



Universität für Bodenkultur Wien

Der Agrarstrukturwandel in Österreich unter der Berücksichtigung räumlicher Abhängigkeiten

Masterarbeit

zur Erlangung des akademischen Grades Diplom-Ingenieurin
im Rahmen des Studiums Agrar- und Ernährungswirtschaft

Eingereicht von: Laura ECKART
Matrikelnummer: 01340098
Email: laura.eckart@students.boku.ac.at

Betreuer:
Univ.-Prof. Dr. Jochen Kantelhardt
Dipl.-Ing. Dr. Andreas Niedermayr
Institut für Agrar- und Forstökonomie
Department für Wirtschafts- und Sozialwissenschaften

Wien, Dezember 2020



Eidesstattliche Erklärung

Ich erkläre eidesstattlich, dass ich die Arbeit selbstständig angefertigt habe. Es wurden keine als die angegebenen Hilfsmittel benutzt. Die aus fremden Quellen direkt oder indirekt übernommenen Formulierungen und Gedanken sind als solche kenntlich gemacht. Diese schriftliche Arbeit wurde noch an keiner Stelle vorgelegt.

Wien, Dezember 2020

Danksagung

An dieser Stelle möchte ich ein großes Dankeschön aussprechen an alle, die direkt oder indirekt dazu beigetragen haben, dass diese Arbeit entstehen konnte und ich mit dem Abschluss meines Studiums auf eine aufregende und schöne Studienzeit zurückblicken kann.

Insbesondere gilt mein großer Dank Herrn Dipl.-Ing. Dr. Andreas Niedermayr, der durch seine konstruktive Kritik und seine hilfreichen Anmerkungen von der Themenfindung bis zum Abschluss der Arbeit einen ganz wesentlichen Beitrag zu deren Entstehen geleistet hat. Ebenso gedankt sei an dieser Stelle Herrn Univ.-Prof. Dr. Jochen Kantelhardt in seiner Funktion als Hauptbetreuer meiner Masterarbeit.

Meiner lieben Familie, allen voran meinen Eltern Petra und Georg, aber auch meiner Oma Viktoria gilt ein weiteres, großes und herzliches Dankeschön. Euer fast blindes Vertrauen in mich und euer Glaube an meinen Erfolg über all die Jahre hinweg war die größte Motivation, ganz besonders in schwierigen Zeiten. Und nicht zuletzt wäre es mir ohne eure finanzielle Unterstützung nicht möglich gewesen, diesen Weg zu gehen. All den Menschen, die mich in meiner Studienzeit begleitet haben, sei es vom ersten Tag an, über Jahre, Monate oder auch nur ein paar Wochen hinweg, gilt ein weiterer Dank. Durch euch waren die letzten Jahre nicht nur lehrreich, sondern auch unglaublich bereichernd, aufregend und interessant. Ein besonderer Dank gilt auch meinem Partner Lukas, dich in diesen so herausfordernden Zeiten kennengelernt zu haben und an meiner Seite zu wissen ist wohl das größte Glück.

Zusammenfassung

Seit dem Jahr 1951 haben in Österreich mehr als 60% aller Landwirtinnen und Landwirte ihren Betrieb aufgegeben, gleichzeitig stieg die durchschnittliche Betriebsgröße um etwa 50%. Diesen Agrarstrukturwandel zu bremsen ist ein Ziel der Förderungen im Rahmen der gemeinsamen Agrarpolitik (GAP) der EU.

Der Agrarstrukturwandel wurde bereits vielfach anhand ökonometrischer Methoden untersucht. Bislang wurden dabei selten räumlich-ökonometrische Methoden angewandt, um räumliche Abhängigkeiten zu berücksichtigen. Studien aus Norwegen zeigen, dass Förderungen auf lokaler Ebene unter der Berücksichtigung nachbarschaftlicher Beziehungen den Agrarstrukturwandel beschleunigen, während sich auf der regionalen Ebene ein bremsender Effekt zeigt. Ob sich ähnliche Zusammenhänge in Österreich erkennen lassen, soll im Rahmen dieser Masterarbeit untersucht werden.

