kriteriums die Best Subset Selection ab, gefolgt von LASSO und der quadratischen Minimierung.

Variation der geschätzten Koeffizienten über die Zeit

Als zweites Desideratum legen wir fest, dass die geschätzten Koeffizienten über die Zeit möglichst wenig Variation aufweisen sollen. Zu diesem Zweck normieren (auf Werte zwischen 0 und 1) wir die Koeffizienten zunächst, um sie über die Methoden hinweg vergleichbar zu machen. Dieser Schritt erlaubt uns die einheitliche Berechnung der Standardabweichung der Koeffizienten über die Zeit, getrennt für jede Ausgabenfunktion und jede Methode. Im nächsten Aggregationsschritt bilden wir den Mittelwert der Standardabweichungen über alle Ausgabenfunktionen hinweg. Zuletzt mitteln wir auf Ebene der Methoden, um ein Mass für die Variation aller Koeffizienten über die Zeit zu erhalten. Auch bezüglich dieses Kriteriums liegt die Best Subset Selection vorne, gefolgt von LASSO und der quadratischen Minimierung.

Variation der relativen Wichtigkeit über die Zeit

Drittens ist es erstrebenswert, den Einfluss einzelner Indikatoren auf das Gesamtergebnis konstant zu halten. Nehmen wir als extremes Beispiel den folgenden Fall: Für eine Ausgabenfunktion werden die Indikatoren «Siedlungsdichte» und «Altersstruktur» ausgewählt. Die selektierte Teilmenge bleibt über die Jahre konstant, jedoch variieren die Koeffizienten dieser Indikatoren: Im Jahr 2015 betragen sie 5 resp. 20, im Jahr 2016 25 resp. 3. Die relative Wichtigkeit der Koeffizienten für die Schätzung der abhängigen Variable (der Nettoausgaben pro Kopf) kehrt sich demnach um. Das nachfolgend beschriebene Kriterium begegnet diesem unerwünschten Ergebnis durch die Minimierung der Standardabweichung der relativen Wichtigkeit über die Zeit. Es erfolgen mehrere Berechnungsschritte: Zunächst berechnen wir den Anteil eines Koeffizienten an der Summe der Koeffizienten pro Methode und Ausgabenfunktion. Im nächsten Schritt berechnen wir auf dieser Ebene für jeden Indikator die Standardabweichung über die Zeit. Durch die Bildung von Mittelwerten aggregieren wir die Standardabweichungen zunächst über Ausgabenfunktionen hinweg und zuletzt auf Ebene der Methoden. Basierend auf diesem Kriterium weist die quadratische Minimierung den besten Wert auf, gefolgt von LASSO und der Best Subset Selection. Die Unterschiede sind allerdings gering.

3.4.3 Inhaltliche Plausibilität

Neben den objektiven Kriterien, die über die Robustheit der verschiedenen Methoden Auskunft geben, betrachten wir die ausgewählten Indikatoren unter dem Gesichtspunkt der inhaltlichen Plausibilität. Es erscheint zum Beispiel plausibel, dass sich die Indikatoren des geographisch-topographischen Lastenausgleichs primär auf die Nettoausgaben in Funktionen wie «Landwirtschaft», «Forstwirtschaft» oder «Jagd und Fischerei» auswirken und nur nachgelagert auf Nettoausgaben im Bereich des Strafvollzugs oder der Rechtssprechung. Im Prinzip kann für jede Ausgabenfunktion ein solches Wirkungsmodell hergeleitet werden, das die Wirkungskette zwischen Indikator und Höhe der Nettoausgaben nachzeichnet. Im Rahmen dieses Mandats muss eine detaillierte Analyse ausbleiben; wir notieren aber, dass über alle Methoden hinweg die Auswahl der Indikatoren sehr gut mit den «erwarteten» Bestimmungsfaktoren korreliert und das Kriterium der inhaltlichen Plausibilität folglich methodenübergreifend erfüllt ist.

3.4.4 Nachvollziehbarkeit

Unter diesem Aspekt beleuchten wir, wie gut die grundlegende Funktionsweise der vorgeschlagenen Methoden vermittelt werden kann. Allen Methoden ist gemein, dass sie aus einer Menge von Indikatoren eine Teilmenge auswählen. Bei der Best Subset Selection und LASSO handelt es sich

um Methoden, die explizit zur Variablenselektion genutzt werden; im Fall der quadratischen Minimierung findet diese Selektion als Nebenprodukt des Optimierungsproblems statt und ist daher etwas weniger gut nachvollziehbar. Ein weiterer Unterschied besteht in der Berechnung der Indikatorengewichte: Während bei der quadratischen Minimierungsmethode die Nebenbedingungen des Optimierungsproblems dafür sorgen, dass die geschätzten Koeffizienten direkt als Gewichte interpretiert werden können, ist bei den anderen betrachteten Methoden ein weiterer Schritt nötig. Die Schätzung der Sonderlasten in einem separaten Rechenschritt führt unserer Einschätzung nach den Prozess anschaulicher vor Augen. Insgesamt bewerten wir daher die Möglichkeit, die Methodik zu vermitteln, bei der Best Subset Selection und LASSO und als sehr gut, bei der quadratischen Minimierung als etwas weniger gut.

3.4.5 Erhebungs- und Berechnungsaufwand

Zuletzt haben wir geprüft, ob sich der Aufwand für die Datenerhebung und Berechnung der Sonderlasten zwischen den Methoden unterscheidet. Die benötigten Daten sind modellübergreifend gleich. Durch den Wegfall eines Berechnungsschritts ist der Rechenaufwand bei der quadratischen Minimierungsmethode theoretisch geringer. In der Praxis spielt dies jedoch keine Rolle.

3.4.6 Zusammenfassung

Die Ergebnisse der Bewertung sind in Tabelle 5 zusammengefasst. Über alle Kriterien betrachtet schneidet die Best Subset Selection am besten ab, gefolgt von LASSO und der quadratischen Minimierung. Im Vergleich zu LASSO schneidet die Best Subset Selection bei zwei von drei Unterkriterien zur Abbildung der Robustheit der Ergebnisse besser ab (Selektion der Indikatoren über die Zeit, Variation der geschätzten Koeffizienten über die Zeit). Einzig in Bezug auf die Variation der relativen Wichtigkeit über die Zeit schneidet Best Subset Selection schlechter ab als LASSO.

Tabelle 5: Bewertung der Methoden

Kriterien	Lasso	Best Subset Selection	Quadratische Minimierung
Korrekte Abbildung der Sonderlasten (gegeben Rahmenbedingungen)	● ● ●	● ● ●	● ● ● *
Robustheit der Ergebnisse	● ●	● ● ●	●
<i>Selektion der Indikatoren über die Zeit (Rang in Klammern)</i>	2	1	3
<i>Variation der geschätzten Koeffizienten über die Zeit (Rang in Klammern)</i>	2	1	3
<i>Variation der relativen Wichtigkeit über die Zeit (Rang in Klammern)</i>	2	3	1
Inhaltliche Plausibilität	● ● ●	● ● ●	● ● ●
Nachvollziehbarkeit	● ● ●	● ● ●	● ●
Aufwand	● ● ●	● ● ●	● ● ●

Anmerkungen: * Keine direkte Berechnung der Sonderlasten notwendig.

3.5 Simulation

3.5.1 Konzeptionelle Überlegungen

In diesem Kapitel werden die berechneten Gewichte verwendet, um die Ausgleichszahlungen im Lastenausgleich des NFA zu simulieren. Wir verwenden die Gewichte gemäss der Best Subset Selection. Diese Methode hat im Vergleich zu den anderen beiden Methoden insb. in Bezug auf die Robustheit der Ergebnisse am besten abgeschnitten (vgl. Kapitel 3.4). Im Anhang C.2 sind die detaillierten Ergebnisse der Simulation für alle drei Methoden bzw. der damit berechneten Gewichte tabellarisch aufgeführt.

Wir treffen dabei die Annahme, dass die Verteilung der Dotation auf den geografisch-topografischen Lastenausgleich und den soziodemografischen Lastenausgleich sowie die Verteilung der Dotation des SLA auf den SLA A-C und den SLA F derjenigen des Lastenausgleichs 2021 entspricht (vgl. Tabelle 6).²⁶

²⁶ Gemäss den Schätzungen der Anteile der Sonderlasten der Indikatorengruppen an den gesamten Sonderlasten (vgl. Abbildung 8) würde sich eine andere Verteilung der Gesamtdotation auf den GLA (5,7%) und

Tabelle 6: Dotationen Lastenausgleich 2021 (in CHF)

Geografisch-topografischer Lastenausgleich	Soziodemografischer Lastenausgleich		Lastenausgleich Total
360'331'399	440'331'399		800'662'798
	SLA A-C (2/3)	SLA F (1/3)	
	293'554'266	146'777'133	

Quelle: EFV

Für die Simulation der Ausgleichszahlungen haben wir verschiedene Ausgleichsvarianten untersucht. Diese erläutern wir in der Tabelle 7.

Tabelle 7: Ausgleichsvarianten

Ausgleichsgefäss	Variante	Beschreibung
GLA	1	Indikatorspezifische Lastenindexe («Status quo»): <ul style="list-style-type: none"> - Verteilung der Dotation des GLA auf die Indikatoren gemäss deren Gewicht - Berechnung eines Lastenindex pro Indikator - Je Indikator Verteilung der Dotation gemäss Lastenindex auf die Kantone
SLA A-C	1	Lastenindex als gewichtete Kombination aus den Indikatoren («Status quo»): <ul style="list-style-type: none"> - Berechnung eines Lastenindex als gewichtete Kombination aus den (standardisierten) Indikatoren - Verteilung der Dotation gemäss Lastenindex auf die Kantone
	2	Indikatorspezifische Lastenindexe <ul style="list-style-type: none"> - Verteilung der Dotation des SLA A-C auf die Indikatoren gemäss deren Gewichte - Berechnung eines Lastenindex pro Indikator - Je Indikator Verteilung der Dotation gemäss Lastenindex auf die Kantone
SLA F	1	Lastenindex als gewichtete Kombination aus den Indikatoren («Status quo») <ul style="list-style-type: none"> - Berechnung eines Lastenindex als gewichtete Kombination aus den (standardisierten) Indikatoren auf Gemeindeebene - Aggregation Lastenindex auf Kantonsebene - Verteilung der Dotation gemäss Lastenindex auf die Kantone

den SLA (94,3%) sowie der Dotation des SLA auf den SLA A-C (74,8%) und den SLA F (25,2%) ergeben. Gemäss Rahmenbedingungen dieser Studie ist die Gesamtdotation des GLA und des SLA als gegeben zu betrachten. Es sei angemerkt, dass die Verteilung der Gesamtdotation gemäss den oben angegebenen Anteilen eine grosse Veränderung bei den Ausgleichszahlungen verursachen würde.

Ausgleichsgefäss	Variante	Beschreibung
	2	Indikatorspezifische Lastenindexe <ul style="list-style-type: none"> - Aggregation der Indikatoren auf Kantonsebene* - Verteilung der Dotation des SLA F auf die Indikatoren gemäss deren Gewicht - Berechnung eines Lastenindex pro Indikator - Je Indikator Verteilung der Dotation gemäss Lastenindex auf die Kantone

Anmerkungen: * Die Indikatoren liegen beim SLA F auf Ebene der Gemeinden vor.

Im aktuellen Lastenausgleich werden grundsätzlich zwei mögliche Berechnungsvarianten angewendet:

- *Indikatorspezifische Lastenindexe*: Die Dotation wird auf die Indikatoren des Ausgleichsgefässes aufgeteilt. Hierfür werden den Indikatoren Gewichte zugeschrieben. Pro Indikator wird ein Lastenindex berechnet. Kantone mit Indikatorwerten über dem (gewichteten) Mittelwert weisen einen Lastenindex > 100 auf, Kantone mit Indikatorwerten unter dem (gewichteten) Mittelwert einen Lastenindex < 100 . Für Kantone mit einem Lastenindex > 100 werden die massgebenden Sonderlasten berechnet. Diese ergeben sich aus der gewichteten Differenz zwischen dem Lastenindex und 100. Auf Grundlage der berechneten massgebenden Sonderlasten wird die Dotation auf die Kantone verteilt. Diese Berechnungsvariante kommt aktuell beim GLA zur Anwendung.
- *Lastenindex als gewichtete Kombination aus den Indikatoren*: Die (standardisierten) Indikatoren werden zu einem Lastenindex zusammengefasst, wobei die Indikatoren gewichtet in diesen Lastenindex einfließen. Auf Basis des Lastenindex werden wiederum die massgebenden Sonderlasten berechnet. Da die Indikatoren standardisiert sind, ergeben sich diese massgebenden Sonderlasten für Kantone mit einem Indexwert > 0 durch die Multiplikation (Gewichtung) mit dem entsprechenden Indexwert. Auf Grundlage der berechneten massgebenden Sonderlasten wird die Dotation auf die Kantone verteilt. Diese Berechnungsvariante kommt aktuell beim SLA A-C und beim SLA F zur Anwendung.

Die beiden Varianten unterscheiden sich hinsichtlich eines wichtigen Aspekts: Bei der Variante mit dem Lastenindex als gewichtete Kombination aus den Indikatoren kann es zur «Verrechnung» von Sonderlasten zwischen den berücksichtigten Indikatoren kommen. Dies ist dann zu erwarten, wenn die Indikatoren eine negative Korrelation aufweisen: Im Falle von zwei Indikatoren würde ein Kanton beim ersten Indikator einen überdurchschnittlichen Wert aufweisen, beim zweiten Indikator hingegen einen unterdurchschnittlichen Wert. Je nach Gewichtung der Indikatoren kompensiert der zweite Indikator die Sonderlasten des ersten Indikators stärker oder schwächer. Diese Berechnungsvariante bevorteilt Kantone, die über alle Indikatoren betrachtet hohe Sonderlasten aufweisen. Die Dotation wird entsprechend auf diese besonders belasteten Kantone konzentriert.

Bei der Variante mit den indikatorspezifischen Lastenindexen findet keine Verrechnung von Sonderlasten eines Indikators mit (allfälligen) Minderlasten eines anderen Indikators statt. Im Effekt bedeutet dies allerdings, dass die Dotation auf mehr Kantone verteilt wird: Neben dem stark belasteten Kanton, der bei allen Indikatoren überdurchschnittliche Werte aufweist, erhalten auch

weniger stark belastete Kantone, die bspw. nur bei einem Indikator einen überdurchschnittlichen Wert aufweisen, bei allen anderen hingegen unterdurchschnittliche Werte haben, Ausgleichszahlungen. Falls die Indikatoren untereinander positiv korreliert sind, ist keine Kompensation zu erwarten und die Variante mit den indikatorspezifischen Lastenindexen sollte vom Ergebnis her ähnlich ausfallen wie die Variante mit dem Lastenindex als Kombination aus den gewichteten Indikatoren.

Abbildung 5 im Kapitel 2.2.2 zeigt die Korrelationen zwischen den Indikatoren auf. Die Indikatoren des GLA sind untereinander positiv korreliert. Eine Kompensation zwischen den Indikatoren ist somit nicht zu erwarten. Die Indikatoren des SLA A-C sind untereinander teils positiv (Armutquote und Altersstruktur sowie Armutquote und Ausländerintegration), teils negativ (Altersstruktur und Ausländerintegration) korreliert. Hier besteht also Potenzial für eine Kompensation. Die Indikatoren des SLA F wiederum sind positiv (Bevölkerung und Beschäftigungsquote sowie Beschäftigungsquote und Siedlungsdichte) oder nicht korreliert (Bevölkerung und Siedlungsdichte). Auch hier besteht Potenzial für eine Kompensation, wenn auch nicht so stark ausgeprägt wie beim SLA A-C.

3.5.2 Variantenvergleich bei alter Gewichtung

Um die Unterschiede der beiden Berechnungsvarianten im Ergebnis darzustellen, haben wir beim SLA A-C und beim SLA F zusätzlich zur Variante, die den Status quo abbildet (Variante 1), jeweils auch eine Variante mit indikatorspezifischen Lastenindexen berechnet (Variante 2). Bei der folgenden Simulation geht es darum, Unterschiede im Ergebnis aufzuzeigen.

Bevor wir die Ausgleichsbeiträge mit den neuen Gewichten der Indikatoren simulieren, betrachten wir beim SLA A-C und beim SLA F die Unterschiede zwischen der Variante 1 («Status quo») und der Variante 2 bei der Anwendung der Gewichtung der Indikatoren, wie sie im Lastenausgleich 2021 hinterlegt ist.²⁷

Abbildung 17 (SLA A-C) und Abbildung 19 (SLA F) zeigen die Ergebnisse des Variantenvergleichs bei alter Gewichtung absolut, Abbildung 18 (SLA A-C) und Abbildung 20 (SLA F) pro Kopf betrachtet. Wie aufgrund der theoretischen Überlegungen (s.o.) vermutet, verteilt sich die Dotation auf weitere Kantone. Beim SLA A-C würden die Kanton Basel-Landschaft, Freiburg, Graubünden, Glarus, Uri Appenzell A.Rh. und Appenzell I.Rh. (blaue Balken) neu einen Ausgleichsbeitrag erhalten. Der Kanton Basel-Landschaft bspw. weist eine relativ hohe Quote über-80-Jähriger auf.

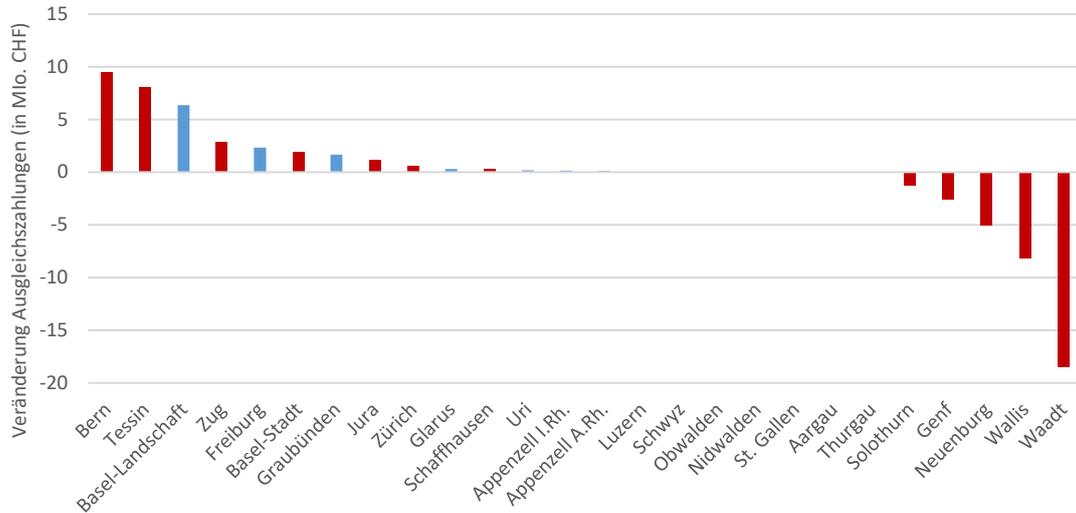
²⁷ Im Lastenausgleich 2021 wurden die Indikatoren «Armutquote», «Altersstruktur» und «Ausländerintegration» mit 0,56, 0,18 und 0,48 gewichtet. Die Gewichte wurden mittels Hauptkomponentenanalyse bestimmt. Für die Simulation wurden die Gewichte so normiert, dass sich die Gewichte auf eins summieren. Die Indikatoren «Bevölkerung», «Beschäftigungsquote» und «Siedlungsdichte» wurden im Lastenausgleich 2021 mit 0,47, 0,34 und 0,49 gewichtet. Diese Gewichte wurden für die Simulation ebenfalls normiert, dass die Summe der Gewichte eins ergibt. Im Unterschied zum Lastenausgleich 2021 wurde beim SLA A-C und beim SLA F auf die Berechnung der Masszahl der Lasten verzichtet. Die massgebenden Sonderlasten wurden direkt aus dem Lastenindex berechnet. Für die Berechnung der Masszahl der Lasten wurde im Lastenausgleich 2021 vom Lastenindex (SLA A-C) bzw. vom Kernstadtindikator (SLA F) der minimale Lastenindexwert bzw. der minimale Kernstadtindikatorwert abgezogen. Der Verzicht auf die Berechnung der Masszahl der Lasten hat keine Auswirkungen auf die Ausgleichszahlungen. Im Gegensatz zum Lastenausgleich 2021 werden die Lastenindexe nicht gerundet. Der Verzicht auf die Berechnung der Masszahl der Lasten und auf die Rundung des Lastenindex verursacht leichte Differenzen im Vergleich zu den Ausgleichszahlungen des Lastenausgleichs 2021 von max. rund 20'000 CHF.

Demgegenüber weist der Kanton bei der Armutsquote und der Ausländerintegration unterdurchschnittliche Werte auf. Während die Sonderlasten aufgrund der überdurchschnittlichen Altersstruktur durch die Minderlasten durch die unterdurchschnittliche Armutsquote und die unterdurchschnittliche Ausländerintegration bei Variante 1 («Status quo») kompensiert werden, schlagen sie bei einer nach Indikatoren differenzierten Betrachtung (Variante 2) zu Buche.²⁸ Beim SLA F würden neben den vier bisherigen Kantonen bei Anwendung der Variante 2 elf weitere eine Ausgleichszahlung erhalten (Bern, Aargau, Zug, St. Gallen, Tessin, Luzern, Basel-Landschaft, Graubünden, Wallis, Solothurn, Thurgau).

Für die folgenden Simulationsrechnungen für den SLA A-C und den SLA F wenden wir jeweils die Variante 1 bzw. die Berechnung der Ausgleichszahlungen gemäss Status quo an. Diese Variante hat zwei Vorteile: Erstens wird der Lastenausgleich auf besonders belastete Kantone fokussiert. Zweitens fallen die Unterschiede zu den effektiven Ausgleichszahlungen des Lastenausgleichs 2021 weniger stark aus.

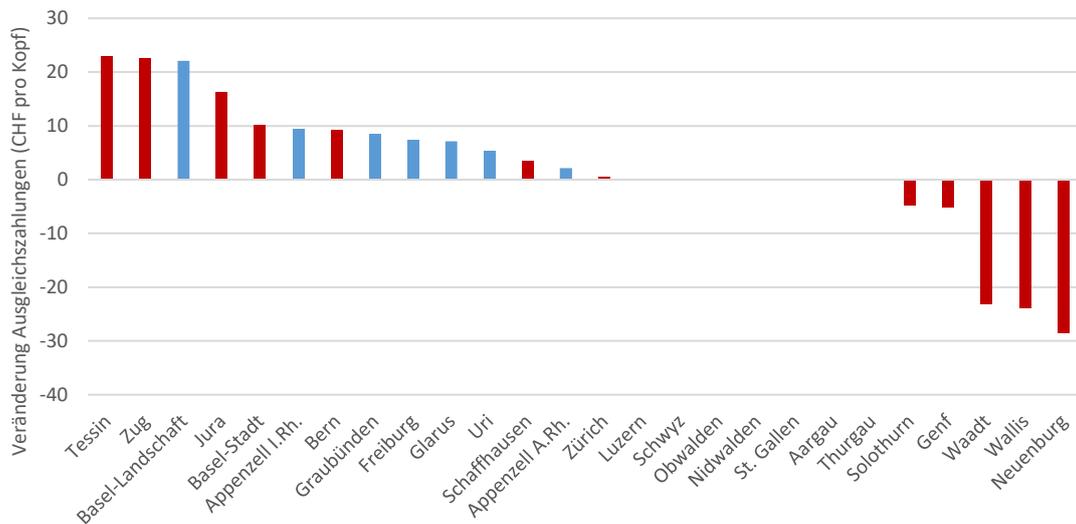
²⁸ Für den SLA F wurden noch zwei weitere Varianten geprüft: 2a) Berechnung des Lastenindex und der massgebenden Lasten pro Indikator auf Ebene der Gemeinden, erst dann Aggregation der massgebenden Lasten auf Kantonsebene. 2b) Berechnung des Lastenindex, der massgebenden Lasten und der Ausgleichszahlung pro Indikator auf Ebene der Gemeinden. Bei beiden Varianten verteilt sich die Dotation auf noch mehr Kantone. Die Unterschiede zum Status quo fallen entsprechend noch grösser aus. Aus diesem Grund werden diese Varianten nicht weiter betrachtet.

Abbildung 17: Veränderung Ausgleichszahlungen (absolut) SLA A-C, Variantenvergleich



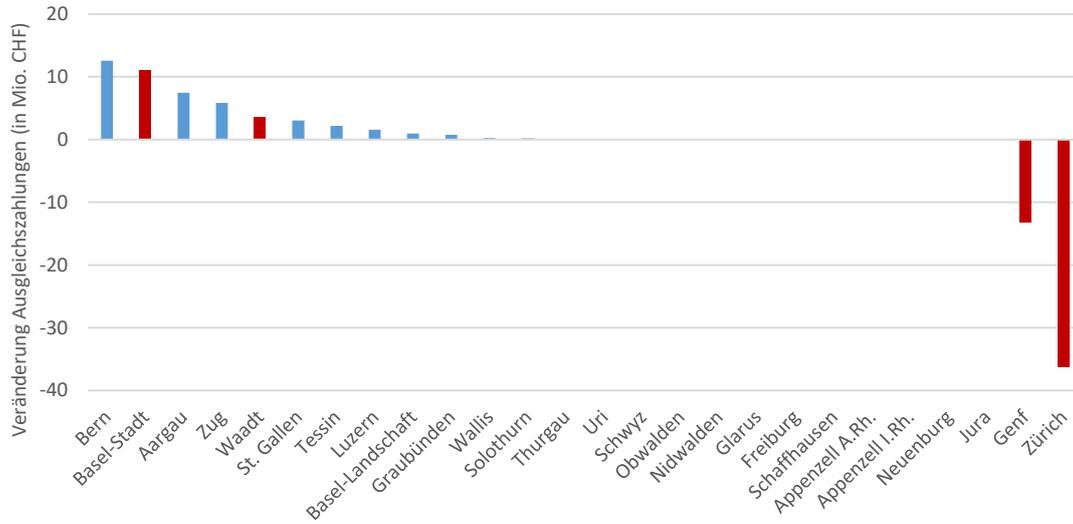
Quelle: EFV, eigene Berechnungen. Anmerkungen: Rote Balken kennzeichnen Kantone, die im Lastenausgleich 2021 Ausgleichszahlungen aus dem SLA A-C erhalten haben.

Abbildung 18: Veränderung Ausgleichszahlungen (pro Kopf) SLA A-C, Variantenvergleich



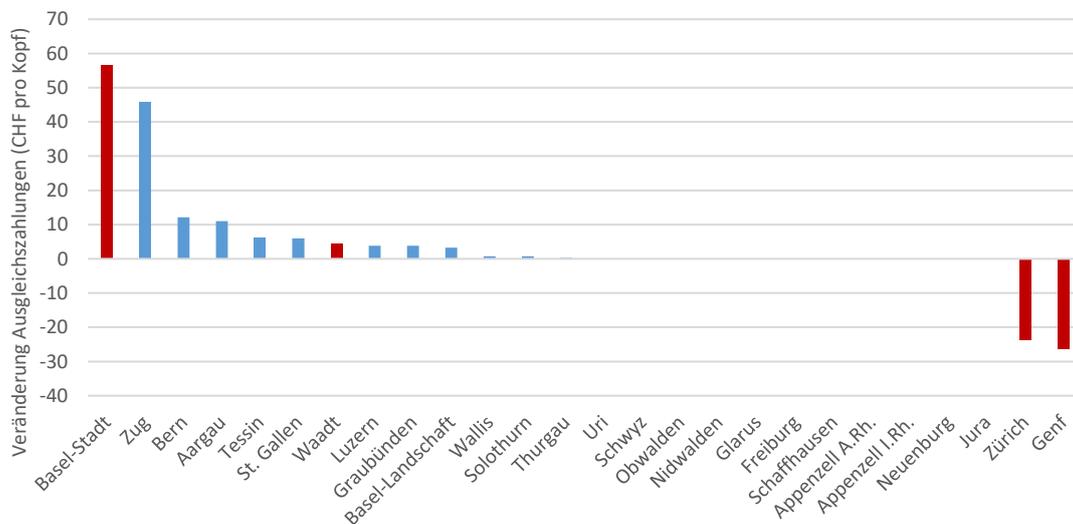
Quelle: EFV, eigene Berechnungen. Anmerkungen: Rote Balken kennzeichnen Kantone, die im Lastenausgleich 2021 Ausgleichszahlungen aus dem SLA A-C erhalten haben.

Abbildung 19: Veränderung Ausgleichszahlungen (absolut) SLA F, Variantenvergleich



Quelle: EFV, eigene Berechnungen. Anmerkungen: Rote Balken kennzeichnen Kantone, die im Lastenausgleich 2021 Ausgleichszahlungen aus dem SLA F erhalten haben.

Abbildung 20: Veränderung Ausgleichszahlungen (pro Kopf) SLA F, Variantenvergleich



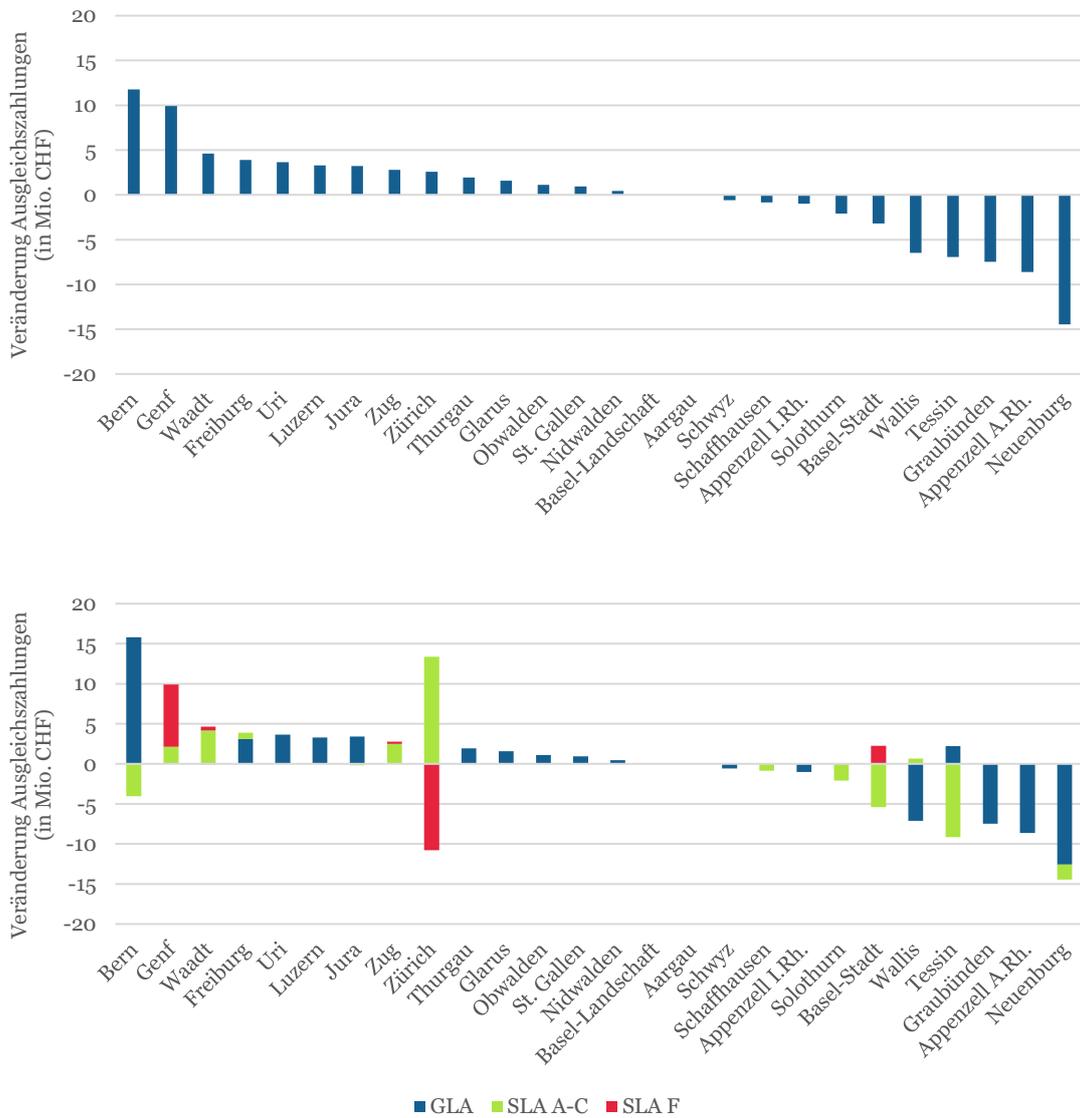
Quelle: EFV, eigene Berechnungen. Anmerkungen: Rote Balken kennzeichnen Kantone, die im Lastenausgleich 2021 Ausgleichszahlungen aus dem SLA F erhalten haben.

3.5.3 Veränderung Ausgleichszahlungen bei neuer Gewichtung

Nachfolgend berechnen wir die Veränderung der Ausgleichszahlungen bei neuer Gewichtung der Indikatoren. Als Gewichte verwenden wir die über drei Jahre gemittelten Gewichte. Diese sind in Tabelle 4 (Spalte «gemittelt», Kapitel 3.3), aufgeführt. Die Ausgleichszahlungen mit den neuen Gewichten vergleichen wir mit den Ausgleichszahlungen des Lastenausgleichs 2021. Bei der Diskussion konzentrieren wir uns auf die Ergebnisse basierend auf die Methode Best Subset Selection. Dieser Ansatz hat gemäss unserer Bewertung (vgl. Kapitel 3.4) am besten abgeschnitten. Der Vollständigkeit halber haben wir im Anhang C.2 die Veränderungen in den Ausgleichszahlungen pro Ausgleichsgefäss des Lastenausgleichs und Kanton für alle geprüften Methoden tabellarisch zusammengefasst.

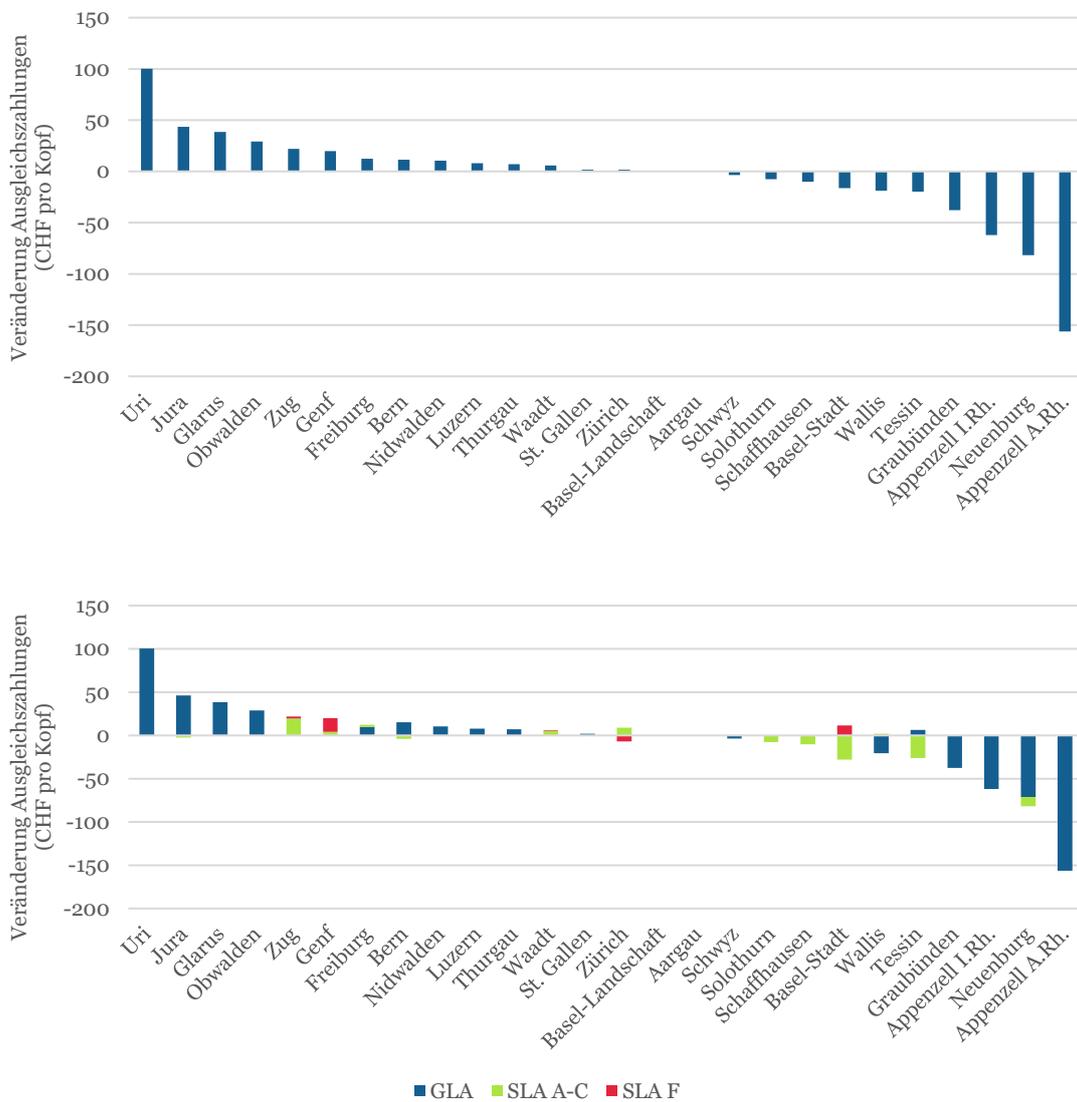
Abbildung 21 stellt die Summe der Veränderungen der Ausgleichszahlungen mit neuer Gewichtung über alle Ausgleichsgefässe des Lastenausgleichs (oben) und die Zusammensetzung der Veränderungen nach Ausgleichsgefäss (unten) in absoluten Werten dar. Abbildung 22 zeigt die Veränderungen pro Kopf auf. Die detaillierten Zahlen im Vergleich zu den Ausgleichszahlungen im Lastenausgleich 2021 finden sich in Tabelle 9 (Total), Tabelle 10 (GLA), Tabelle 15 (SLA A-C) und Tabelle 16 (SLA F), Anhang C.2. Absolut betrachtet bilden der Kanton Bern mit + 11,8 Mio. CHF und der Kanton Neuenburg mit -14,4 Mio. CHF die Extremwerte. Pro Kopf betrachtet sind es die Kantone Uri (+100 CHF pro Kopf) und Appenzell A.Rh. (-156 CHF pro Kopf). Nachfolgend diskutieren wir die Veränderungen der Ausgleichszahlungen bei neuer Gewichtung im Vergleich zu den Ausgleichszahlungen des Lastenausgleichs 2021 für die einzelnen Ausgleichsgefässe. Diese Diskussion ermöglicht es, Unterschiede auf aggregierter Ebene, wie sie in Abbildung 21 (oben) und Abbildung 22 (oben) dargestellt werden, zu erklären. Weiter können auch allfällige gegenläufige Effekte identifiziert werden, die sich in der Summe (teilweise) kompensieren. Gemäss Abbildung 21 (unten) und Abbildung 22 (unten) fällt diesbezüglich der Kanton Zürich auf.

Abbildung 21: Veränderung der Ausgleichszahlungen mit neuer Gewichtung, Total und differenziert nach Ausgleichsgefässen



Quelle: EFV, eigene Berechnungen.

Abbildung 22: Veränderung der Ausgleichszahlungen pro Kopf mit neuer Gewichtung, Total und differenziert nach Ausgleichsgefässen

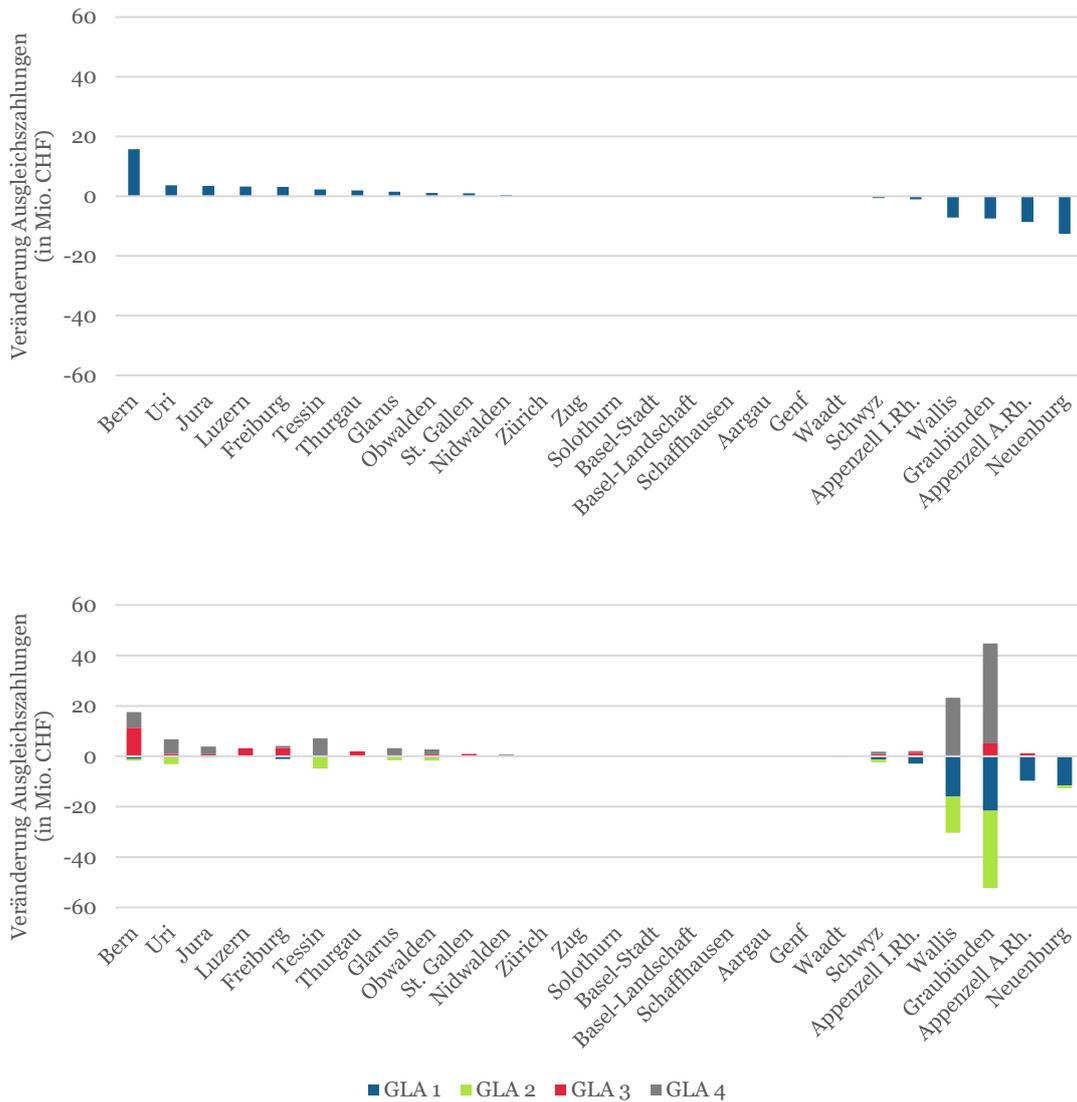


Quelle: EFV, eigene Berechnungen.