Auf Basis einer Literaturrecherche und explorativen Datenanalyse wurden wesentliche den Agrarstrukturwandel beeinflussende Faktoren ermittelt und deren Einfluss anhand von fixed-effects- sowie SLX-Modellen geschätzt. Letztere erlauben es, räumliche Abhängigkeiten zu schätzen. Herangezogen wurden Daten aus 2.066 Gemeinden im Zeitraum von 2003 bis 2017.

Die Ergebnisse der geschätzten Modelle lassen signifikante Abhängigkeiten in den Effekten auf den Agrarstrukturwandel erkennen. Die Effekte einiger Variablen variieren zwischen verschiedenen räumlichen Bezugsebenen deutlich. Der Einfluss der Zahlungen im Rahmen der 1. Säule der GAP wird in den fixed-effects-Modellen überschätzt. Ein Teil der Zahlungen bremst den Agrarstrukturwandel in den Gemeinden, unter Berücksichtigung von Nachbarschaftseffekten kehrt sich der Effekt um. Diese Zusammenhänge lassen sich nicht in ganz Österreich gleichermaßen erkennen. Während in den Flach- und Hügelländern signifikante räumliche Abhängigkeiten vorliegen, sind diese in den Hochalpen nicht signifikant. Offen bleibt, welche tatsächlichen Interaktionen diese räumlichen Abhängigkeiten verursachen.

Abstract

Since 1951 more than 60% of all farmers in Austria have given up farming, while at the same time the average farm size has increased by about 50%. Slowing down this agricultural structural change is one of the objectives of the subsidies within the Common Agricultural Policy (CAP) of the EU.

Agricultural structural change has already been examined many times using econometric methods. Until now, spatial econometric methods have rarely been used to take into account spatial dependence. Studies from Norway show that subsidies at the local level, taking into account spatial dependence, accelerate agricultural structural change, while at a higher, regional level there is a slowing effect. Whether similar relationships can be identified in Austria is investigated in the context of this master thesis.

A literature research and exploratory data analysis is used to identify the main factors influencing agricultural structural change and their influence is estimated using fixed-effects and SLX-models. The latter allow the estimation of spatial dependencies. The analysis is based on data from 2.066 municipalities in the period from 2003 to 2017.

The results indicate significant spatial dependencies in the effects on agricultural structural change. The effects of some variables vary significantly between different spatial reference levels. The influence of payments under the 1st pillar of the CAP is overestimated in the fixed-effects-models. Some of the payments slow down agricultural structural change in the municipalities, but when neighbourhood effects are considered, the effect is reversed. These correlations cannot be seen to the same extent throughout Austria. While there are significant spatial dependencies in the north and south-eastern countries, they are not significant in the high Alps. It remains unclear which actual interactions cause these spatial dependencies.

Inhalt

| | |
|---|-----------|
| 1. Einleitung | 1 |
| 2. Der Agrarstrukturwandel in der wissenschaftlichen Literatur | 5 |
| 2.1. Methodische Zugänge zur Untersuchung des Agrarstrukturwandels..... | 5 |
| 2.2. Räumliche Effekte im Agrarstrukturwandel..... | 7 |
| 2.3. Einflussfaktoren auf den Agrarstrukturwandel..... | 12 |
| 2.4. Wesentliche Indikatoren des Agrarstrukturwandels in Österreich..... | 22 |
| 3. Daten | 27 |
| 3.1. Abhängige Variablen..... | 27 |
| 3.2. Unabhängige Variablen..... | 28 |
| 3.3. Deskriptive Statistik..... | 33 |
| 4. Methoden | 35 |
| 4.1. Konzeptioneller Rahmen..... | 35 |
| 4.2. Lineare Regressionsmodelle..... | 37 |
| 4.2.1. Das OLS-Regressionsmodell..... | 37 |
| 4.2.2. Panelökonometrische Modelle..... | 38 |
| 4.3. Räumliche Regressionsmodelle..... | 41 |
| 4.3.1. Räumliche Autokorrelation und Nachbarschaft..... | 41 |
| 4.3.2. Das SLX-Modell..... | 45 |
| 4.4. Modellbildung und geschätzte Modelle..... | 46 |
| 5. Ergebnisse | 49 |
| 5.1. Räumlich-deskriptive Statistik und kartographische Darstellung..... | 49 |
| 5.2. Modellauswahl..... | 56 |
| 5.3. Modellergebnisse..... | 57 |
| 6. Diskussion | 67 |
| 6.1. Diskussion der Datengrundlage und Methode..... | 67 |
| 6.2. Diskussion der Ergebnisse..... | 70 |
| 6.3. Schlussfolgerungen und Ausblick..... | 77 |
| Literaturverzeichnis | 79 |
| Anhang | 84 |
| A. Kartographische Darstellungen..... | 84 |
| B. Weitere Ergebnistabellen..... | 87 |
| C. R-Code für das Schätzen der fixed-effects- und SLX-Modelle..... | 95 |