Wie Abbildung 21 (unten) bereits aufzeigt, sind die absoluten Veränderungen der Ausgleichsbeträge in den Kantonen Bern und Neuenburg hauptsächlich getrieben durch Veränderungen im GLA. Abbildung 23 (oben, absolut) und Abbildung 24 (oben, pro Kopf) stellt die Veränderungen der Ausgleichszahlungen im GLA mit neuer Gewichtung dar. Abbildung 23 (unten, absolut) und Abbildung 24 (unten, pro Kopf) lässt eine nach Teilausgleichsgefässen (Indikatoren) des GLA differenzierte Betrachtung zu. Die detaillierten Zahlen finden sich in Tabelle 10 bis Tabelle 14 im Anhang C.2. Die für den Kantone Neuenburg in der Summe festgestellten tieferen absoluten Ausgleichszahlungen haben ihren Ursprung in Veränderungen bei den Ausgleichszahlungen für Sonderlasten aufgrund der Siedlungshöhe (GLA 1). Die Best Subest Selection gewichtet diesen Indikator weniger stark als dies heute der Fall ist. Im Gegensatz dazu gewichtet Best Subset Selection die Bevölkerungsdichte (GLA 4) deutlich stärker als dies heute der Fall ist. Da der Kanton Neu-

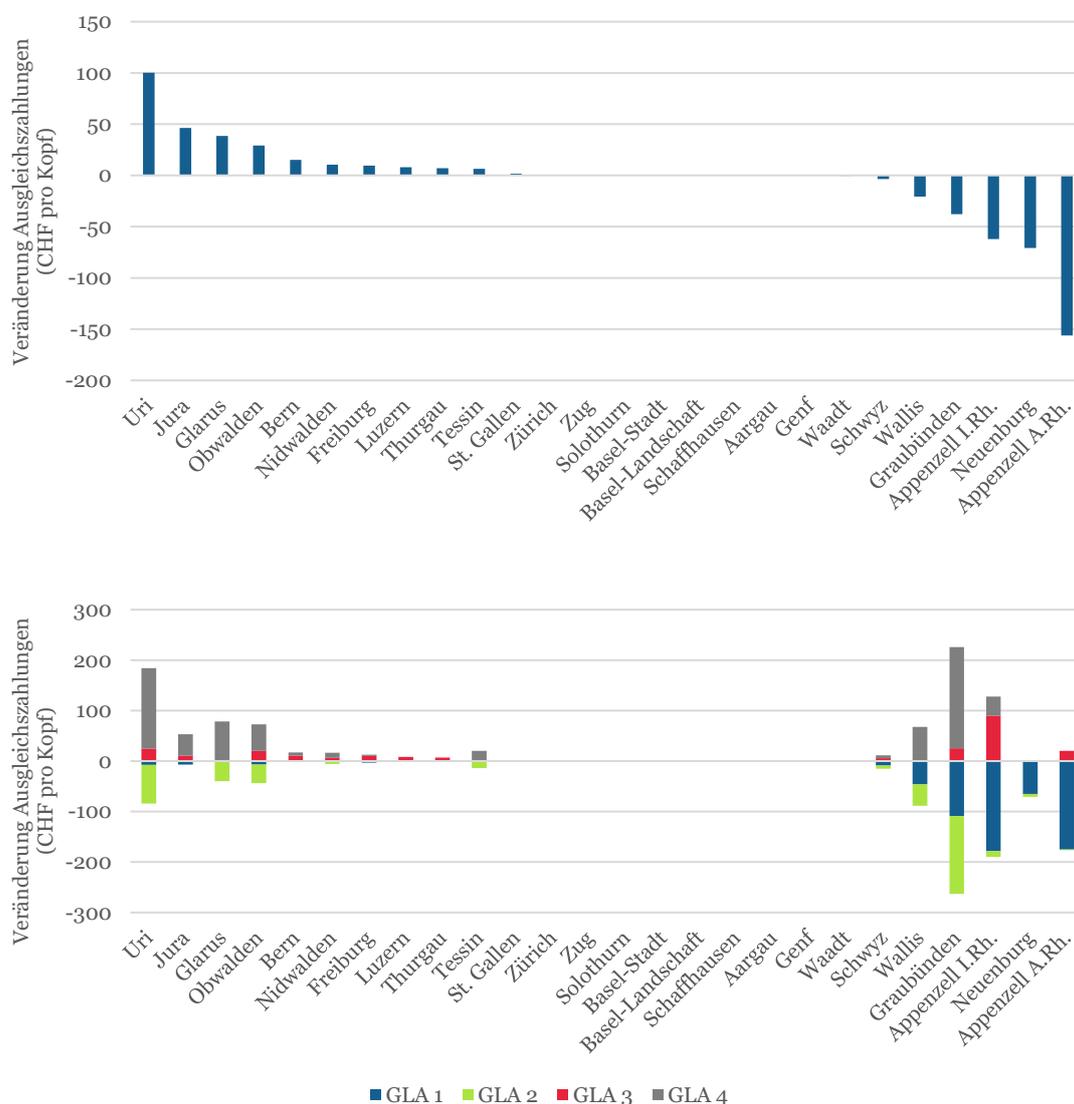
enburg eine überdurchschnittliche Bevölkerungsdichte aufweist, kann er nicht von dieser stärkeren Gewichtung profitieren. Dies im Gegensatz zu den Kantonen Graubünden und Wallis, welche die tieferen Ausgleichszahlungen im GLA 1 und GLA 2 durch höhere Ausgleichszahlungen im GLA 4 aufgrund unterdurchschnittlicher Bevölkerungsdichten teilweise kompensieren können. Der Kanton Bern profitiert von der stärkeren Gewichtung der Siedlungsstruktur (GLA 3) und der Bevölkerungsdichte (GLA 4).

Abbildung 23: Veränderung der Ausgleichszahlungen mit neuer Gewichtung, GLA



Quelle: EFV, eigene Berechnungen.

Abbildung 24: Veränderung der Ausgleichszahlungen pro Kopf mit neuer Gewichtung, GLA



Quelle: EFV, eigene Berechnungen.

Wie Abbildung 21 (unten, absolut) und Abbildung 22 (unten, pro Kopf) aufzeigt, wird die Veränderung der Ausgleichszahlung für den Kanton Zürich durch Veränderungen der Auszahlungen aus dem SLA A-C (+) und den SLA F (-) getrieben. Im SLA A-C profitiert der Kanton Zürich dabei von der stärkeren Gewichtung des Indikators «Ausländerintegration» und der tieferen Gewichtung des Indikators «Altersstruktur»: Auf der einen Seite weist der Kanton Zürich für das Ausgleichsjahr 2021 eine der höchsten Ausländerquoten, auf der anderen Seite einen relativ tiefen Anteil der über 80-Jährigen Personen an der ständigen Wohnbevölkerung auf. Mit dem Indikator «Ausländerintegration» wird nun derjenige Indikator stärker gewichtet, bei welchem der Kanton Zürich einen überdurchschnittlichen Wert aufweist. Demgegenüber wird mit dem Indikator «Altersstruktur» derjenige Indikator weniger stark gewichtet, bei welchem der Kanton Zürich einen

unterdurchschnittlichen Wert aufweist. Im SLA F verliert der Kanton Zürich an Ausgleichszahlungen, da der Indikator «Bevölkerung» im Vergleich zum Lastenausgleich 2021 weniger stark gewichtet wird.

4. Schlussfolgerungen und Empfehlungen

Ausgangslage und Rahmenbedingungen

Der Lastenausgleich des nationalen Finanzausgleichs dient dazu, strukturell bedingte, von den Kantonen weitgehend unbeeinflussbare Sonderlasten abzugelten. Es wird zwischen geografisch-topografischen und soziodemografischen Sonderlasten unterschieden. Die Ausgleichszahlungen werden aufgrund von insgesamt zehn Indikatoren berechnet. Vier Indikatoren für den geografisch-topografischen Lastenausgleich und sechs Indikatoren für den soziodemografischen Lastenausgleich. Um die Ausgleichszahlungen zu bestimmen, müssen die Indikatoren gewichtet werden. Die Gewichtungsfaktoren für den GLA sind in der FiLaV festgeschrieben und seit dem Jahr 2008 (Einführung NFA) unverändert geblieben. Die Gewichte für die Indikatoren des SLA werden jährlich auf Grundlage einer Hauptkomponentenanalyse neu berechnet. Diese weist allerdings verschiedene Schwächen auf und soll durch eine neue Methode ersetzt werden. Im Rahmen dieses Mandats haben wir einen Vorschlag für eine neue Methode zur Gewichtung der Indikatoren erarbeitet. Folgende *Rahmenbedingungen* waren dabei zu berücksichtigen:

- Die zehn Indikatoren wie auch die Gesamtdotation des GLA und des SLA sind als gegeben zu betrachten.
- Die Methode zur Schätzung der Gewichte der Indikatoren soll sich an den effektiven Sonderlasten orientieren.
- Die Gewichtung der Indikatoren im SLA sollen neu ebenfalls in der FiLaV festgeschrieben werden.
- Die Methode soll eine regelmässige Überprüfung, und, falls angezeigt, eine Anpassung der Gewichte ermöglichen.

Vorgehen

Wir haben drei Methoden zur Schätzung der Indikatorgewichte geprüft. Zwei dieser Methoden können als Selektionsmethoden bezeichnet werden. Dabei nehmen wir Ausgehend von den vier Indikatoren des geografisch-topografischen Lastenausgleichs und den sechs Indikatoren des soziodemografischen Lastenausgleichs in einem ersten Schritt eine Selektion der Indikatoren vor. Die Selektion dient in erster Linie dazu, die Varianz der geschätzten Koeffizienten möglichst gering zu halten.²⁹ In zweiter Linie geht es darum, die relevantesten Indikatoren für jede Ausgabenfunktion zu identifizieren und auf diese Weise die Nachvollziehbarkeit der Modelle zu erhöhen. Für den Zweck der Variablenselektion haben wir folgende zwei Methoden angewendet:

- LASSO/Elastic Net: Mittels eines Bestrafungsterms werden einzelne Koeffizienten auf Null geschrumpft und fallen so aus dem Modell heraus.

²⁹ Sofern die Zahl der Beobachtungen n deutlich grösser ist als die Zahl der erklärenden Variablen p (hier: Indikatoren), können traditionelle Schätzmethoden ohne vorherige Variablenselektion zur Anwendung gelangen. Im vorliegenden Fall ist die Zahl der Beobachtungen mit $n = 26$ zwar grösser als die Zahl der Indikatoren ($p = 10$), aber nur unwesentlich. Eine Selektion ist daher indiziert, um die Präzision der geschätzten Koeffizienten zu erhöhen.

- Best Subset Selection: Ausgehend vom Gesamtmodell mit allen Indikatoren werden Modelle mit allen möglichen Indikatorkombinationen geschätzt. Anhand einer Kreuzvalidierung wird das Modell ausgewählt, welches die Daten am besten erklärt.

In einem zweiten Schritt haben wir mit den selektierten Indikatoren ein lineares Regressionsmodell mittels OLS geschätzt. Auf Grundlage der geschätzten Koeffizienten haben wir in einem dritten Schritt die Sonderlasten abgeschätzt und die Gewichte der Indikatoren bestimmt.

Als dritte Methode haben wir die Quadratische Minimierung angewendet. Diese schätzt durch Optimierung einer Zielfunktion unter Nebenbedingungen direkt Gewichte der Indikatoren.

Zur Identifikation der am besten geeigneten Methode haben wir fünf Kriterien definiert, die für die operative Umsetzung relevant sind. Es handelt sich dabei um den Grad, zu dem Sonderlasten korrekt abgebildet werden, die Robustheit der Ergebnisse über die Zeit, die inhaltliche Plausibilität, die Nachvollziehbarkeit und den Erhebungs- und Berechnungsaufwand.

Weiter haben wir die Ausgleichszahlungen, welche aus den neu berechneten Gewichten resultieren, simuliert. Wir haben die Dotation der Ausgleichsgefässe dabei fixiert, haben aber verschiedene Möglichkeiten untersucht, aus den gegebenen Indikatoren einen Lastenindex zu ermitteln.

Die Analyse basiert auf Daten zu den Nettoausgaben der Kantone und ihrer Gemeinden (2-Steller Funktionen) und den zehn bestehenden Indikatoren des Lastenausgleichs. Wir haben die Jahre 2012-2019 berücksichtigt.

Herausforderungen

Die Analyse hat aufgezeigt, dass die korrekte Bestimmung von Indikatorgewichten im Rahmen des Lastenausgleichs eine grosse *Herausforderung* darstellt. Dies aus mehreren Gründen:

- Sonderlasten sind ein latentes Konzept. Es fehlt daher eine Bezugsgrösse, um die mittels verschiedener Modelle geschätzten Sonderlasten zu evaluieren.
- Die Anzahl der Datenpunkte (max. 26) je Schätzung ist klein, die nutzbare Variation daher auch. Dies wirkt sich auf die Präzision der geschätzten Koeffizienten aus.
- Da es sich um strukturelle Lasten handelt, sollten die erklärenden Faktoren für die Sonderlasten einer gegebenen Ausgabenfunktion über die Zeit möglichst konstant bleiben. Bei allen drei untersuchten Methoden finden wir Variation in der Selektion der Indikatoren und in den geschätzten Koeffizienten über die Zeit. Dies manifestiert sich schliesslich in mehr oder weniger grossen Schwankungen der Indikatorgewichte über die Zeit (besonders ausgeprägt bei den Indikatoren des GLA).
- Gemäss Rahmenbedingungen sind die Indikatoren als fix zu betrachten. Sie sind so definiert, dass ein höherer Indikatorwert grundsätzlich mit höheren Sonderlasten einhergeht. In unseren Analysen stellen wir für die Koeffizienten einiger Indikatoren bei bestimmten Ausgabenfunktionen jedoch *negative* Vorzeichen fest. Dies deutet darauf hin, dass der Indikator in diesem Fall keine Sonderlasten, sondern Minderlasten abbildet.

Empfehlungen

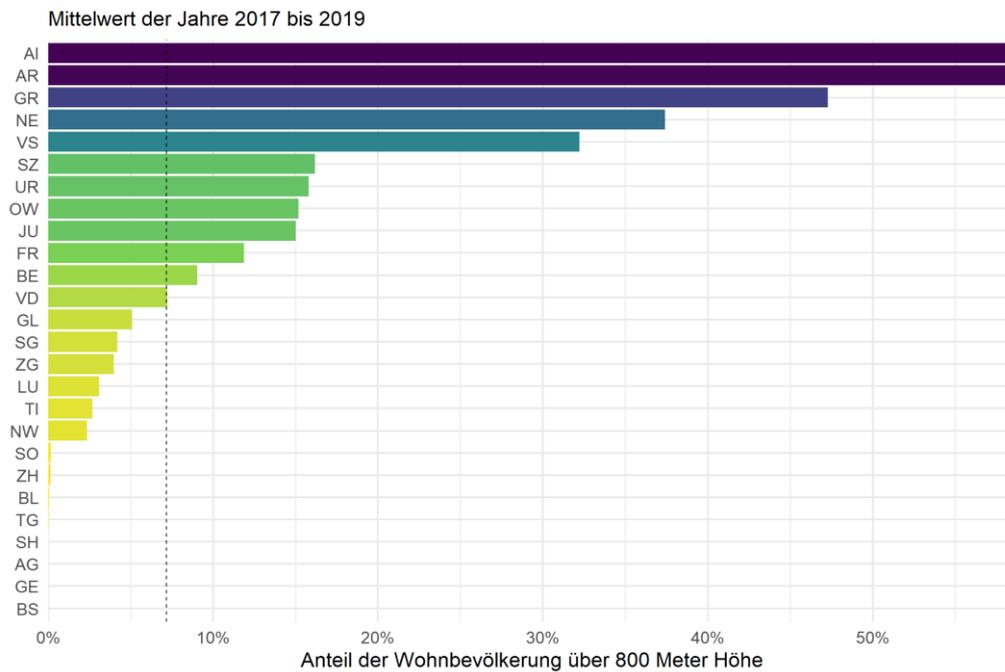
Im Lichte der oben erwähnten Rahmenbedingungen und Herausforderungen sprechen wir folgende Empfehlungen aus:

- *Methode*: Basierend auf die in Kapitel 3.4 formulierten Anforderungen, die wir an eine geeignete Methode stellen, hat die *Best Subset Selection* als Methode für die Variablenselektion und Bestimmung der Gewichte am besten abgeschnitten. Entsprechend sprechen wir eine Empfehlung für diese Methode aus.
- *Operative Umsetzung*: Erstens steht in Frage, für welche Indikatoren empirische Gewichte bestimmt werden sollen. Gegenwärtig ist dies nur für die Indikatoren des soziodemografischen Lastenausgleichs der Fall; für die Indikatoren des geografisch-topografischen Lastenausgleichs sind die Gewichte in der FiLaV festgeschrieben. Wir halten fest, dass die vorgeschlagene Methodik die Bestimmung empirisch hergeleiteter Gewichte auch für die Indikatoren des GLA ermöglicht und empfehlen, diese zu nutzen. Zweitens stellt sich die Frage, in welchem Rhythmus die Gewichte künftig neu bestimmt werden sollten. Die ermittelten Gewichte können grundsätzlich in der FiLaV festgeschrieben werden. Wir empfehlen dabei, die Gewichte regelmässig, z.B. alle vier Jahre im Rahmen der Berichterstattung über den Vollzug und die Wirksamkeit des Finanzausgleichs zwischen Bund und Kantonen neu zu prüfen und allenfalls für die nächste Periode anzupassen. Um Schwankungen der Gewichte über die Jahre möglichst gering zu halten, empfehlen wir eine doppelte Mittelwertbildung, die auch in dieser Studie zur Anwendung gelangt: Zunächst werden die Nettoausgaben und Indikatorwerte jeweils über drei Jahre gemittelt (rollierend, ausgehend von den festgelegten Referenz- bzw. Bemessungsjahren). Mit diesen rollierenden Mittelwerten erfolgt dann die Bestimmung der Gewichte für die Jahre t , $t-1$ und $t-2$, wobei sich t auf das Bemessungsjahr bezieht. Die relevanten Gewichte ergeben sich aus einer Mittelwertbildung der Gewichte wiederum rollierend über drei Jahre.
- *Berechnung der Ausgleichszahlungen*: Basierend auf den in Abschnitt 3.5.1 ausgeführten konzeptionellen Überlegungen empfehlen wir, den *Status Quo* beizubehalten. Für die Indikatoren des GLA bedeutet dies, dass pro Indikator ein Lastenindex erstellt wird, die Berechnung der Sonderlasten in SLA A-C und SLA F erfolgt weiterhin durch Zusammenfassen der Indikatoren zu einem gewichteten Lastenindex. Die Berechnung eines gewichteten Lastenindex beim SLA A-C und beim SLA F hat den Vorteil, dass sich Sonder- und Minderlasten zumindest teilweise kompensieren und somit Kantone bevorteilt werden, die über alle Indikatoren betrachtet hohe Sonderlasten aufweisen. Beim GLA drängt sich keine Anpassung auf, da die Indikatoren untereinander positiv korreliert sind und eine Kompensation zwischen Indikatoren nicht zu erwarten ist. Einzig auf die Berechnung der Masszahl der Lasten und auf die Rundung des Lastenindex kann aus unserer Sicht verzichtet werden, da sie zur Ermittlung der Verteilung der Dotation inhaltlich nicht benötigt werden.

A. Daten

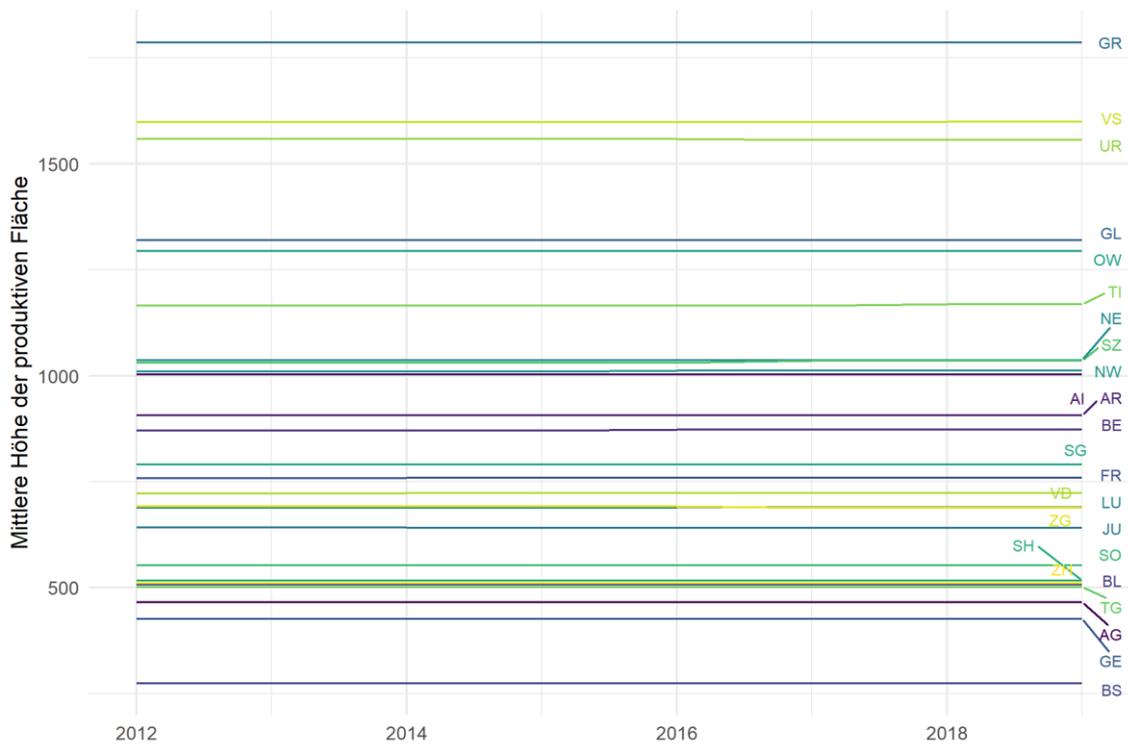
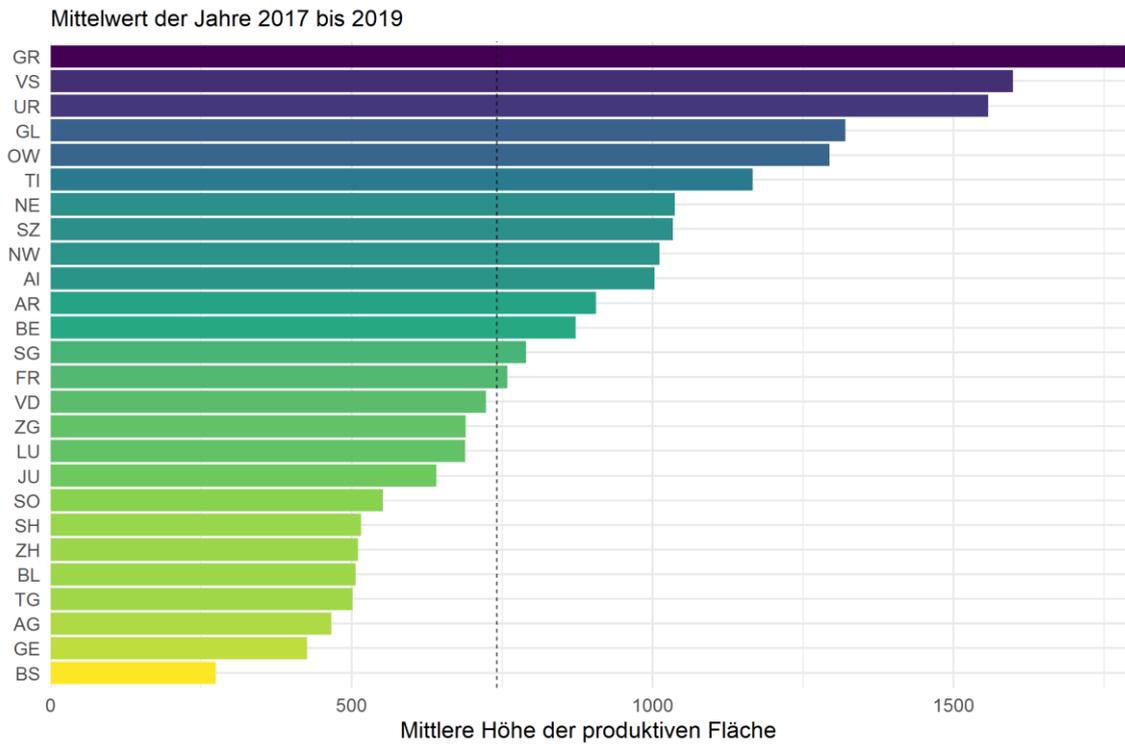
A.1 Indikatoren

Abbildung 25: Siedlungshöhe



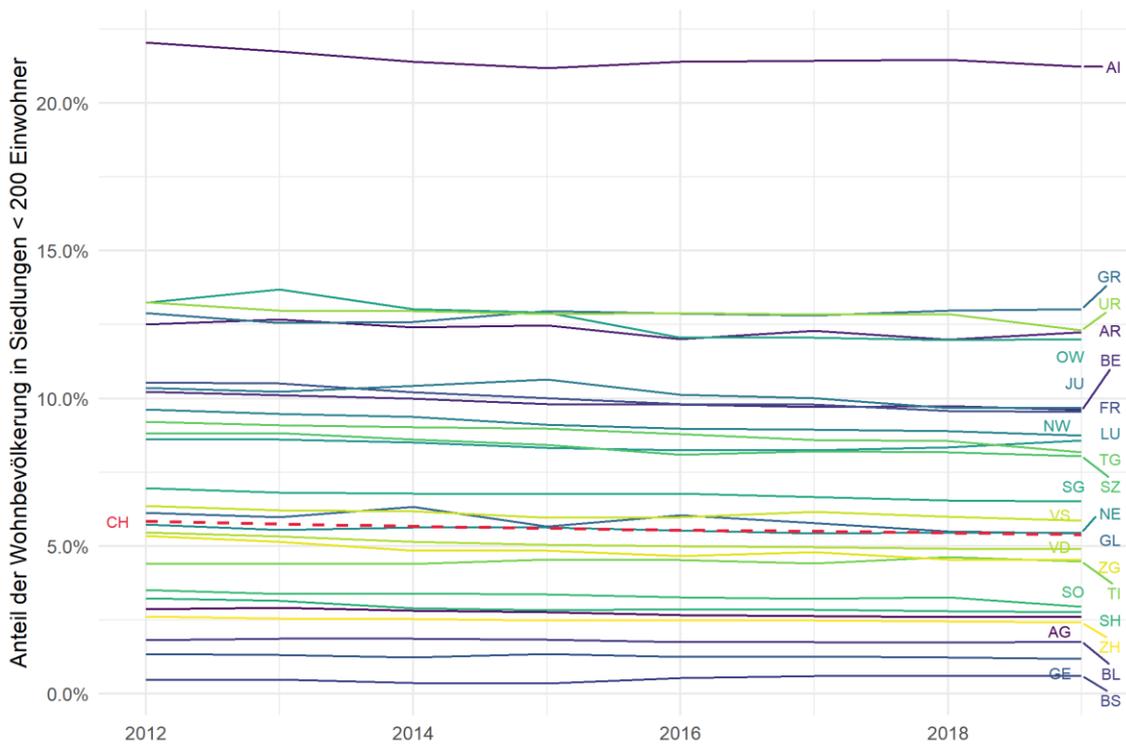
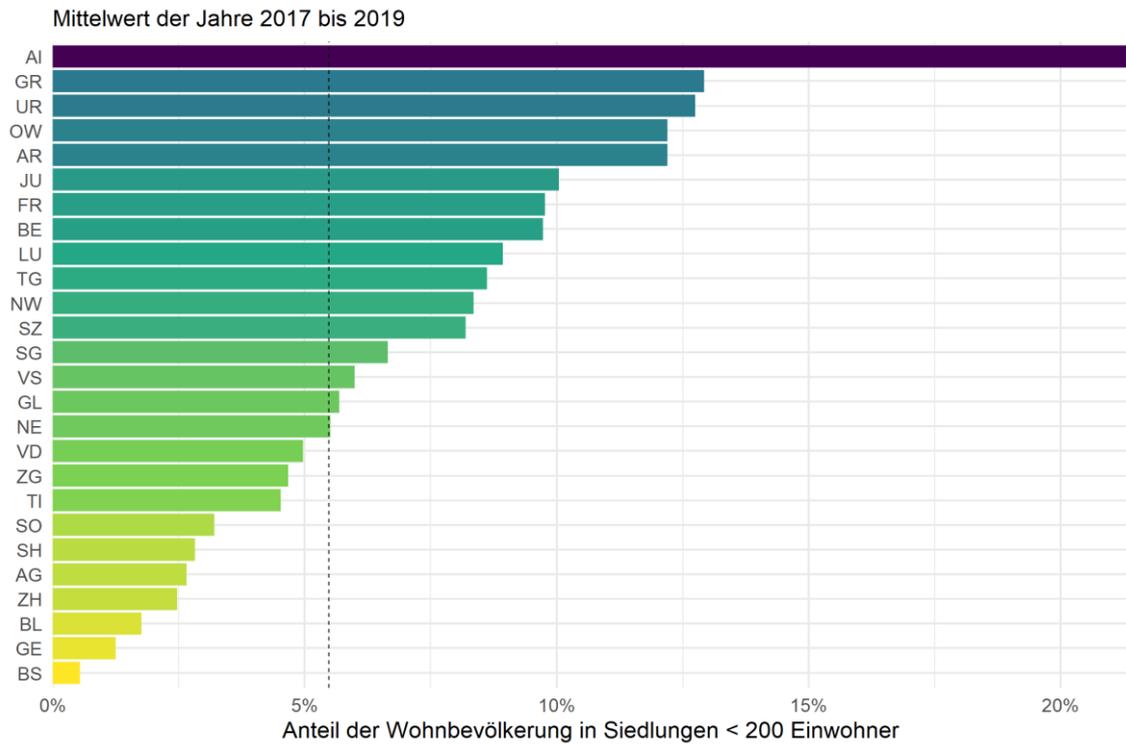
Quelle: EFV, eigene Berechnungen.

Abbildung 26: Steilheit des Geländes



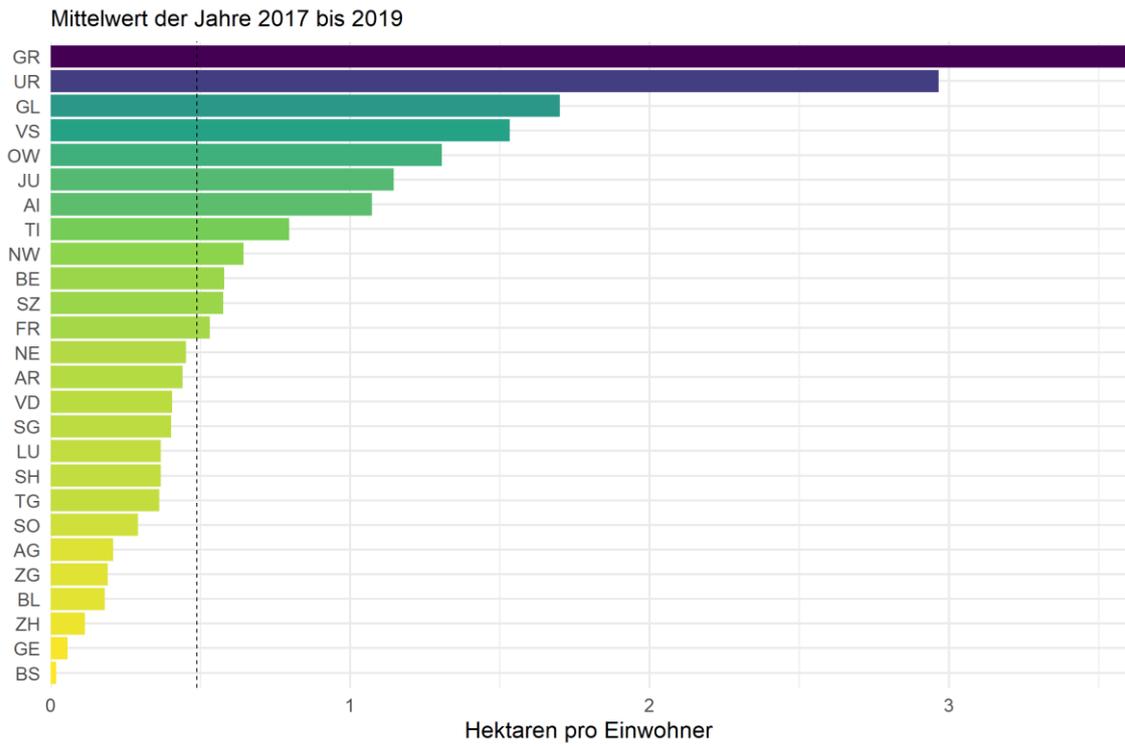
Quelle: EFV, eigene Berechnungen.

Abbildung 27: Siedlungsstruktur



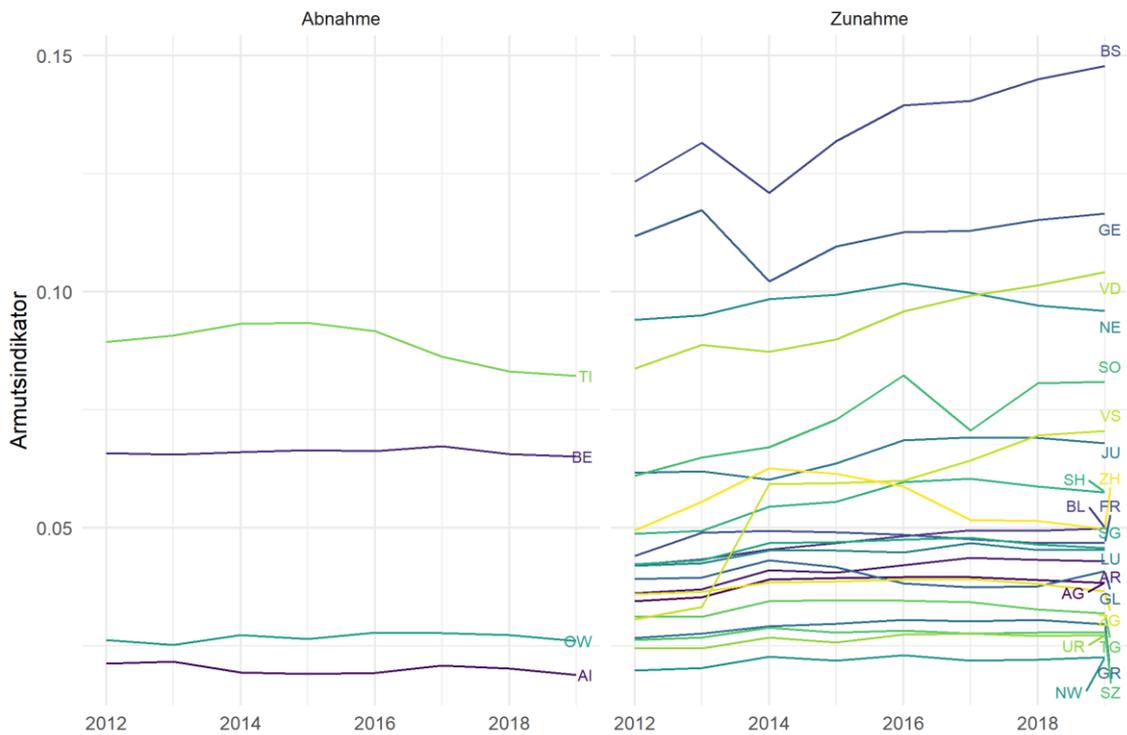
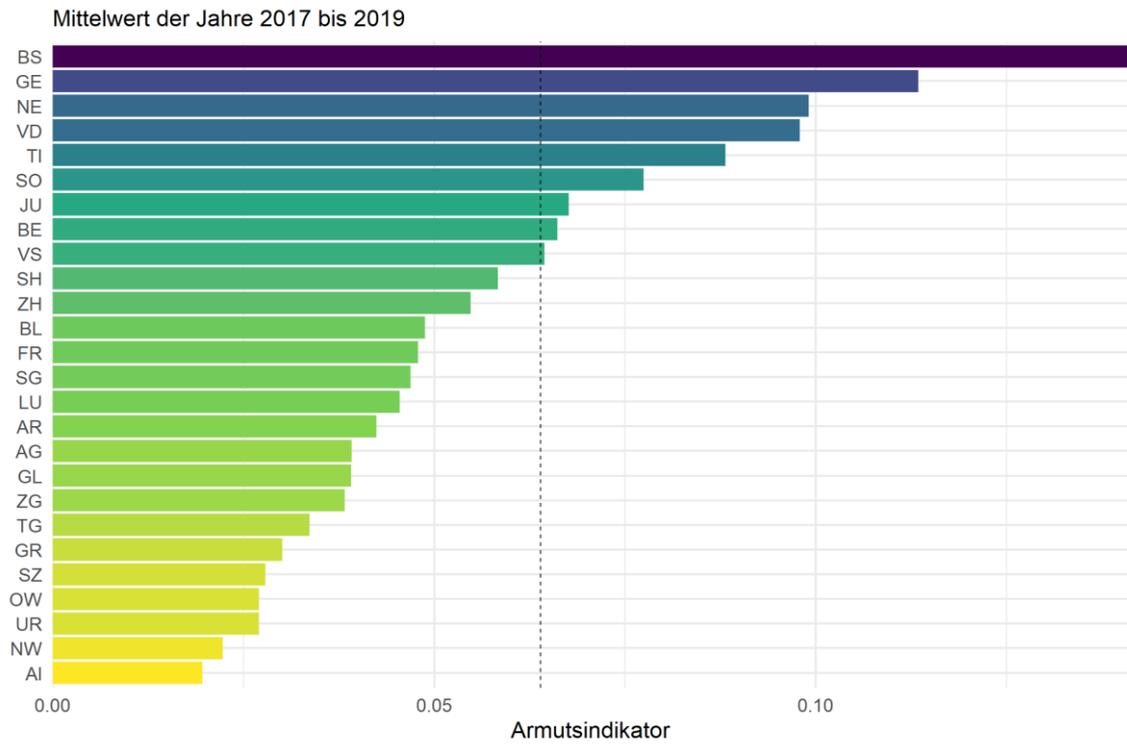
Quelle: EFV, eigene Berechnungen.

Abbildung 28: Geringe Bevölkerungsdichte



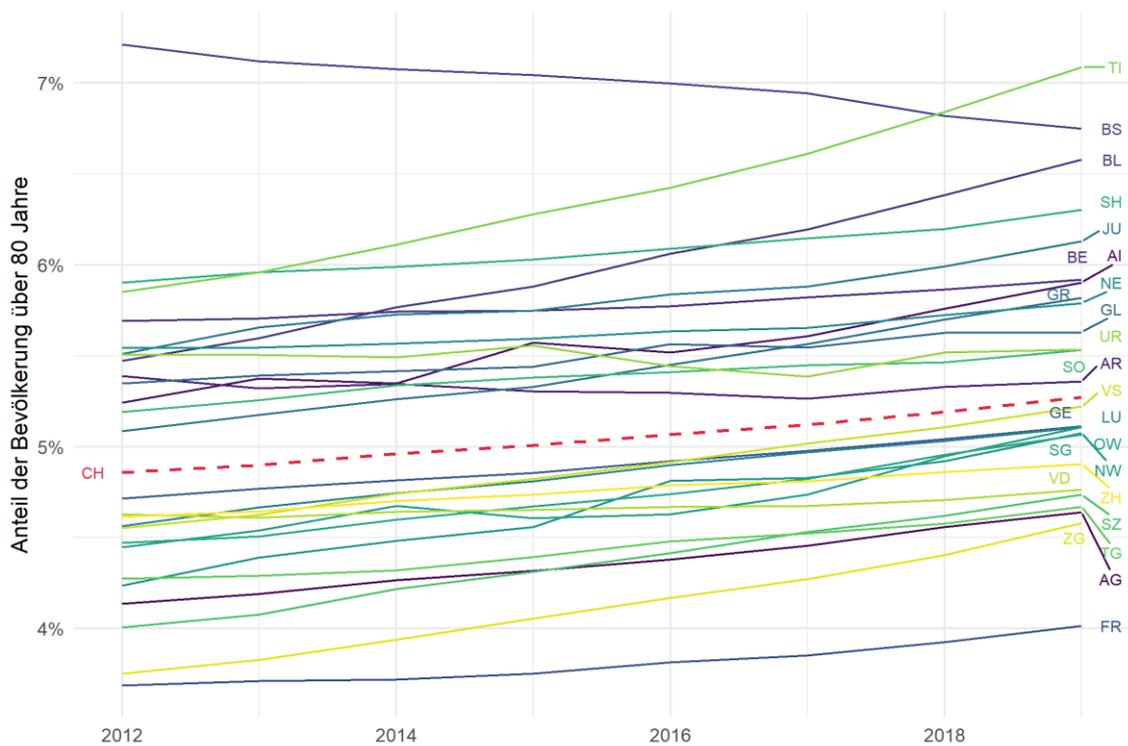
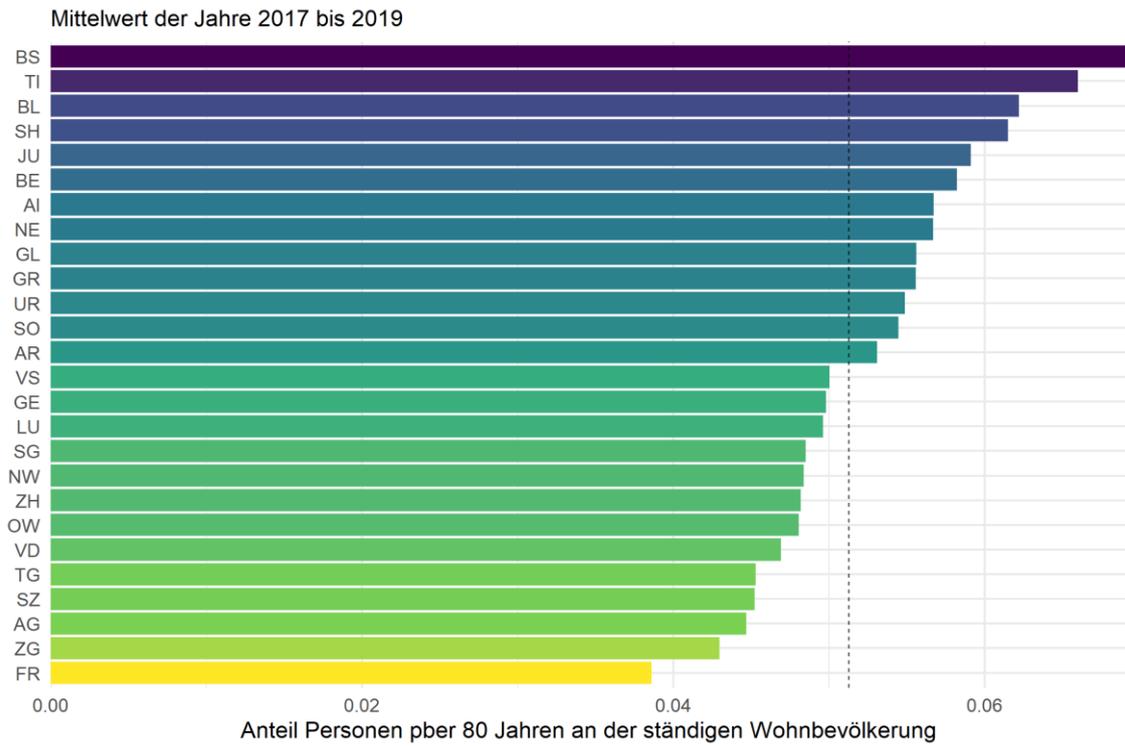
Quelle: EFV, eigene Berechnungen.