Tabellenverzeichnis

| | |
|--|----|
| Tabelle 1: Einflussfaktoren des Humankapitals auf den Agrarstrukturwandel | 15 |
| Tabelle 2: Einflussfaktoren der Betriebsstrukturen auf den Agrarstrukturwandel | 18 |
| Tabelle 3: Einflussfaktoren des Standortes auf den Agrarstrukturwandel | 20 |
| Tabelle 4: Einfluss von Agrarförderungen auf den Agrarstrukturwandel | 22 |
| Tabelle 5: Zusammenfassung der deskriptiven Statistik. | 34 |
| Tabelle 6: Ergebnisse der FE- und SLX-Modelle. | 58 |
| Tabelle 7: Ergebnisse der SLX-Modelle mit weiteren, räumlich verzögerten Variablen. Abhängige Variable: Anzahl an Betrieben je Gemeinde..... | 64 |
| Tabelle 8: Ergebnisse der SLX-Modelle mit weiteren, räumlich verzögerten Variablen. Abhängige Variable: durchschnittliche Betriebsgröße in ha je Gemeinde..... | 65 |
| Tabelle 9: SLX-Modelle für verschiedene Hauptproduktionsgebiete Österreichs..... | 66 |
| Tabelle 10: Ergebnisse der OLS—Regressionen aller Jahre des Beobachtungszeitraums 2003-2017), abhängige Variable: Anzahl Betriebe | 87 |
| Tabelle 11: Ergebnisse der OLS—Regressionen aller Jahre des Beobachtungszeitraums 2003-2017), abhängige Variable: durchschnittliche Betriebsgröße | 88 |
| Tabelle 12: Gepoolte OLS-Regressionen, abhängige Variable: Anzahl Betriebe..... | 89 |
| Tabelle 13: Gepoolte OLS-Regressionen, abhängige Variable: durchschnittliche Betriebsgröße... .. | 90 |
| Tabelle 14: Gepoolte OLS-Regressionen, abhängige Variable: Anzahl Betriebe..... | 91 |
| Tabelle 15: Gepoolte OLS-Regressionen, abhängige Variable: durchschnittliche Betriebsgröße... .. | 92 |
| Tabelle 16: Gepoolte OLS Regressionen mit ausgewählter Modellspezifikation | 93 |
| Tabelle 17: Random-effects-Modelle | 94 |

Abbildungsverzeichnis

| | |
|---|----|
| Abbildung 1: Theoretische Annahmen..... | 37 |
| Abbildung 2: Übersicht räumlich-ökonometrische Modelle..... | 44 |
| Abbildung 3: durchschnittliche Betriebsgrößen in ha je Gemeinde in den Jahren 2003 und 2017 | 50 |
| Abbildung 4: Veränderung der Betriebsanzahl in Prozent je Gemeinde 2003-2017 | 50 |
| Abbildung 5: durchschnittlicher Anteil an Biobetriebe (2003-2017) je Gemeinde | 51 |
| Abbildung 6: durchschnittlicher Anteil der Ackerflächen (2003-2017) an der LF je Gemeinde... | 52 |
| Abbildung 7: durchschnittliche GVE-Dichte je ha (2003-2017) je Gemeinde | 52 |
| Abbildung 8: Median der Seehöhe über NN je Gemeinde | 53 |
| Abbildung 9: durchschnittliche Summen (2003-2017) der Agrarförderungen 1. Säule GAP sowie OEPUL & AZ je ha je Gemeinde..... | 54 |
| Abbildung 10: local Moran's I | 55 |
| Abbildung 11: Durchschnittliches BIP p.P. (2003-2017) je Gemeinde in Tsd. €..... | 84 |
| Abbildung 12: Durchschnittliche EinwohnerInnendichte je km ² (2003-2017) je Gemeinde..... | 84 |
| Abbildung 13: Durchschnittliche Tourismusintensität (2003-2017) je Gemeinde..... | 85 |
| Abbildung 14: Durchschnittliche Summe Investitionsförderungen je Betrieb (2003-2017) je Gemeinde in Tsd. €..... | 85 |
| Abbildung 16: Hauptproduktionsgebiete in Österreich. | 86 |
| Abbildung 15: Durchschnittliche Summe der Förderungen zur ländlichen Entwicklung (Säule 2) je EinwohnerIn (2003-2017) je Gemeinde in Tsd. €..... | 86 |

Abkürzungsverzeichnis

| | |
|------------|--|
| ABM | agentbasiertes Modell (<i>Agent Based Model</i>) |
| AZ | Ausgleichszulage in Benachteiligten Gebieten |
| BAB | Bundesanstalt für Agrarwirtschaft und Bergbauernwirtschaft |
| BIP | Bruttoinlandsprodukt |
| BLUE | <i>best linear unbiased estimator</i> |
| BRP | Bruttoregionalprodukt |
| <i>Cov</i> | Kovarianz |
| <i>E</i> | Erwartungswert |
| EW | EinwohnerInnen |
| GAP | gemeinsame Agrarpolitik |
| GVE | Großvieheinheit |
| ha | Hektar |
| INVEKOS | Integriertes Verwaltungs- und Kontrollsystem |
| LAEDER | <i>Liaison entre actions de développement de l'économie rurale</i> |
| LF | landwirtschaftlich genutzte Fläche |
| LM | Lagrange-Multiplier |
| NN | Normalnull |
| NUTS | <i>Nomenclature des unités territoriales statistiques</i> – räumliche Bezugseinheiten der EU-Statistiken |
| OLS | <i>Ordinary Least Squares</i> |
| ÖPUL | Österreichisches Programm für umweltgerechte Landwirtschaft |
| SAC | <i>Spatial Autoregressive Combined-Model</i> |
| SLX | <i>Spatial Lag of X-Model</i> |
| SWM | räumliche Gewichtungsmatrix (<i>Spatial Weights Matrix</i>) |
| Tsd. | Tausend |
| ÜN | Übernachtungen |
| <i>Var</i> | Varianz |
| WTP | <i>Zahlungsbereitschaft (Willingness to Pay)</i> |

1. Einleitung

Ein Drittel der Fläche ist in Österreich durch überwiegend kleinstrukturierte Landwirtschaft geprägt und wird als Grün- oder Ackerland genutzt. Nur die Forstwirtschaft nimmt eine noch größere Fläche ein (vgl. UMWELTBUNDESAMT 2013, 246). Rund 433.000 landwirtschaftliche Betriebe bewirtschafteten diese Fläche im Jahr 1951 und prägten somit wesentlich das Landschaftsbild in Österreich. Bis zum Jahr 2016 ist die Anzahl dieser Betriebe auf rund 162.000 gesunken (vgl. BMNT 2018, 165). Rechnerisch haben damit etwa 63% aller Landwirtinnen und Landwirte ihren Betrieb aufgegeben. Gleichzeitig ging die landwirtschaftlich genutzte Fläche (LF) nicht im selben Ausmaß zurück, was zu einer steigenden durchschnittlichen Betriebsgröße führte. Im Jahr 1951 bewirtschaftete ein landwirtschaftlicher Betrieb rund 9,6 Hektar LF. Bis 2016 wuchs die durchschnittliche Betriebsgröße auf 19,8 Hektar LF an. Betriebe sind damit heute im Durchschnitt mehr als doppelt so groß wie 1951 (vgl. BMNT 2018, 165). Diese Entwicklungen sind Teil des landwirtschaftlichen Strukturwandels (vgl. SEHER 2004, 65), der im Folgenden als Agrarstrukturwandel bezeichnet wird.