Abbildung 29: Armutsindikator



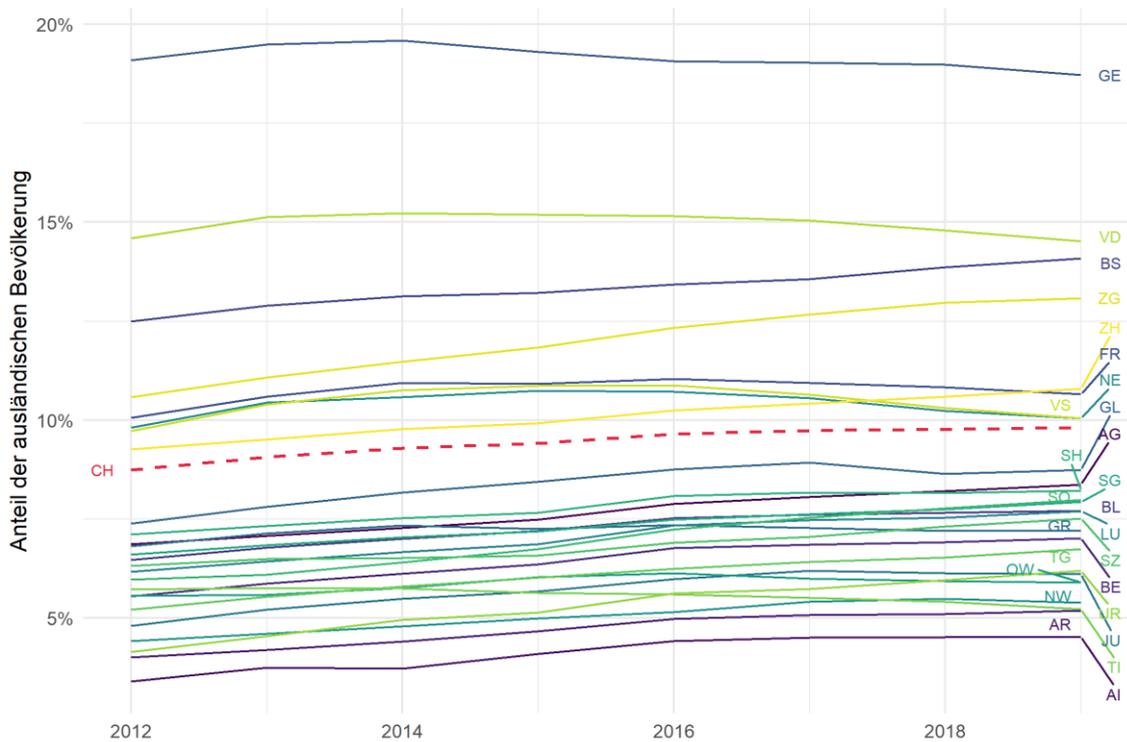
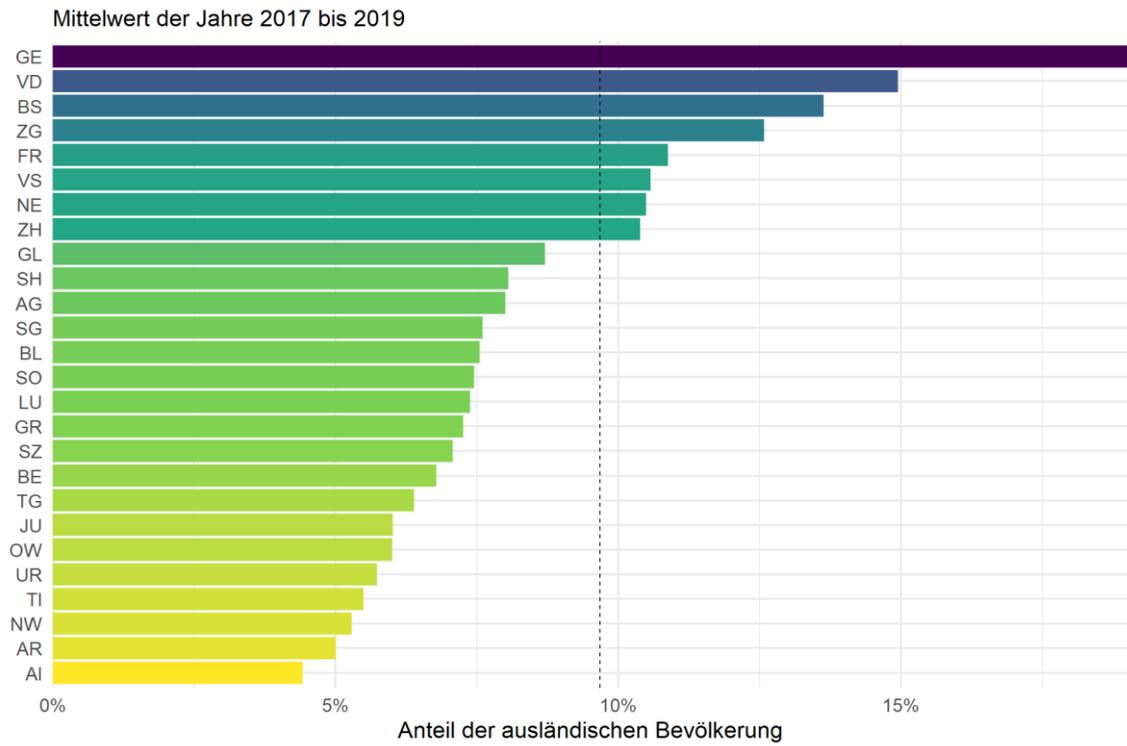
Quelle: EFV, eigene Berechnungen.

Abbildung 30: Altersstruktur



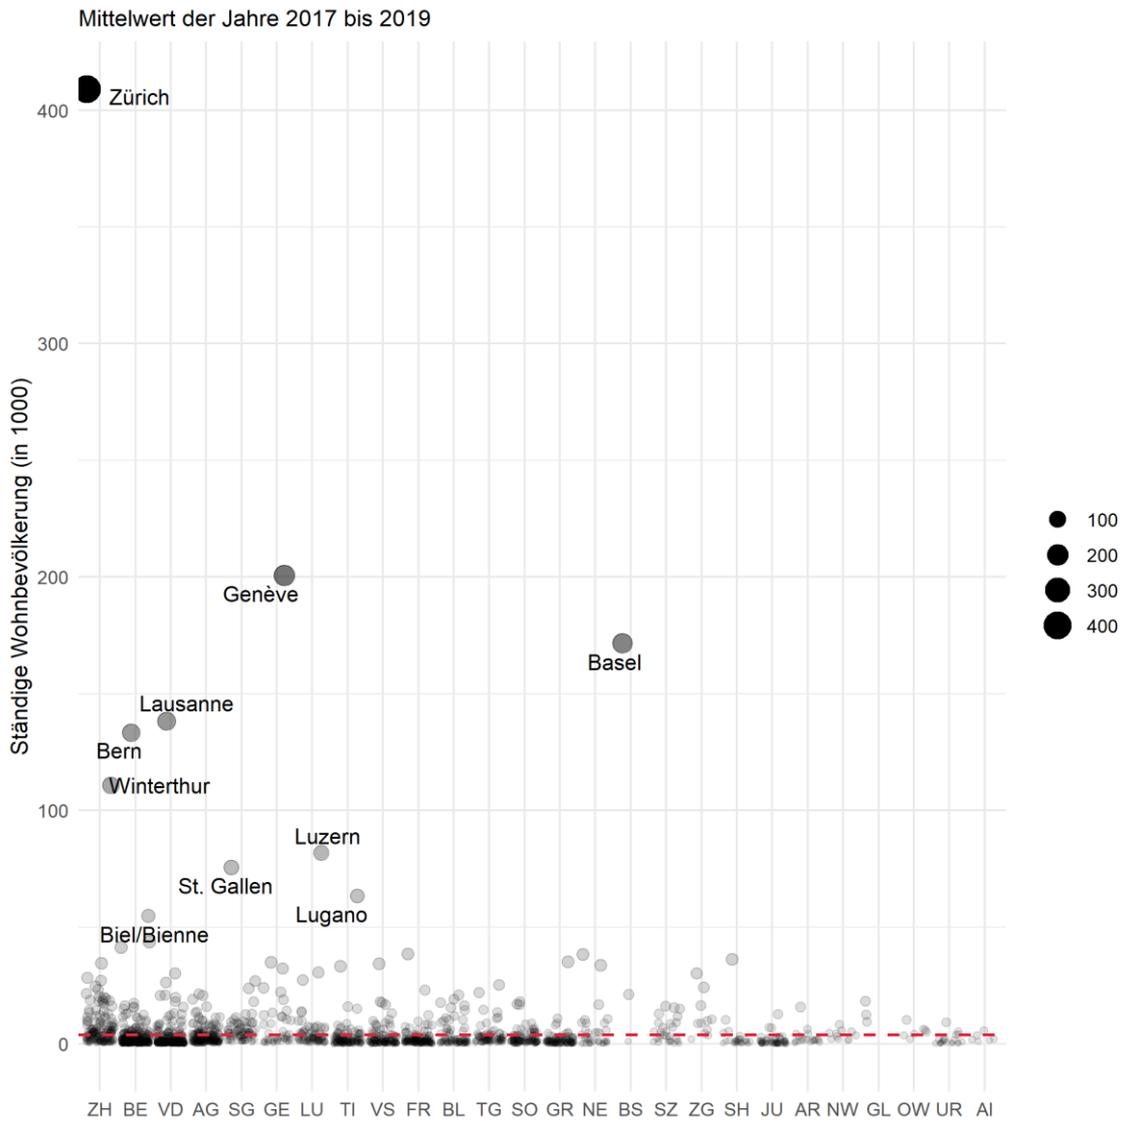
Quelle: EFV, eigene Berechnungen.

Abbildung 31: Ausländerintegration



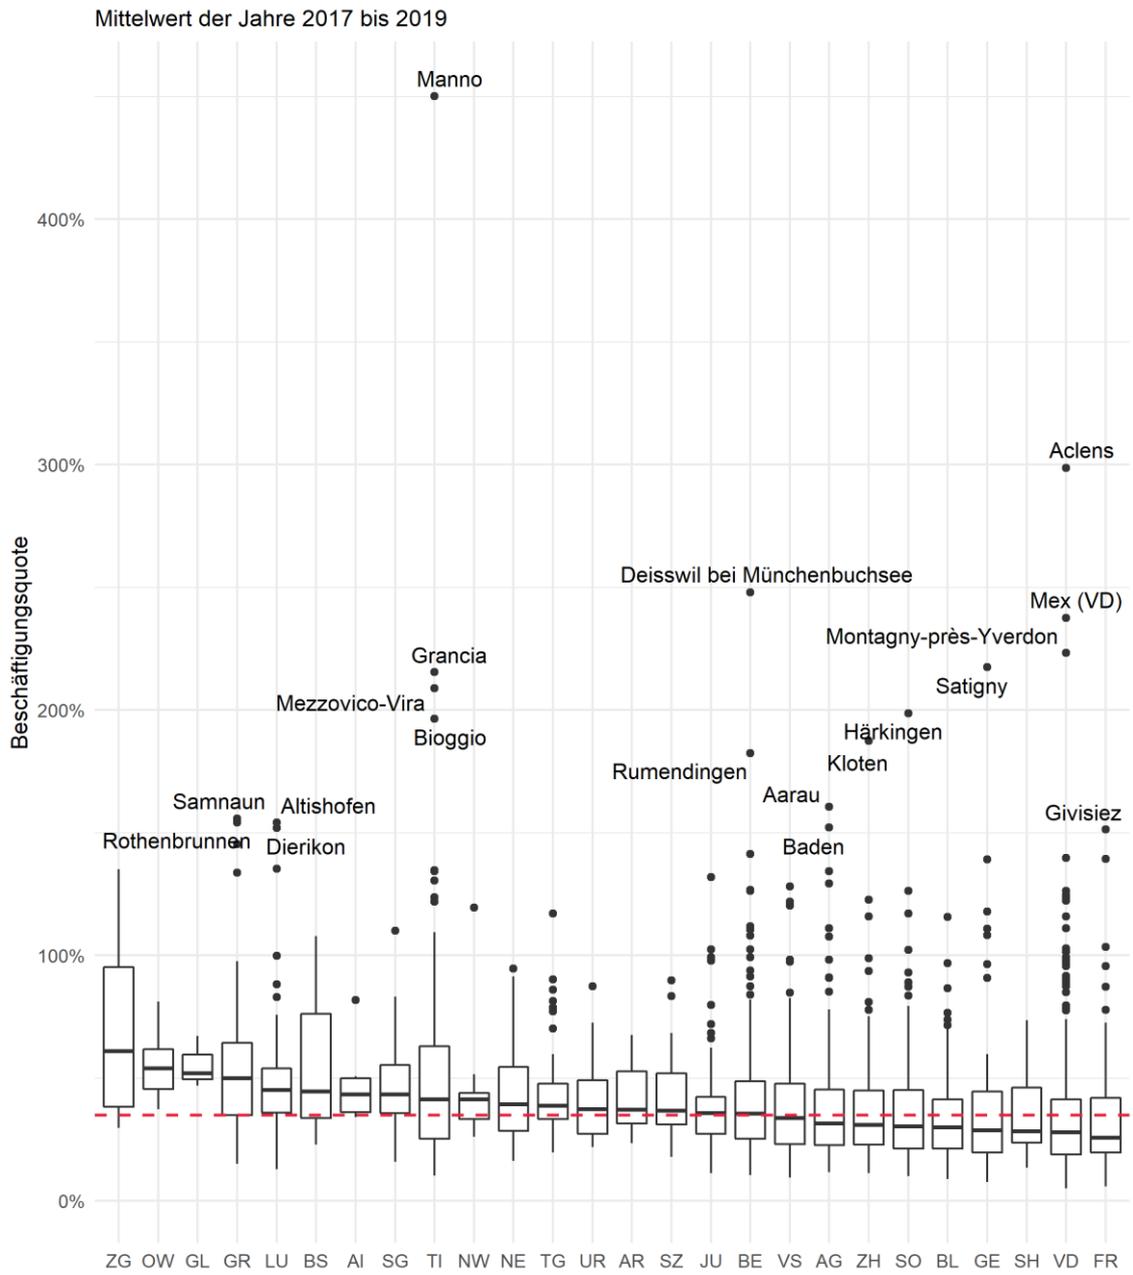
Quelle: EFV, eigene Berechnungen.

Abbildung 32: Ständige Wohnbevölkerung



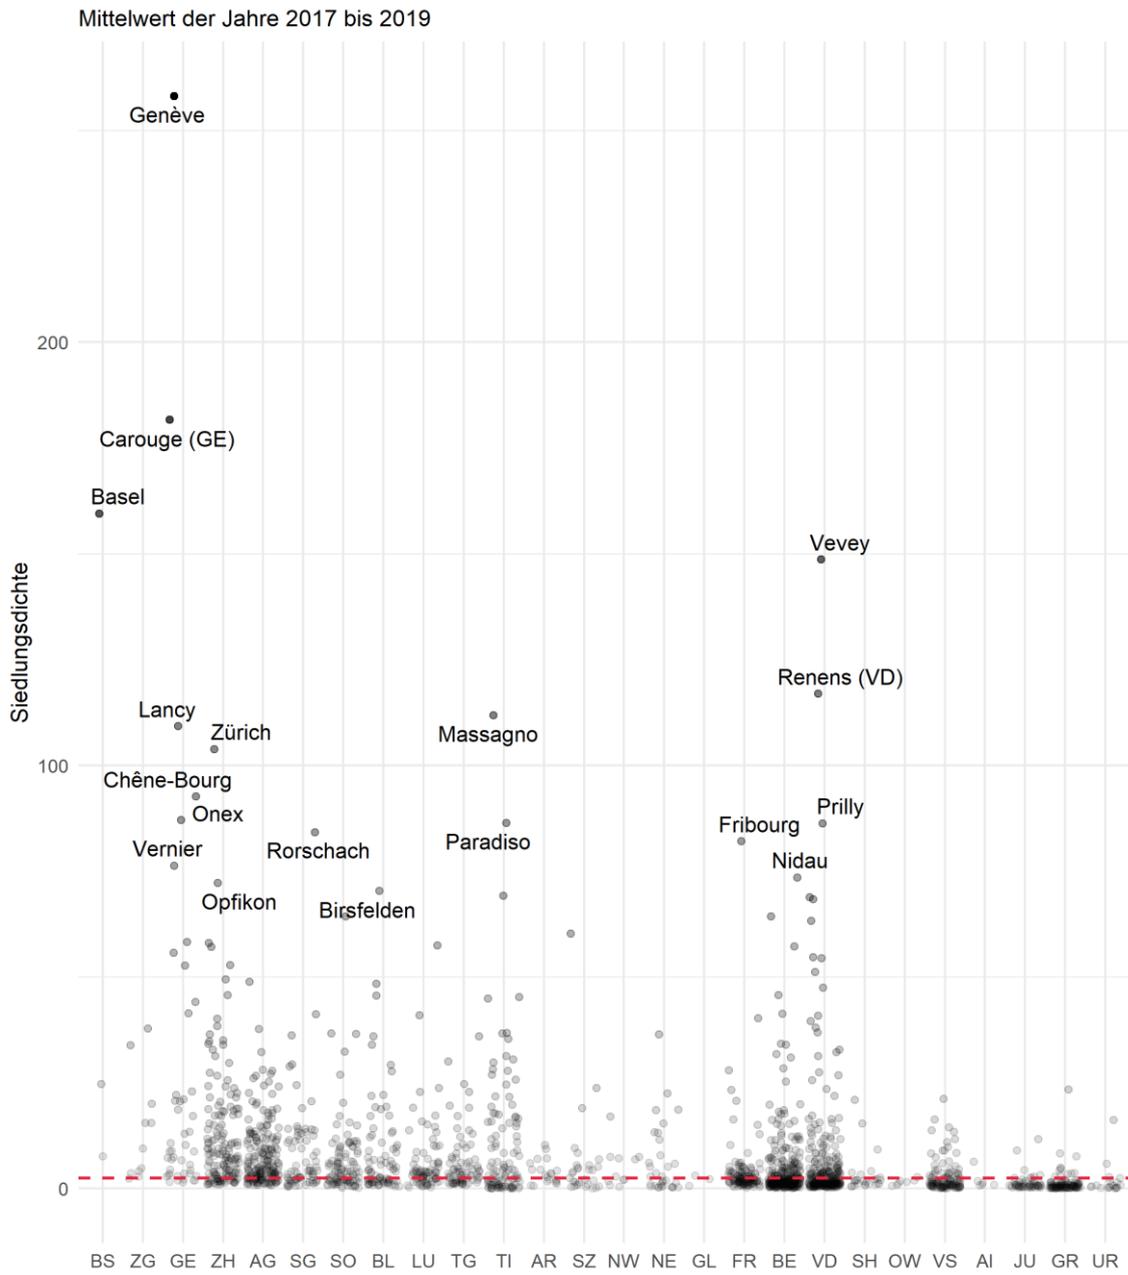
Quelle: EFV, eigene Berechnungen. Anmerkung: Reihenfolge gemäss Grösse des Kantons, gemessen an der ständigen Wohnbevölkerung.