Trotz des Agrarstrukturwandels sind noch immer über 90% der land- und forstwirtschaftlichen Betriebe Österreichs den bäuerlichen Familienbetrieben zuzuordnen. Sie können damit nach wie vor als tragendes Element der Landwirtschaft in Österreich, sowie in Europa insgesamt, bezeichnet werden (vgl. QUENDLER 2015, 55ff.). Mit bäuerlichen Familienbetrieben sind im Rahmen dieser Arbeit Betriebe gemeint, in denen Betrieb und Familie eine Einheit bilden und die sich im Besitz der Betriebsleiterin oder des Betriebsleiters befinden. Die Arbeitskraft wird für gewöhnlich von der Betriebsleiterin bzw. dem Betriebsleiter und mithelfenden Familienangehörigen gestellt, die Einkünfte aus der Landwirtschaft müssen nicht zwingend den Unterhalt der gesamten Familie sicherstellen (vgl. QUENDLER 2015, 43). Ihnen traut man eine besondere Leistungsfähigkeit in der Produktion hochwertiger Lebensmittel und ökologischer Güter zu. In der Gemeinsamen Agrarpolitik der EU (GAP) sind bäuerliche Familienbetriebe deshalb als agrarpolitisches und -strukturelles Leitbild zu erkennen und ihre Erhaltung ist eines der Hauptziele der gemeinsamen Agrarpolitik (GAP) der EU (vgl. QUENDLER 2015, 60f.).

Ob die aus der GAP hervorgehenden Zahlungen, beziehungsweise Agrarförderungen im Allgemeinen, an die Landwirtinnen und Landwirte dieses Ziel erreichen und inwiefern sie damit den Agrarstrukturwandel bremsen oder beschleunigen sowie welche weiteren Faktoren dabei eine Rolle spielen, wird in der wissenschaftlichen Literatur immer wieder diskutiert (z.B. WEISS 1999, KIRCHWEGER und KANTELHARDT 2015). Zur Erklärung des Agrarstrukturwandels werden neben Agrarförderungen (z.B. BREUSTEDT und GLAUBEN 2007, STORM und HECKELEI 2018) Eigenschaften des Humankapitals, der Betriebsstruktur sowie des sozioökonomischen und strukturellen Umfelds von Betrieben herangezogen (vgl. FERJANI et al. 2015, 62).

Darüber hinaus beeinflussen aber auch Wechselwirkungen zwischen benachbarten Betrieben die Entscheidungen von Landwirtinnen und Landwirten und damit indirekt auch den Agrarstrukturwandel. Die Entscheidung der Landwirtinnen und Landwirte, beispielsweise mehr LF zu bewirtschaften oder ihre Flächen gänzlich zu verpachten und damit den Betrieb aufzugeben, hängt auch von benachbarten Betrieben ab. Da es sich bei Boden um einen immobilien Produktionsfaktor handelt, werden die Preise für LF lokal durch die Zahlungsbereitschaften (WTP = *willingness to pay*) benachbarter Landeigentümerinnen und Landeigentümern und/oder Landwirtinnen und Landwirten bestimmt (vgl. HAPPE et al. 2006, 602). Die Zahlungsbereitschaften der Landwirtinnen und Landwirte wiederum hängen maßgeblich von den

Einleitung

jeweiligen Betriebscharakteristika, zum Beispiel von vorhandenem Kapital und damit auch von Agrarförderungen, ab. Somit sind Entscheidungen von Landwirtinnen und Landwirten nicht nur von den eigenen Voraussetzungen abhängig, sondern auch von denen benachbarter Betriebe (vgl. SAINT-CYR et al. 2019, 239). Es bestehen demnach räumliche Abhängigkeiten, welche die Betriebsgrößenentwicklung und damit auch die Ausstiegsrate, die beiden wesentlichen Indikatoren des Agrarstrukturwandels (vgl. WEISS 1999, 103), beeinflussen.

Diese räumlichen Abhängigkeiten können als nicht beobachtbare Variablen interpretiert werden. Sie nicht zu berücksichtigen, kann zu Verzerrungen in geschätzten Modellen führen (vgl. LESAGE und PACE 2009, 27f.). Mit der Verwendung räumlich-ökonomischer Modelle können räumliche Abhängigkeiten jedoch berücksichtigt und untersucht werden. Im Rahmen dieser Arbeit sollen diese Modelle verwendet werden, um räumliche Abhängigkeiten im Agrarstrukturwandel unter besonderer Berücksichtigung der Agrarförderungen im Rahmen der GAP zu untersuchen. STORM und HECKELEI (2014, 1) argumentieren, dass sich die Effekte dieser räumlichen Abhängigkeiten je nach räumlicher Ebene unterschiedlich auswirken. Sie erkennen, dass Direktzahlungen an Landwirtinnen und Landwirte in Norwegen auf regionaler Ebene das Wachstum von landwirtschaftlichen Betrieben begünstigen, beobachten jedoch auf lokaler Ebene einen gegenteiligen Effekt (vgl. STORM und HECKELEI 2018, 6).

Dies berücksichtigend lautet die erste Forschungsfrage der vorliegenden Arbeit: *Welche räumlichen Abhängigkeiten gibt es in den Effekten von Agrarsubventionen auf Wachstum und Ausstiegsrate von landwirtschaftlichen Betrieben in Österreich und wie unterscheiden sich diese zwischen lokaler und regionaler Ebene?* Die Rahmenbedingungen für die Landwirtschaft unterscheiden sich innerhalb Österreichs stark. Durch diese unterschiedlichen Bedingungen sind strukturelle Unterschiede in der Landwirtschaft zwischen verschiedenen Regionen Österreichs, beispielsweise zwischen dem Marchfeld und dem alpinen Raum, bedingt. Es wird vermutet, dass sich die unterschiedlichen topographischen Bedingungen auch auf die Nachbarschaftsbeziehungen auswirken und sich damit die räumlichen Abhängigkeiten innerhalb Österreichs unterscheiden. Die zweite Forschungsfrage lautet deshalb: *Unterscheiden sich diese Effekte, bedingt durch unterschiedliche topographische Bedingungen sowie unterschiedliche Wirtschafts- und Agrarstrukturen, zwischen verschiedenen Teilregionen Österreichs?*

Bislang sind ökonomische Studien, die sich mit räumlichen Abhängigkeiten im Agrarstrukturwandel auseinandersetzen rar (vgl. STORM et al. 2014, 1193), können aber erste Erkenntnisse über diese vermitteln. STORM et al. (2014) untersuchen, wie sich Direktzahlungen in Norwegen auf die Ausstiegsraten von landwirtschaftlichen Betrieben auswirken. In einem nicht-räumlichen Modell lassen sich Direktzahlungen als ein effektives Mittel zur Senkung der Ausstiegsraten von Betrieben identifizieren (vgl. STORM et al. 2014, 1199). Wird der Zusammenhang aber in einem räumlichen Modell untersucht, muss diese Aussage relativiert werden. Die Wahrscheinlichkeit, dass Betriebe aufgegeben werden, ist umso höher, je mehr Direktzahlungen nachbarschaftliche Betriebe erhalten (vgl. STORM et al. 2014, 1201). Dass mehr Agrarförderungen dazu führen, dass Ausstiegsrate und durchschnittliche Betriebsgröße steigen, konnte auch in den USA beobachtet werden (vgl. z.B. KEY und ROBERTS 2007b; ROBERTS und KEY 2008). STORM et al. (2014, 1202) erklären dies damit, dass Landwirtinnen und Landwirte dann einen größeren Anreiz haben, ihren Betrieb zu verpachten oder zu verkaufen, weil sie durch die geringere Wettbewerbsfähigkeit ihren benachbarten Betrieben gegenüber in ihren Wachstumsmöglichkeiten begrenzt werden.

Einleitung

STORM und HECKELEI (2018) gehen gegenüber STORM et al. (2014) noch einen Schritt weiter und berücksichtigen nicht nur eine, sondern zwei räumliche Ebenen bei der Untersuchung des Einflusses von Direktzahlungen auf den Agrarstrukturwandel in Norwegen. Indem sie einem Einflussfaktor zwei unterschiedliche räumliche Gewichtungsmatrizen zuordnen, sollen Verzerrungen durch unbeobachtete Variablen auf regionaler Ebene vermindert werden. Ihre Ergebnisse zeigen zum einen, dass so tatsächlich die Verzerrung der Ergebnisse durch unbeobachtete Variablen, die auf einer regionalen Ebene wirken, verringert werden kann. Zum anderen erkennen sie, dass Direktzahlungen auf lokaler Ebene das Wachstum von landwirtschaftlichen Betrieben reduzieren, auf regionaler Ebene jedoch ein gegenteiliger Effekt erkennbar wird (vgl. STORM und HECKELEI 2018, 6). Die Ergebnisse von STORM et al. (2014) sowie STORM und HECKELEI (2018) zeigen damit, dass Direktzahlungen in Norwegen unter Umständen die Wahrscheinlichkeit einer Aufgabe von landwirtschaftlichen Betrieben sogar erhöhen, obwohl es deren Ziel ist, das Weiterbestehen möglichst vieler landwirtschaftlicher Betriebe zu sichern (vgl. STORM und HECKELEI 2018, 1192).