Abbildung 33: Beschäftigungsquote



Quelle: EFV, eigene Berechnungen. Anmerkung: Reihenfolge gemäss mittlerer Beschäftigungsquote.

Abbildung 34: Siedlungsdichte



Quelle: EFV, eigene Berechnungen. Anmerkung: Reihenfolge gemäss mittlerer Siedlungsdichte.

A.2 Nettoausgaben

Tabelle 8: Funktionale Gliederung der Nettoausgaben

Nr.	Funktion
<i>0</i>	<i>Allgemeine Verwaltung</i>
01	Legislative und Exekutive
02	Allgemeine Dienste
03	Beziehungen zum Ausland
08	F&E in allgemeine Verwaltung
1	<i>Öffentliche Ordnung und Sicherheit, Verteidigung</i>
11	Öffentliche Sicherheit
12	Rechtssprechung
13	Strafvollzug
14	Allgemeines Rechtswesen
15	Feuerwehr
16	Verteidigung
18	F&E in Öffentliche Ordnung und Sicherheit, Verteidigung
2	<i>Bildung</i>
21	Obligatorische Schule
22	Sonderschulen
23	Berufliche Grundbildung
25	Allgemeinbildende Schulen
26	Höhere Berufsbildung
27	Hochschulen
28	Forschung
29	Übriges Bildungswesen
3	<i>Kultur, Sport und Freizeit, Kirche</i>
31	Kulturerbe
32	Kultur, übrige
33	Medien
34	Sport und Freizeit
35	Kirchen und religiöse Angelegenheiten
38	F&E in Kultur, Sport und Freizeit, Kirche
4	<i>Gesundheit</i>
41	Spitäler, Kranken- und Pflegeheime
42	Ambulante Krankenpflege
43	Gesundheitsprävention
48	F&E in Gesundheit
49	Gesundheitswesen n.a.g.

Nr.	Funktion
5	<i>Soziale Sicherheit</i>
51	Krankheit und Unfall
52	Invalidität
53	Alter + Hinterlassene
54	Familie und Jugend
55	Arbeitslosigkeit
56	Sozialer Wohnungsbau
57	Sozialhilfe und Asylwesen
58	F&E in soziale Sicherheit
59	Soziale Wohlfahrt n.a.g.
6	<i>Verkehr und Nachrichtenübermittlung</i>
61	Strassenverkehr
62	Öffentlicher Verkehr
63	Verkehr, übrige
64	Nachrichtenübermittlung
68	F&E in Verkehr und Nachrichtenübermittlung
7	<i>Umweltschutz und Raumordnung</i>
71	Wasserversorgung
72	Abwasserbeseitigung
73	Abfallwirtschaft
74	Verbauungen
75	Arten- und Landschaftsschutz
76	Bekämpfung von Umweltverschmutzung
77	Übriger Umweltschutz
78	F&E in Umweltschutz
79	Raumordnung
8	<i>Volkswirtschaft</i>
81	Landwirtschaft
82	Forstwirtschaft
83	Jagd und Fischerei
84	Tourismus
85	Industrie, Gewerbe, Handel
86	Banken und Versicherungen
87	Brennstoffe und Energie
88	F&E in Volkswirtschaft
89	Sonstige gewerbliche Betriebe
9	<i>Finanzen und Steuern</i>
91	Steuern
92	Steuerabkommen

Nr.	Funktion
93	Finanz- und Lastenausgleich
94	Ertragsanteile an Bundeseinnahmen ohne Zweckbindung
95	Ertragsanteile, übrige, ohne Zweckbindung
96	Vermögens- und Schuldenverwaltung
97	Rückverteilungen
99	Nicht aufgeteilte Posten

B. Methoden

B.1 Quadratische Minimierung

Das Problem der quadratischen Minimierung fällt in die Klasse der nichtlinearen Optimierungsprobleme. Die Methode kann bei Vorliegen einer quadratischen Zielfunktion und linearen Nebenbedingungen angewendet werden. Das Optimierungsproblem ist wie folgt:

$$\min_x \frac{1}{2} \mathbf{x}^T D \mathbf{x} - \mathbf{d}^T \mathbf{x}$$

unter den Nebenbedingungen $A^T \mathbf{x} \geq \mathbf{b}$. Hier beschreibt \mathbf{x} die 26 x 10-Indikatormatrix der standardisierten Indikatoren für alle Kantone in einem bestimmten Jahr und A^T die 10 x 11-Matrix der Nebenbedingungen (ein 1 x 10-Vektor für die Bedingung, dass die Koeffizienten sich auf 1 summieren müssen und eine 10 x 10-Matrix für die Nichtnegativitätsbedingungen). Die Vorgehensweise entspricht einer OLS-Regression mit Nebenbedingungen. Die resultierenden Koeffizienten können daher direkt als Gewichte interpretiert werden.

B.2 LASSO Regression

Bei der LASSO Regression wird folgende Funktion minimiert, wobei $y_{f,k}$ die Nettoausgaben pro Kopf für die Ausgabenfunktion f und den Kanton k und $x_{p,k}$ die Indikatoren p darstellen.

$$\operatorname{argmin}_{\beta^{LASSO}} \sum_{k \in K} \left(y_{f,k} - \beta_0 - \sum_{p \in P} x_{p,k} \cdot \beta_p^{LASSO} \right)^2 + \lambda^{LASSO} \sum_{p \in P} |\beta_p^{LASSO}|$$

Wobei $\lambda^{LASSO} \geq 0$ ein Tuningparameter ist, der über das relative Gewicht der beiden Terme entscheidet.

Die Grösse des Tuningparameters λ^{LASSO} wird mittels Kreuzvalidierung (*cross-validation*) bestimmt. Dabei handelt es sich um eine datengetriebene Methode, die den Tuningparameter basierend auf der Vorhersagefähigkeit des Modells festlegt. Hierzu werden die 26 Kantone in $k \leq 26$ Teilmengen T_1, \dots, T_k aufgeteilt. Für jeden Wert des Tuningparameters werden anschliessend

k Testdurchläufe durchgeführt, wobei im i -ten Testdurchlauf die Teilmenge T_i als Testdaten und die restlichen Kantone als Trainingsdaten dienen. Für jeden Testdurchlauf wird basierend auf den Trainingsdaten das Modell (s.o.) geschätzt und basierend auf den Testdaten anschliessend die mittlere quadratische Abweichung des vorhergesagten Wertes vom gemessenen Wert (*mean squared error, MSE*) berechnet.

Die geschätzte Kreuzvalidierungsstatistik (KV) für den Testdurchlauf i ergibt sich sodann aus den gemittelten MSE dieses Testdurchlaufs:

$$KV_i = \frac{1}{k} \sum_{k \in K} MSE_i$$

Auf dieser Grundlage wird derjenige Tuningparameter gewählt, für welchen die Kreuzvalidierungsstatistik minimal ist.

In der konkreten Anwendung setzen wir $k = 26$. D.h. wir führen eine sog. Leave-One-Out Kreuzvalidierung (LOOCV) durch. Das Modell wird dabei auf Grundlage von Daten von 25 Kantonen trainiert und anschliessend für die Vorhersage der Nettoausgaben pro Kopf bzw. des MSE für den verbleibenden Kanton (Testdaten) angewendet.

LASSO tendiert bei Gruppen hoch korrelierter erklärender Variablen, jeweils eine Variable aus dieser Gruppe zu selektieren. Eine Möglichkeit, diese Eigenschaft zumindest abzuschwächen, ist die Verwendung von Elastic Net. Elastic Net kombiniert die Bestrafungsterme von LASSO und der Ridge Regression.

$$\operatorname{argmin}_{\beta^{Ridge}} \sum_{k \in K} \left(y_{f,k} - \beta_0 - \sum_{p \in P} x_{p,k} \cdot \beta_p^{Ridge} \right)^2 + \lambda^{Ridge} \sum_{p \in P} \beta_p^{Ridge^2}$$

Wie bei LASSO ist $\lambda^{Ridge} \geq 0$ ein Tuningparameter, der über das relative Gewicht der beiden Terme entscheidet.

Elastic Net kombiniert die beiden Bestrafungsterme wie folgt:

$$\lambda \left(\frac{1-\alpha}{2} \sum_{p \in P} \beta_p^{Ridge^2} + \alpha \sum_{p \in P} |\beta_p^{LASSO}| \right)$$

Die Gewichtung der beiden Bestrafungsterme wird dabei über den Parameter α gesteuert. Ist $\alpha = 1$, dann ergibt sich LASSO, ist $\alpha = 0$, ergibt sich die Ridge Regression. Für die Schätzungen mit Elastic Net setzen wir $\alpha = 0,5$.

B.3 Best Subset Selection

Bei der Best Subset Selection Methode wird die «optimale» Teilmenge der Indikatoren bestimmt, wobei sich «optimal» an bestimmten statistischen Kriterien bemisst (s.u.).

Bei der Best Subset Selection Methode werden Regressionsmodelle für alle möglichen Kombinationen der zehn Indikatoren geschätzt. Bei 10 Indikatoren p ergeben sich $2^p = 1024$ mögliche Modelle. Aus diesen Modellen wird anhand von statistischen Kriterien das «beste» Modell gewählt. Der Algorithmus sieht wie folgt aus:

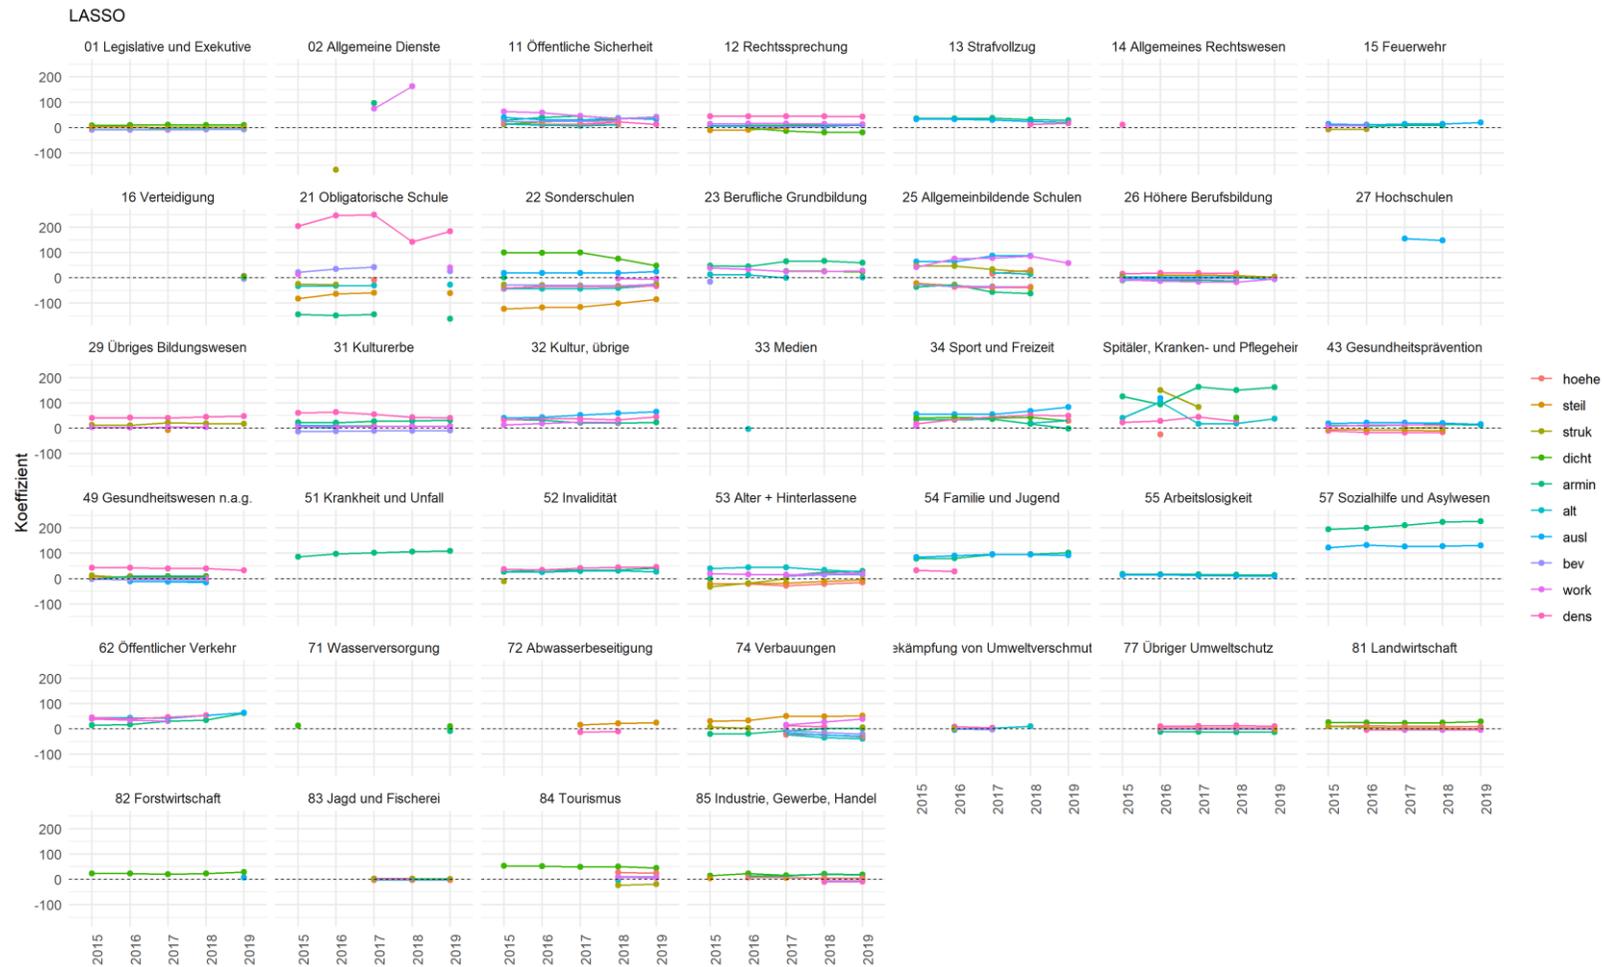
1. Schätze ein lineares Regressionsmodell mit der Kleinstquadratmethode (OLS) ohne Indikatoren. Daraus resultiert das Modell M_0 .
2. Für $p = 1, 2, \dots, 10$:
 - a) Schätze alle $\binom{10}{p}$ Modelle, die exakt p Indikatoren enthalten. Bei zwei Indikatoren ($p=2$) ergeben sich bspw. 45 Modelle: $\binom{10}{2} = \frac{10!}{(10-2)! \cdot 2!} = 45$. Bei 5 Indikatoren ($p=5$) ergeben sich 252 Modelle.
 - b) Wähle aus den $\binom{10}{p}$ Modellen dasjenige Modell mit der tiefsten Summe der Residuenquadrate: $SQR = \sum_{k \in K} (y_k - \hat{y}_k)$, wobei y_k für die beobachteten Nettoausgaben pro Kopf des Kantons k und \hat{y}_k für die vorhergesagten Nettoausgaben pro Kopf des Kantons k stehen. Aus diesem Schritt resultieren M_p Modelle.
3. Im dritten Schritt wird für jedes der in den Schritten 1 und 2 geschätzten bzw. ausgewählten Modelle M_0, \dots, M_{10} eine Kreuzvalidierung mittels LOOCV³⁰ durchgeführt. Dasjenige Modell mit dem kleinsten Vorhersagefehler wird selektiert und für die Schätzung der Sonderlasten verwendet.

C. Zusätzliche Ergebnisse

C.1 Entwicklung der Koeffizienten

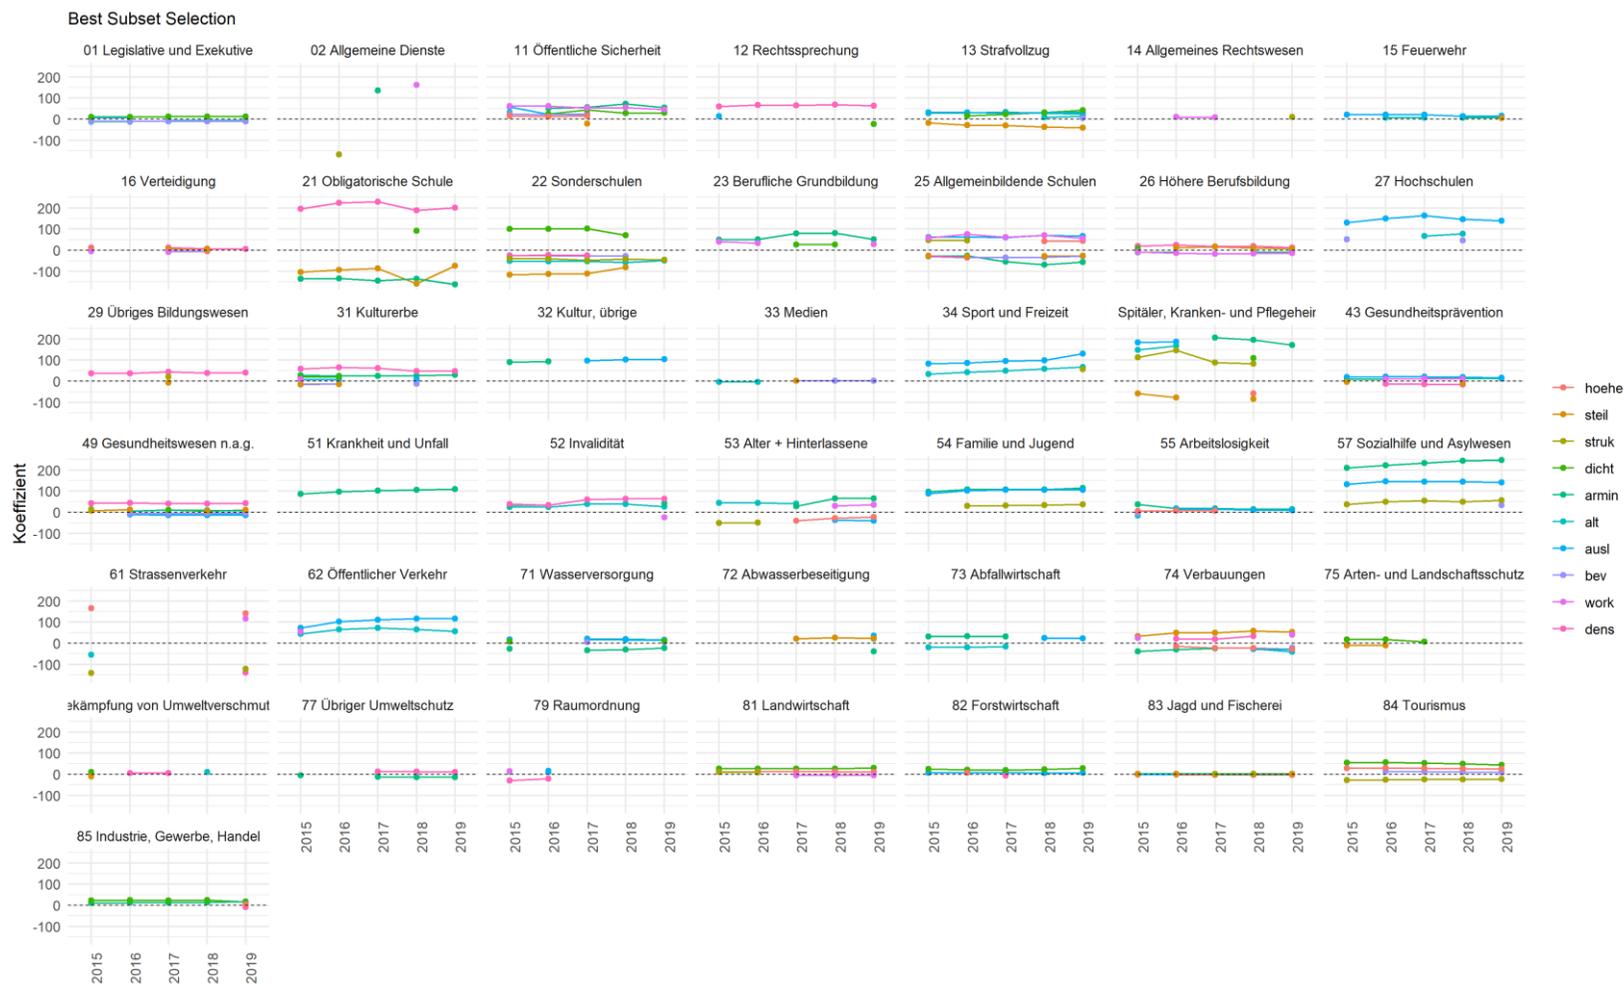
³⁰ Vgl. Ausführungen zur LASSO-Regression.