Den Agrarstrukturwandel in Österreich analysierte beispielsweise WEISS (1999) am Beispiel Oberösterreichs mittels ökonomischer Methoden. Er untersuchte unterschiedliche Einflussfaktoren hinsichtlich ihrer Bedeutung für das Betriebswachstum und die Ausstiegsrate. Er stellt beispielsweise fest, dass Betriebe meist entweder ihre Betriebsgröße reduzieren um nicht-landwirtschaftlichen Nebentätigkeiten nachzugehen oder deutlich wachsen (vgl. WEISS 1999, 114). Weder räumliche Abhängigkeiten noch Agrarförderungen wurden jedoch dabei berücksichtigt. KIRCHWEGER und KANTELHARDT (2015, 86) untersuchen den Agrarstrukturwandel in Österreich im Hinblick auf die Bedeutung der Effekte von staatlich gestützten Investitionen. Sie zeigen, dass diese das Betriebswachstum signifikant positiv beeinflussen, berücksichtigen jedoch ebenfalls keine räumlichen Zusammenhänge. Weitere Studien zum Agrarstrukturwandel in Österreich befassen sich unter anderem mit den Ursachen für Betriebsaufgaben (z.B. GROIER 2004), Diversifizierungstendenzen (z.B. KIRNER 2019) oder der Dynamik des Strukturwandels in einzelnen Zweigen der Landwirtschaft wie etwa der Milchwirtschaft (z.B. KIRNER 2004).

Die Entwicklung der Betriebszahlen sowie der durchschnittlichen Betriebsgrößen in Österreich wurde bislang noch nicht unter der Verwendung von räumlicher Ökonometrie untersucht. Da sich hieraus aber auch neue Erkenntnisse über die Wirksamkeit von Agrarsubventionen ableiten lassen können (vgl. STORM et al. 2014, 1202 f.) ist es das Ziel dieser Arbeit, den Einfluss von Agrarsubventionen auf den Agrarstrukturwandel zu untersuchen. STORM und HECKELEI (2018) sowie STORM et al. (2014) konnten für ihre Analysen auf Daten auf Betriebsebene zurückgreifen. Im Rahmen der vorliegenden Arbeit werden auf Gemeindeebene aggregierte Daten verwendet. Rückschlüsse auf einzelbetriebliches Verhalten sind deshalb nicht möglich (vgl. OPENSHAW 1984, 26), jedoch kann untersucht werden, ob sich die vermuteten räumliche Effekte bereits auf Basis räumlich aggregierter Daten beobachten lassen. Sowohl STORM und HECKELEI (2018) als auch STORM et al. (2014) untersuchen die räumlichen Effekte für das Land Norwegen insgesamt und unterscheiden nicht zwischen verschiedenen Teilregionen. Sie nehmen damit an, dass die beobachteten Effekte in ganz Norwegen gleichermaßen wirken. Im Rahmen dieser Arbeit sollen die räumlichen Effekte auch für verschiedene Teilregionen Österreichs getrennt untersucht werden (Forschungsfrage 2). Dies erlaubt Rückschlüsse darüber, ob die beobachteten räumlichen Effekte in ganz Österreich den gleichen Einfluss haben, oder ob sie sich regional unterscheiden.