Abbildung 35: Entwicklung der Koeffizienten über die Zeit, LASSO



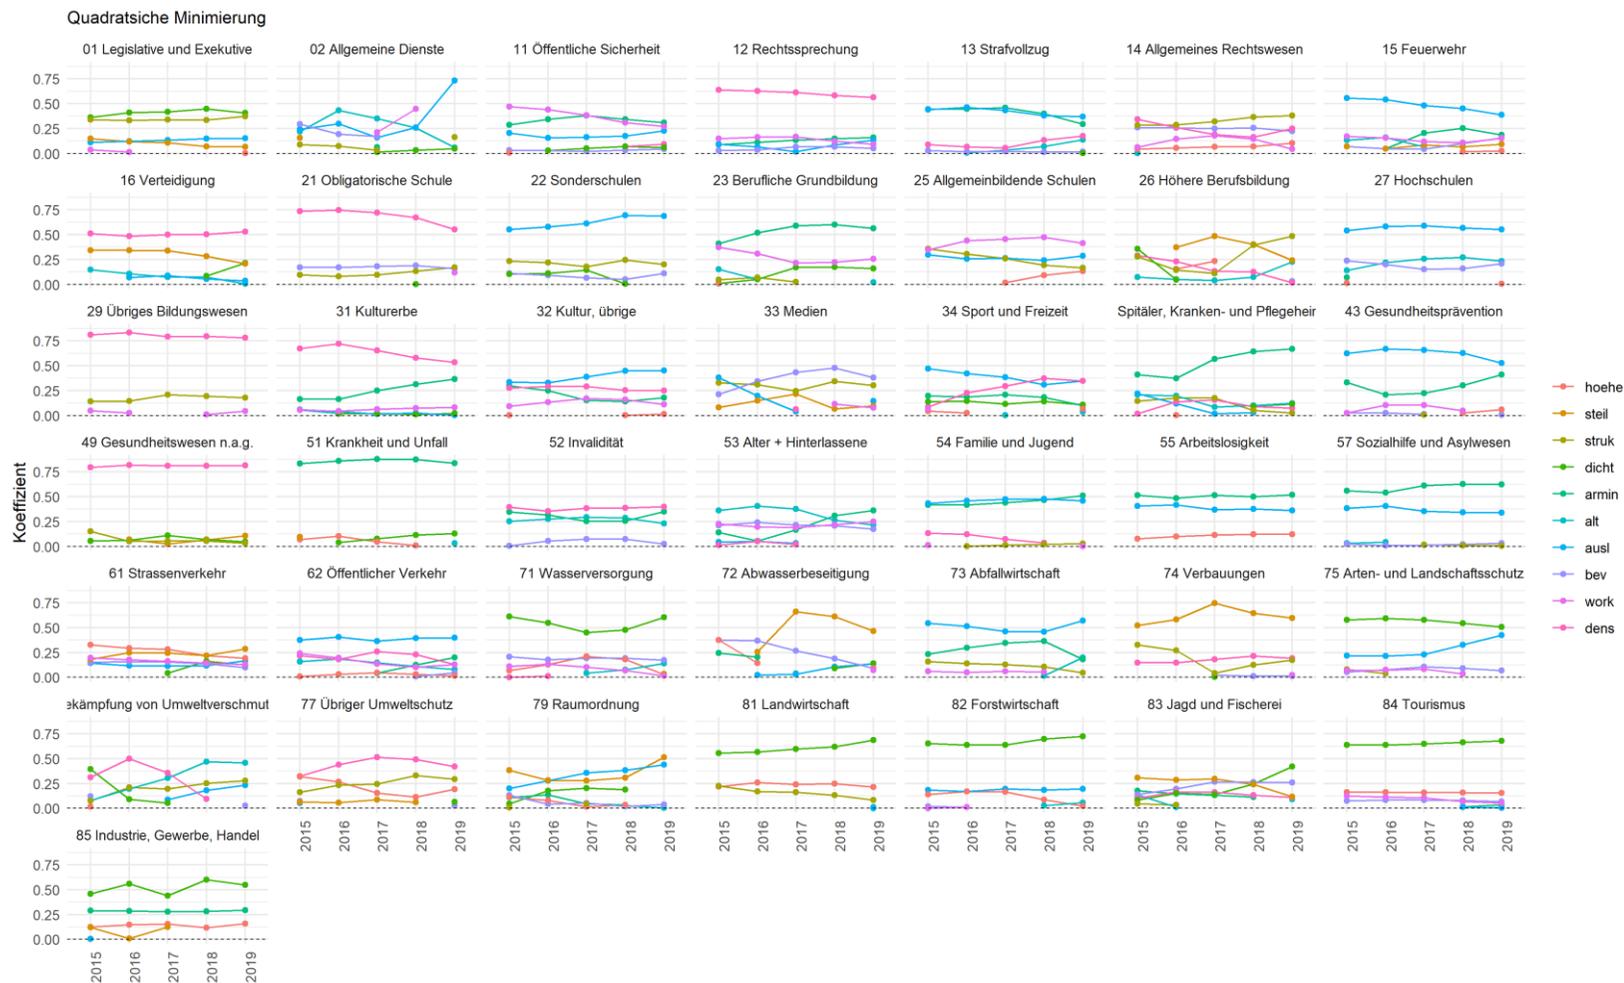
Quelle: EFV, eigene Berechnungen. Anmerkungen: Die angegebenen Jahre weisen auf das jeweils letzte Jahr des betrachteten Dreijahresmittelwerts hin. Das Jahr 2019 bspw. steht für den Mittelwert aus den Jahren 2017-2019.

Abbildung 36: Entwicklung der Koeffizienten über die Zeit, Best Subset Selection



Quelle: EFV, eigene Berechnungen. Anmerkungen: Die angegebenen Jahre weisen auf das jeweils letzte Jahr des betrachteten Dreijahresmittelwerts hin. Das Jahr 2019 bspw. steht für den Mittelwert aus den Jahren 2017-2019.

Abbildung 37: Entwicklung der Koeffizienten über die Zeit, Quadratische Minimierung



Quelle: EFV, eigene Berechnungen. Anmerkungen: Die angegebenen Jahre weisen auf das jeweils letzte Jahr des betrachteten Dreijahresmittelwerts hin. Das Jahr 2019 bspw. steht für den Mittelwert aus den Jahren 2017-2019.

C.2 Simulation

Tabelle 9: Veränderung Ausgleichszahlungen (in CHF), Total

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	89'617'968	-556'375	2'591'122	-20'634'438
Bern	32'280'785	787'448	11'760'688	37'206'335
Luzern	6'080'440	-615'956	3'274'707	9'502'748
Uri	11'617'446	5'370'788	3'655'272	2'162'408
Schwyz	6'893'039	-1'340'314	-585'460	405'704
Obwalden	6'038'372	1'189'722	1'097'742	1'355'397
Nidwalden	1'312'660	343'300	447'638	719'399
Glarus	5'327'066	3'113'143	1'558'646	-186'688
Zug	463'744	2'006'985	2'781'859	-463'744
Freiburg	8'585'987	138'621	3'894'344	8'834'591
Solothurn	7'372'205	-592'470	-2'110'748	694'308
Basel-Stadt	63'189'822	-2'426'415	-3'181'947	4'036'698
Basel-Landschaft	-	-	-	442'096
Schaffhausen	1'197'608	-994'166	-836'579	172'683
Appenzell A.Rh.	19'810'183	-11'328'247	-8'631'412	-7'627'087
Appenzell I.Rh.	8'677'500	-2'855'692	-1'001'754	1'109'813
St. Gallen	1'747'994	-177'074	941'407	2'731'833
Graubünden	136'612'253	4'840'594	-7'475'151	-24'450'725
Aargau	-	-	-	-
Thurgau	3'561'208	-360'755	1'917'939	5'565'594
Tessin	25'645'995	-1'533'128	-6'928'446	532'020
Waadt	101'086'315	5'732'850	4'621'921	-596'456
Wallis	85'037'832	3'014'138	-6'463'780	-21'921'196
Neuenburg	37'729'196	-15'191'441	-14'444'960	-13'655'713
Genf	136'180'646	7'982'333	9'913'201	10'347'504
Jura	4'596'536	3'452'110	3'203'750	3'716'917
Schweiz	800'662'798	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 10: Veränderung Ausgleichszahlungen (in CHF), GLA

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	28'250'302	4'817'931	15'791'172	34'248'263
Luzern	6'080'440	-615'956	3'274'707	9'502'748
Uri	11'617'446	5'370'788	3'655'272	2'162'408
Schwyz	6'893'039	-1'340'314	-585'460	405'704
Obwalden	6'038'372	1'189'722	1'097'742	1'355'397
Nidwalden	1'312'660	343'300	447'638	719'399
Glarus	5'327'066	3'113'143	1'558'646	-186'688
Zug	-	-	-	-
Freiburg	8'585'987	-647'746	3'075'536	8'834'591
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	19'810'183	-11'328'247	-8'631'412	-7'627'087
Appenzell I.Rh.	8'677'500	-2'855'692	-1'001'754	1'109'813
St. Gallen	1'747'994	-177'074	941'407	2'731'833
Graubünden	136'612'253	4'840'594	-7'475'151	-24'450'725
Aargau	-	-	-	-
Thurgau	3'561'208	-360'755	1'917'939	5'565'594
Tessin	14'596'903	5'970'838	2'231'521	-1'976'178
Waadt	59'131	-37'254	-32'626	-36'424
Wallis	73'763'738	2'085'409	-7'106'991	-21'686'457
Neuenburg	22'993'344	-14'013'497	-12'554'636	-14'100'754
Genf	-	-	-	-
Jura	4'403'835	3'644'810	3'396'450	3'428'564
Schweiz	360'331'399	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 11: Veränderung Ausgleichszahlungen (in CHF), GLA 1

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	1'915'836	-1'207'029	-1'057'088	-1'180'132
Luzern	-	-	-	-
Uri	516'740	-325'560	-285'118	-318'306
Schwyz	2'498'233	-1'573'956	-1'378'433	-1'538'882
Obwalden	488'138	-307'540	-269'336	-300'687
Nidwalden	-	-	-	-
Glarus	-	-	-	-
Zug	-	-	-	-
Freiburg	1'925'361	-1'213'030	-1'062'343	-1'186'000
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	17'520'513	-11'038'403	-9'667'173	-10'792'427
Appenzell I.Rh.	5'219'242	-3'288'265	-2'879'785	-3'214'991
St. Gallen	-	-	-	-
Graubünden	39'175'414	-24'681'584	-21'615'548	-24'131'588
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	-	-	-	-
Waadt	59'131	-37'254	-32'626	-36'424
Wallis	28'950'969	-18'239'904	-15'974'076	-17'833'452
Neuenburg	20'914'979	-13'177'010	-11'540'114	-12'883'378
Genf	-	-	-	-
Jura	925'909	-583'348	-510'882	-570'349
Schweiz	120'110'466	-75'672'885	-66'272'523	-73'986'615

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 12: Veränderung Ausgleichszahlungen (in CHF), GLA 2

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	1'335'048	-538'313	-655'063	-789'060
Luzern	-	-	-	-
Uri	5'660'841	-2'282'544	-2'777'585	-3'345'757
Schwyz	2'095'068	-844'766	-1'027'980	-1'238'259
Obwalden	2'833'873	-1'142'664	-1'390'486	-1'674'919
Nidwalden	525'985	-212'086	-258'083	-310'876
Glarus	3'276'073	-1'320'967	-1'607'459	-1'936'275
Zug	-	-	-	-
Freiburg	-	-	-	-
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	191'768	-77'324	-94'094	-113'342
Appenzell I.Rh.	371'065	-149'620	-182'069	-219'313
St. Gallen	-	-	-	-
Graubünden	62'370'082	-25'148'645	-30'602'907	-36'862'919
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	9'985'263	-4'026'223	-4'899'434	-5'901'643
Waadt	-	-	-	-
Wallis	29'392'147	-11'851'398	-14'421'741	-17'371'796
Neuenburg	2'073'252	-835'969	-1'017'275	-1'225'365
Genf	-	-	-	-
Jura	-	-	-	-
Schweiz	120'110'466	-48'430'519	-58'934'177	-70'989'524

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 13: Veränderung Ausgleichszahlung (in CHF), GLA 3

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	20'990'875	-2'126'400	11'304'933	32'805'352
Luzern	6'080'440	-615'956	3'274'707	9'502'748
Uri	1'680'667	-170'254	905'147	2'626'611
Schwyz	1'721'808	-174'421	927'304	2'690'908
Obwalden	1'431'662	-145'029	771'042	2'237'457
Nidwalden	506'794	-51'339	272'941	792'037
Glarus	5'292	-536	2'850	8'271
Zug	-	-	-	-
Freiburg	6'114'145	-619'370	3'292'859	9'555'422
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	2'097'902	-212'520	1'129'855	3'278'682
Appenzell I.Rh.	2'692'792	-272'783	1'450'241	4'208'400
St. Gallen	1'747'994	-177'074	941'407	2'731'833
Graubünden	9'407'517	-952'992	5'066'551	14'702'431
Aargau	-	-	-	-
Thurgau	3'561'208	-360'755	1'917'939	5'565'594
Tessin	-	-	-	-
Waadt	-	-	-	-
Wallis	551'738	-55'892	297'146	862'277
Neuenburg	5'112	-518	2'753	7'990
Genf	-	-	-	-
Jura	1'459'287	-147'827	785'919	2'280'630
Schweiz	60'055'233	-6'083'666	32'343'597	93'856'642

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 14: Veränderung Ausgleichszahlungen (in CHF), GLA 4

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	4'008'543	8'689'674	6'198'389	3'412'104
Luzern	-	-	-	-
Uri	3'759'198	8'149'147	5'812'828	3'199'859
Schwyz	577'929	1'252'829	893'649	491'938
Obwalden	1'284'699	2'784'956	1'986'523	1'093'546
Nidwalden	279'882	606'724	432'780	238'238
Glarus	2'045'700	4'434'645	3'163'255	1'741'316
Zug	-	-	-	-
Freiburg	546'480	1'184'654	845'020	465'169
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	-	-	-	-
Appenzell I.Rh.	394'400	854'976	609'859	335'716
St. Gallen	-	-	-	-
Graubünden	25'659'240	55'623'816	39'676'753	21'841'351
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	4'611'639	9'997'061	7'130'955	3'925'465
Waadt	-	-	-	-
Wallis	14'868'884	32'232'602	22'991'680	12'656'513
Neuenburg	-	-	-	-
Genf	-	-	-	-
Jura	2'018'640	4'375'986	3'121'413	1'718'283
Schweiz	60'055'233	130'187'070	92'863'103	51'119'497

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 15: Veränderung Ausgleichszahlungen (in CHF), SLA A-C

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	7'854'095	9'981'785	13'373'521	-4'044'997
Bern	4'030'483	-4'030'483	-4'030'483	2'958'072
Luzern	-	-	-	-
Uri	-	-	-	-
Schwyz	-	-	-	-
Obwalden	-	-	-	-
Nidwalden	-	-	-	-
Glarus	-	-	-	-
Zug	463'744	1'639'445	2'503'273	-463'744
Freiburg	-	786'367	818'808	-
Solothurn	7'372'205	-592'470	-2'110'748	694'308
Basel-Stadt	41'775'402	-4'683'389	-5'415'120	1'053'704
Basel-Landschaft	-	-	-	442'096
Schaffhausen	1'197'608	-994'166	-836'579	172'683
Appenzell A.Rh.	-	-	-	-
Appenzell I.Rh.	-	-	-	-
St. Gallen	-	-	-	-
Graubünden	-	-	-	-
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	11'049'092	-7'503'966	-9'159'967	2'508'198
Waadt	96'582'070	5'386'345	4'147'318	-1'945'670
Wallis	11'274'094	928'729	643'210	-234'739
Neuenburg	14'735'852	-1'177'944	-1'890'325	445'040
Genf	97'026'920	452'446	2'149'791	-1'873'306
Jura	192'700	-192'700	-192'700	288'354
Schweiz	293'554'266	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 16: Veränderung Ausgleichszahlungen (in CHF), SLA F

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	81'763'873	-10'538'160	-10'782'400	-16'589'441
Bern	-	-	-	-
Luzern	-	-	-	-
Uri	-	-	-	-
Schwyz	-	-	-	-
Obwalden	-	-	-	-
Nidwalden	-	-	-	-
Glarus	-	-	-	-
Zug	-	367'540	278'587	-
Freiburg	-	-	-	-
Solothurn	-	-	-	-
Basel-Stadt	21'414'421	2'256'973	2'233'173	2'982'994
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	-	-	-	-
Appenzell I.Rh.	-	-	-	-
St. Gallen	-	-	-	-
Graubünden	-	-	-	-
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	-	-	-	-
Waadt	4'445'114	383'759	507'229	1'385'637
Wallis	-	-	-	-
Neuenburg	-	-	-	-
Genf	39'153'726	7'529'887	7'763'411	12'220'810
Jura	-	-	-	-
Schweiz	146'777'133	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

D. Alternativer Indikator für «Steilheit»

Für die Abbildung von geografisch-topografischen Sonderlasten wird als Indikator u.a. die Steilheit des produktiven Geländes verwendet. Aktuell wird der Indikator über die Medianhöhe des produktiven Geländes operationalisiert. Das BFS hat eine alternative Berechnungsmöglichkeit für die Steilheit des Geländes aufgezeigt. Gemäss Kurzbericht des BFS basiert diese auf der direkten Berechnung der Geländesteilheit unabhängig von der Höhenlage eines Gebiets.³¹ Im Rahmen des Auftrags haben wir geprüft, welche Auswirkungen die Verwendung des alternativen Indikators auf die Gewichtung der Indikatoren hat.

Über die konkreten Gewichte gibt die Tabelle 17 Auskunft. Zum Vergleich sind in der letzten Spalte wiederum die effektiven Gewichte der Indikatoren abgebildet. Dabei handelt es sich um die über die letzten vier Ausgleichsjahre gemittelten Gewichte.³² Pro Methode sind jeweils die Gewichte für den Mittelwert der Jahre 2017-2019 (2017-2019) und den Durchschnitt aus den Gewichten der Mittelwerte der Jahre 2015-2017, 2016-2018, 2017-2019 (Spalte *gemittelt*) aufgeführt. Im Vergleich zu den Ergebnissen mit dem aktuellen Indikator zur Abbildung der Steilheit des produktiven Geländes sind im Grossen und Ganzen keine grossen Unterschiede zu erkennen. Der alternative Indikator wird etwas weniger stark gewichtet als der aktuelle Indikator.

Tabelle 17: Gewichte der Indikatoren innerhalb der Indikatorengruppen (alternativer Indikator «Steilheit»)

Ausgleichsgefäss	Indikator	LASSO		Best Subset Selection		Quadratische Minimierung		Effektiv*
		2017-2019	gemittelt	2017-2019	gemittelt	2017-2019	gemittelt	
GLA	Siedlungshöhe	14.9%	10.9%	26.4%	15.5%	12.9%	14.5%	33,3%
	Steilheit	16.6%	16.6%	17.0%	17.8%	11.3%	9.9%	33,3%
	Siedlungsstruktur	6.5%	14.7%	27.0%	29.9%	41.4%	41.0%	16,7%
	Bevölkerungsdichte	62.0%	57.8%	29.5%	36.8%	34.4%	34.6%	16,7%
SLA A-C	Armut	56.1%	53.6%	40.2%	41.9%	47.1%	47.8%	45,8%
	Alter	4.9%	4.5%	7.1%	8.7%	11.8%	15.7%	14,9%
	Ausländerintegration	39.0%	41.9%	52.7%	49.4%	41.2%	36.5%	39,3%
SLA F	Bevölkerung	22.1%	21.1%	21.9%	24.8%	19.8%	19.8%	36,3%
	Beschäftigungsquote	30.9%	35.8%	40.8%	36.0%	22.8%	22.3%	25,9%
	Siedlungsdichte	47.0%	43.1%	37.3%	39.2%	57.4%	57.9%	37,9%

Anmerkungen: * Gewichte gemäss Methodenpapier der EFV («Gewichtung der Indikatoren im Lastenausgleich») vom 28. Oktober 2021, Tabelle 5 (Vierjahresmittel).

³¹ BFS (2017). Steilheit der Produktivfläche. Neue Berechnungsmöglichkeiten. (Der Kurzbericht und die Daten für den Indikator wurden von der EFV für die vorliegende Studie zur Verfügung gestellt.)

³² Da die Gewichte der Indikatoren im GLA in der FiLaV festgeschrieben sind, ist der Mittelwert im Prinzip nur für die Indikatoren des SLA relevant.

Werden die Gewichte aus Tabelle 17 (Spalte *gemittelt*) in der Simulation verwendet, zeigen sich über alle Ausgleichsgefässe des Lastenausgleichs betrachtet bei den Kantonen Graubünden und Tessin die grössten Unterschiede im Vergleich mit den Ergebnissen, die auf der Verwendung des bisherigen Indikators basieren. Vergleiche mit den Ausgleichszahlungen des Lastenausgleichs 2021 sind in Tabelle 18 bis Tabelle 25 im Anhang C.2 aufgeführt. Während der Kanton Tessin stark von der Verwendung des alternativen Indikators profitiert (im Vergleich zum Ausgleichsbetrag des Lastenausgleichs 2021 resultiert mit dem alternativen Indikator bspw. bei LASSO ein Plus von rund 10,5 Mio. CHF, bei der Verwendung des bisherigen Indikators ein Minus von rund 1,5 Mio. CHF), verliert der Kanton Graubünden (im Vergleich zum Ausgleichsbetrag des Lastenausgleichs 2021 resultiert mit dem alternativen Indikator bspw. bei LASSO ein Minus von rund 5,5 Mio. CHF, bei der Verwendung des bisherigen Indikators ein Plus von rund 4,8 Mio. CHF). Grund für diese Veränderungen liegen beim GLA 2. Bei Verwendung des bisherigen Indikators weist der Kanton Graubünden die mit Abstand höchsten massgebenden Sonderlasten auf. Mit der Verwendung des alternativen Indikators weist immer noch der Kanton Graubünden die höchsten massgebenden Sonderlasten auf, diese fallen allerdings deutlich tiefer aus, womit auch der Abstand zu den massgebenden Sonderlasten der anderen Kantone schrumpft. Das Gegenteil ist für den Kanton Tessin zu beobachten. Die massgebenden Sonderlasten steigen mit der Verwendung des neuen Indikators deutlich an, womit auch ein grösserer Anteil an der Dotation resultiert.

Tabelle 18: Veränderung Ausgleichszahlungen (in CHF), Total (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	89'617'968	-2'601'214	6'766'451	-20'210'701
Bern	32'280'785	739'647	15'153'627	35'115'631
Luzern	6'080'440	-725'555	4'837'087	8'860'086
Uri	11'617'446	6'627'663	3'749'861	2'672'706
Schwyz	6'893'039	-1'524'189	-260'856	240'820
Obwalden	6'038'372	1'268'761	1'127'665	1'215'767
Nidwalden	1'312'660	1'075'831	1'255'571	1'094'751
Glarus	5'327'066	4'370'162	1'980'483	488'195
Zug	463'744	1'572'642	2'837'496	-463'744
Freiburg	8'585'987	-301'947	5'004'399	8'410'554
Solothurn	7'372'205	-43'389	-2'306'850	678'944
Basel-Stadt	63'189'822	-1'789'743	-3'732'443	3'899'950
Basel-Landschaft	-	-	-	257'769
Schaffhausen	1'197'608	-982'127	-762'411	130'677
Appenzell A.Rh.	19'810'183	-12'224'486	-7'895'371	-7'032'436
Appenzell I.Rh.	8'677'500	-3'082'384	-387'814	1'116'678
St. Gallen	1'747'994	-208'581	1'390'557	2'547'082
Graubünden	136'612'253	-5'474'276	-22'333'502	-30'579'883
Aargau	-	-	-	-
Thurgau	3'561'208	-424'945	2'832'998	5'189'198
Tessin	25'645'995	10'547'318	3'278'693	6'513'700
Waadt	101'086'315	6'095'305	3'969'679	-199'312
Wallis	85'037'832	2'185'187	-11'535'624	-21'077'102
Neuenburg	37'729'196	-16'979'294	-15'177'518	-13'465'328
Genf	136'180'646	7'884'472	7'294'852	10'558'013
Jura	4'596'536	3'995'143	2'912'969	4'037'984
Schweiz	800'662'798	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 19: Veränderung Ausgleichszahlungen (in CHF), GLA (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	28'250'302	4'770'130	19'184'110	32'490'029
Luzern	6'080'440	-725'555	4'837'087	8'860'086
Uri	11'617'446	6'627'663	3'749'861	2'672'706
Schwyz	6'893'039	-1'524'189	-260'856	240'820
Obwalden	6'038'372	1'268'761	1'127'665	1'215'767
Nidwalden	1'312'660	1'075'831	1'255'571	1'094'751
Glarus	5'327'066	4'370'162	1'980'483	488'195
Zug	-	-	-	-
Freiburg	8'585'987	-674'937	4'494'511	8'410'554
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	19'810'183	-12'224'486	-7'895'371	-7'032'436
Appenzell I.Rh.	8'677'500	-3'082'384	-387'814	1'116'678
St. Gallen	1'747'994	-208'581	1'390'557	2'547'082
Graubünden	136'612'253	-5'474'276	-22'333'502	-30'579'883
Aargau	-	-	-	-
Thurgau	3'561'208	-424'945	2'832'998	5'189'198
Tessin	14'596'903	17'021'835	12'316'898	4'323'147
Waadt	59'131	-39'765	-31'632	-33'404
Wallis	73'763'738	1'195'887	-12'108'679	-20'901'405
Neuenburg	22'993'344	-16'138'994	-13'257'557	-13'881'007
Genf	-	-	-	-
Jura	4'403'835	4'187'844	3'105'670	3'779'122
Schweiz	360'331'399	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 20: Veränderung Ausgleichszahlungen (in CHF), GLA 1 (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	1'915'836	-1'288'382	-1'024'868	-1'082'286
Luzern	-	-	-	-
Uri	516'740	-347'503	-276'428	-291'915
Schwyz	2'498'233	-1'680'039	-1'336'418	-1'411'292
Obwalden	488'138	-328'268	-261'127	-275'757
Nidwalden	-	-	-	-
Glarus	-	-	-	-
Zug	-	-	-	-
Freiburg	1'925'361	-1'294'788	-1'029'963	-1'087'667
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	17'520'513	-11'782'384	-9'372'517	-9'897'616
Appenzell I.Rh.	5'219'242	-3'509'892	-2'792'009	-2'948'433
St. Gallen	-	-	-	-
Graubünden	39'175'414	-26'345'107	-20'956'707	-22'130'814
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	-	-	-	-
Waadt	59'131	-39'765	-31'632	-33'404
Wallis	28'950'969	-19'469'261	-15'487'187	-16'354'863
Neuenburg	20'914'979	-14'065'132	-11'188'371	-11'815'204
Genf	-	-	-	-
Jura	925'909	-622'665	-495'311	-523'061
Schweiz	120'110'466	-80'773'187	-64'252'538	-67'852'312

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 21: Veränderung Ausgleichszahlungen (in CHF), GLA 2 (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	1'335'048	-1'335'048	-1'335'048	-1'335'048
Luzern	-	-	-	-
Uri	5'660'841	-2'106'895	-1'854'757	-3'536'204
Schwyz	2'095'068	-1'065'778	-992'753	-1'479'733
Obwalden	2'833'873	-1'404'450	-1'303'038	-1'979'328
Nidwalden	525'985	445'191	514'092	54'608
Glarus	3'276'073	-680'665	-496'531	-1'724'474
Zug	-	-	-	-
Freiburg	-	-	-	-
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	191'768	-191'768	-191'768	-191'768
Appenzell I.Rh.	371'065	-225'065	-214'707	-283'783
St. Gallen	-	-	-	-
Graubünden	62'370'082	-41'367'117	-39'877'038	-49'813'986
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	9'985'263	5'634'288	6'742'434	-647'506
Waadt	-	-	-	-
Wallis	29'392'147	-15'984'837	-15'033'640	-21'376'922
Neuenburg	2'073'252	-2'073'252	-2'073'252	-2'073'252
Genf	-	-	-	-
Jura	-	-	-	-
Schweiz	120'110'466	-60'355'396	-56'116'006	-84'387'395

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 22: Veränderung Ausgleichszahlungen (in CHF), GLA 3 (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	20'990'875	-2'504'758	16'698'574	30'586'758
Luzern	6'080'440	-725'555	4'837'087	8'860'086
Uri	1'680'667	-200'547	1'336'997	2'448'976
Schwyz	1'721'808	-205'456	1'369'725	2'508'924
Obwalden	1'431'662	-170'835	1'138'910	2'086'140
Nidwalden	506'794	-60'474	403'163	738'472
Glarus	5'292	-632	4'210	7'712
Zug	-	-	-	-
Freiburg	6'114'145	-729'577	4'863'899	8'909'198
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	2'097'902	-250'334	1'668'914	3'056'948
Appenzell I.Rh.	2'692'792	-321'320	2'142'159	3'923'790
St. Gallen	1'747'994	-208'581	1'390'557	2'547'082
Graubünden	9'407'517	-1'122'561	7'483'829	13'708'120
Aargau	-	-	-	-
Thurgau	3'561'208	-424'945	2'832'998	5'189'198
Tessin	-	-	-	-
Waadt	-	-	-	-
Wallis	551'738	-65'837	438'916	803'962
Neuenburg	5'112	-610	4'067	7'449
Genf	-	-	-	-
Jura	1'459'287	-174'131	1'160'886	2'126'393
Schweiz	60'055'233	-7'166'152	47'774'890	87'509'209

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 23: Veränderung Ausgleichszahlungen (in CHF), GLA 4 (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	-	-	-	-
Bern	4'008'543	9'898'317	4'845'452	4'320'605
Luzern	-	-	-	-
Uri	3'759'198	9'282'608	4'544'048	4'051'849
Schwyz	577'929	1'427'084	698'590	622'921
Obwalden	1'284'699	3'172'314	1'552'920	1'384'712
Nidwalden	279'882	691'114	338'316	301'670
Glarus	2'045'700	5'051'458	2'472'804	2'204'956
Zug	-	-	-	-
Freiburg	546'480	1'349'427	660'575	589'024
Solothurn	-	-	-	-
Basel-Stadt	-	-	-	-
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	-	-	-	-
Appenzell I.Rh.	394'400	973'894	476'743	425'104
St. Gallen	-	-	-	-
Graubünden	25'659'240	63'360'509	31'016'414	27'656'797
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	4'611'639	11'387'548	5'574'464	4'970'653
Waadt	-	-	-	-
Wallis	14'868'884	36'715'821	17'973'232	16'026'418
Neuenburg	-	-	-	-
Genf	-	-	-	-
Jura	2'018'640	4'984'640	2'440'095	2'175'790
Schweiz	60'055'233	148'294'734	72'593'655	64'730'499

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

Tabelle 24: Veränderung Ausgleichszahlungen (in CHF), SLA A-C (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	7'854'095	8'272'435	13'435'274	-3'586'074
Bern	4'030'483	-4'030'483	-4'030'483	2'625'602
Luzern	-	-	-	-
Uri	-	-	-	-
Schwyz	-	-	-	-
Obwalden	-	-	-	-
Nidwalden	-	-	-	-
Glarus	-	-	-	-
Zug	463'744	1'256'405	2'559'778	-463'744
Freiburg	-	372'990	509'888	-
Solothurn	7'372'205	-43'389	-2'306'850	678'944
Basel-Stadt	41'775'402	-4'066'039	-5'234'661	912'364
Basel-Landschaft	-	-	-	257'769
Schaffhausen	1'197'608	-982'127	-762'411	130'677
Appenzell A.Rh.	-	-	-	-
Appenzell I.Rh.	-	-	-	-
St. Gallen	-	-	-	-
Graubünden	-	-	-	-
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	11'049'092	-6'474'517	-9'038'205	2'190'553
Waadt	96'582'070	5'663'651	3'854'146	-1'549'973
Wallis	11'274'094	989'300	573'055	-175'697
Neuenburg	14'735'852	-840'300	-1'919'961	415'679
Genf	97'026'920	74'775	2'553'131	-1'694'964
Jura	192'700	-192'700	-192'700	258'862
Schweiz	293'554'266	-	-	-

Quelle: EFV, eigne Berechnungen

Tabelle 25: Veränderung Ausgleichszahlungen (in CHF), SLA F (alternativer Indikator «Steilheit»)

Kanton	Referenz*	Veränderungen gegenüber «Referenz»**		
		lasso	select_cv	qmin
Zürich	81'763'873	-10'873'649	-6'668'823	-16'624'628
Bern	-	-	-	-
Luzern	-	-	-	-
Uri	-	-	-	-
Schwyz	-	-	-	-
Obwalden	-	-	-	-
Nidwalden	-	-	-	-
Glarus	-	-	-	-
Zug	-	316'236	277'719	-
Freiburg	-	-	-	-
Solothurn	-	-	-	-
Basel-Stadt	21'414'421	2'276'296	1'502'218	2'987'586
Basel-Landschaft	-	-	-	-
Schaffhausen	-	-	-	-
Appenzell A.Rh.	-	-	-	-
Appenzell I.Rh.	-	-	-	-
St. Gallen	-	-	-	-
Graubünden	-	-	-	-
Aargau	-	-	-	-
Thurgau	-	-	-	-
Tessin	-	-	-	-
Waadt	4'445'114	471'420	147'165	1'384'065
Wallis	-	-	-	-
Neuenburg	-	-	-	-
Genf	39'153'726	7'809'697	4'741'721	12'252'977
Jura	-	-	-	-
Schweiz	146'777'133	-	-	-

Quelle: EFV, eigne Berechnungen. Anmerkungen: * Lastenausgleich 2021. ** rot: Abnahme, blau: Zunahme.

E. Ergänzungen im Nachgang zur Fachgruppensitzung

Im Anschluss an die Diskussion des Schlussberichts (Stand: 5.5.2022) an der Sitzung der Fachgruppe Lastenausgleich vom 31. Mai 2022 wurde BSS gebeten, zu zwei Punkten auf Basis der bestehenden Ergebnisse weitere Abklärungen vorzunehmen:

- Einschätzung zur Bewertung der Modelle / Methoden bei Verwendung des alternativen Indikators für die Steilheit des Geländes
- Schätzung der absoluten Sonderlasten mit der Quadratischen Minimierung

E.1 Einschätzung zur Bewertung der Modelle / Methoden bei Verwendung des alternativen Indikators für die Steilheit des Geländes

Die «Güte» der Methoden kann u.a. anhand der drei Kriterien «Selektion der Indikatoren über die Zeit», «Variation der geschätzten Koeffizienten über die Zeit» und «Variation der relativen Wichtigkeit über die Zeit» (vgl. Tabelle 26) eingeschätzt werden.³³

Die Verwendung des alternativen Indikators für die Steilheit des Geländes führt

- bei allen Methoden zu einer Verbesserung in Bezug auf die Selektion der Indikatoren über die Zeit (die selektierten Indikatorteilmengen sind bei allen drei Methoden über die Zeit stabiler)
- bei der Best Subset Selection zu einer Verbesserung in Bezug auf die Variation der geschätzten Koeffizienten über die Zeit (d.h. weniger Variation / stabiler); keine Veränderung bzw. eine Verschlechterung (d.h. mehr Variation / weniger stabil) ergibt sich für Lasso bzw. die Quadratische Minimierung.
- bei der Best Subset Selection und bei der Quadratischen Minimierung zu einer Verbesserung in Bezug auf die Variation der relativen Wichtigkeit über die Zeit (d.h. weniger Variation / stabiler); eine Verschlechterung (d.h. mehr Variation / weniger stabil) ergibt sich für Lasso.

Die Verwendung des alternativen Indikators für die Steilheit des Geländes führt bei der Bewertung zu keiner anderen Schlussfolgerung in Bezug auf die Wahl der Methode. Die Best Subset Selection Methode schneidet weiterhin am besten ab. In Bezug auf das Kriterium der Variation der relativen Wichtigkeit über die Zeit klassiert sich Best Subset Selection neu vor Lasso (aber weiterhin hinter der Quadratischen Minimierung).

Für Best Subset Selection führt die Verwendung des alternativen Indikators für Steilheit in Bezug auf die drei Kriterien zur Bewertung der Robustheit der Ergebnisse zu einer Verbesserung (d.h. stabilere Ergebnisse). Das Ausmass der Verbesserung kann allerdings nicht quantifiziert werden.

³³ Weitere Kennzahlen haben wir in den Auswertungsskripts nicht als Output programmiert; diese liegen somit nicht vor.

Tabelle 26: Bewertung der Methoden bei Verwendung des alternativen Indikators für die Steilheit des Geländes

Kriterien	Lasso	Best Subset Selection	Quadratische Minimierung
Korrekte Abbildung der Sonderlasten (gegeben Rahmenbedingungen)	● ● ●	● ● ●	● ● ● *
Robustheit der Ergebnisse	●	● ● ●	●
<i>Selektion der Indikatoren über die Zeit</i>	2 (2)**	1 (1)	3 (3)
<i>Variation der geschätzten Koeffizienten über die Zeit</i>	2 (2)	1 (1)	3 (3)
<i>Variation der relativen Wichtigkeit über die Zeit</i>	3 (2)	2 (3)	1 (1)
Inhaltliche Plausibilität	● ● ●	● ● ●	● ● ●
Nachvollziehbarkeit	● ● ●	● ● ●	● ●
Aufwand	● ● ●	● ● ●	● ● ●

Anmerkungen: * Keine direkte Berechnung der Sonderlasten notwendig. ** Rang bei Verwendung des bisherigen Indikators für die Steilheit des Geländes in Klammern.

E.2 Schätzung der absoluten Sonderlasten mit der Quadratischen Minimierung

Mit der Quadratischen Minimierung werden die Gewichte der Indikatoren direkt geschätzt. Eine Abschätzung über die Berechnung der absoluten Sonderlasten ist nicht notwendig.

Wir sehen grundsätzlich zwei Möglichkeiten, die absoluten Sonderlasten nach der Schätzung der Koeffizienten mittels Quadratischer Minimierung zu berechnen:

- Naheliegender wäre es, mit den geschätzten Koeffizienten die Sonderlasten analog wie bei den beiden anderen Methoden in Schritt 3 zu berechnen. Problem: Für die Schätzung mittels Quadratischer Minimierung wurden die Nettoausgaben pro Kopf (abhängige Variable) standardisiert. Auf Grundlage der Ergebnisse liessen sich also die (erwarteten) standardisierten Nettoausgaben pro Kopf (bzw. Sonderlasten) berechnen, nicht aber die absoluten. Hierfür müssten die nicht-standardisierten Nettoausgaben pro Kopf verwendet werden. Wie in der Fussnote 14 (Seite 10) erwähnt, reagiert die Quadratische Minimierung in diesem Anwendungsfall sehr sensitiv auf die Spezifikation der Nettoausgaben pro Kopf. Werden die Nettoausgaben pro Kopf nicht standardisiert, ergeben sich fast ausnahmslos Randlösungen, d.h. der Koeffizient eines Indikators ist 1, die Koeffizienten der anderen Indikatoren sind entsprechend null. Diese Ergebnisse erachten wir als nicht plausibel.
- Als Alternative könnte die Quadratische Minimierung ebenfalls als Selektionsmethode verwendet werden. In einem zweiten Schritt würde wie bei den beiden anderen Methoden mit den Indikatoren, die Koeffizienten grösser Null aufweisen, ein lineares Regressionsmodell geschätzt. Das Vorgehen zur Berechnung der absoluten Sonderlasten wäre dann analog wie bei

den beiden anderen Methoden. Nachteil: Alle Nachteile der beiden anderen Methoden bei Schritt 3 (so ist nicht ausgeschlossen, dass gewisse Koeffizienten bei der Schätzung in der zweiten Stufe negative Werte annehmen). Die vorhandenen Ergebnisse lassen eine Abschätzung wie gerade skizziert nicht ohne weitere Arbeiten zu. Insbesondere müssten die Schritte 2 und 3 programmiert werden (dies ist momentan nicht der Fall).

F. Software

Die Schätzungen und Berechnungen haben wir in der Software R (R Core Team, 2021) mit RStudio (RStudio Team, 2021) durchgeführt. Für sämtliche Analysen nutzten wir die im {tidyverse} (Wickham et al., 2019) enthaltenen Pakete und Funktionen. Die R-Skripte wurden dem Auftraggeber übergeben.

Für die Berechnung rollierender Mittelwerte haben wir das Paket {zoo} verwendet (Zeileis & Grothendieck, 2005). Die Implementierung der Best Subset Selection beruht auf dem Paket {bestglm} (McLeod et al., 2020); für LASSO und Elastic Net haben wir das Paket {glmnet} (Friedman et al., 2010; Simon et al., 2011) verwendet, für die Implementierung der quadratischen Minimierungsmethode das Paket {quadprog} (Turlach et al., 2019). Die Erzeugung der Korrelationsmatrizen erfolgte mittels {corrplot} (Wei & Simko, 2021). Die Berechnung der Levenshtein-Distanz erfolgte mittels {stringdist} (Loo, 2014).

F.1 Software-Bibliographie

Friedman, J., Hastie, T., & Tibshirani, R. (2010). Regularization Paths for Generalized Linear Models via Coordinate Descent. *Journal of Statistical Software*, 33(1), 1–22.

Loo, M. P. J. van der. (2014). The stringdist package for approximate string matching. *The R Journal*, 6(1), 111–122.

McLeod, A. I., Xu, C., & Lai, Y. (2020). *bestglm: Best Subset GLM and Regression Utilities*. <https://CRAN.R-project.org/package=bestglm>

R Core Team. (2021). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. <https://www.R-project.org/>

RStudio Team. (2021). *RStudio: Integrated Development Environment for R*. RStudio, PBC. <http://www.rstudio.com/>

Simon, N., Friedman, J., Hastie, T., & Tibshirani, R. (2011). Regularization Paths for Cox’s Proportional Hazards Model via Coordinate Descent. *Journal of Statistical Software*, 39(5), 1–13.

Turlach, B. A., Weingessel, A., & Moler, C. (2019). *quadprog: Functions to Solve Quadratic Programming Problems*. <https://CRAN.R-project.org/package=quadprog>

Wei, T., & Simko, V. (2021). *R package „corrplot“: Visualization of a Correlation Matrix*. <https://github.com/taiyun/corrplot>

Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L. D., François, R., Golemund, G., Hayes, A., Henry, L., Hester, J., Kuhn, M., Pedersen, T. L., Miller, E., Bache, S. M., Müller, K., Ooms, J., Robinson, D., Seidel, D. P., Spinu, V., ... Yutani, H. (2019). Welcome to the tidyverse. *Journal of Open Source Software*, 4(43), 1686. <https://doi.org/10.21105/joss.01686>

Zeileis, A., & Grothendieck, G. (2005). zoo: S3 Infrastructure for Regular and Irregular Time Series. *Journal of Statistical Software*, 14(6), 1–27. <https://doi.org/10.18637/jss.v014.i06>