In Kapitel **Fehler! Verweisquelle konnte nicht gefunden werden.** wird zunächst ein Überblick über in Frage kommende Methoden, anhand derer der Agrarstrukturwandel in der Wissenschaft

Einleitung

untersucht wird, gegeben. Im Anschluss daran werden insbesondere jene Methoden näher betrachtet, die das Berücksichtigen von räumlichen Effekten erlauben. Ein Überblick über die in der Literatur zur Erklärung des Agrarstrukturwandels häufig herangezogenen Variablen legt dann die Basis für die später zu treffende Auswahl der erklärenden Variablen im Rahmen dieser Arbeit. In einem weiteren Unterkapitel ist die Entwicklung des Agrarstrukturwandels in Österreich kurz dargestellt. Kapitel 3 widmet sich der Auswahl und Aufbereitung der erklärenden und erklärten Variablen des Modells. Nach einer konzeptionellen und theoretischen Einführung werden in Kapitel 4 die in dieser Arbeit verwendeten Modelle vorgestellt. In Kapitel 5 werden die Ergebnisse der Berechnungen vorgestellt und in Kapitel 6 diskutiert, wobei auch Bezug auf die in Kapitel 2 vorgestellte Literatur genommen werden soll.

2. Der Agrarstrukturwandel in der wissenschaftlichen Literatur

2.1. Methodische Zugänge zur Untersuchung des Agrarstrukturwandels

Im Rahmen der vorliegenden Arbeit wird der Agrarstrukturwandel in Österreich anhand quantitativer Methoden untersucht. Zwar gibt es auch zahlreiche qualitative Studien zum Agrarstrukturwandel (z.B. GROIER 2004), der Fokus liegt deshalb im Folgenden jedoch auf quantitativen Studien. Nach ZIMMERMANN et al. (2009, 602) lassen sich zwei methodische Zugänge unterscheiden, anhand derer der Agrarstrukturwandel quantitativ untersucht werden kann. Zum einen sind dies Simulationsmodelle, insbesondere agentenbasierte Modelle (ABM = *agent-based-models*). Zum anderen ökonomische Modelle, wie sie auch im Rahmen dieser Arbeit angewendet werden sollen.

Ein ABM besteht aus drei Komponenten: den Individuen (Agenten), ihrer Umwelt, sowie Regeln, die Beziehungen definieren. Die Agenten treffen Entscheidungen autonom und interagieren in ihrer Umgebung mit anderen Agenten. Es werden Regeln festgelegt, die einerseits die Beziehungen zwischen den Agenten und zwischen den Agenten und ihrer Umgebung festlegen sowie andererseits Regeln, die die Reihenfolge von Aktionen festlegen (vgl. PARKER et al. 2002, 1). Globale Gleichgewichtsbedingungen kommen nicht zum Tragen. Dadurch wird, anders als beispielsweise bei ökonomischen Modellen, eine top-down-Perspektive vermieden und bottom-up modelliert (vgl. ZIMMERMANN et al. 2009, 612).

Dies bringt verschiedene Vorteile mit sich, die ABMs auch für die Untersuchung des Agrarstrukturwandels interessant machen (vgl. ZIMMERMANN et al. 2009, 612). Da Agenten, Umwelt und Beziehungsregeln von den Forscherinnen und Forschern selbst festgelegt werden, sind ABMs sehr flexibel und lassen sich auch experimentell einsetzen. Durch die im Vorhinein festgelegten Entscheidungsregeln der Agenten entwickeln sich diese selbstständig in ihren Eigenschaften weiter und es bildet sich ein komplexes System. Auch die Geschwindigkeit dieser Entwicklung wird nicht von der Forscherin beeinflusst. Dies macht es möglich, systemimmanente Eigenschaften zu ermitteln, welche den Agrarstrukturwandel entweder beschleunigen oder bremsen (vgl. ZIMMERMANN et al. 2009, 612).

ZIMMERMANN et al. (2009, 612) zeigen auch Nachteile von ABMs auf. Ein Wesentlicher ist die Gefahr der Überspezifikation, da die Forscherin versucht sein könnte, ein möglichst realitätsnahes Modell zu entwickeln. Aus der Komplexität von ABMs ergibt sich auch, dass die statistische Validierung von ABMs nicht ausreichend möglich ist, da grundlegende Mechanismen im Entscheidungsprozess nicht beobachtbar sind (vgl. PARKER et al. 2002, 83). Ein weiteres Problem stellt die Datenverfügbarkeit dar, denn Daten auf Betriebsebene aus bestimmten Regionen sind nur selten verfügbar (vgl. ZIMMERMANN et al. 2009, 612). Meist sind Daten nur auf einer räumlich aggregierten Ebene verfügbar, wie auch der in dieser Arbeit verwendete Datensatz.

AgriPoliS (*Agricultural Policy Simulator*) ist ein Beispiel für die Anwendung eines ABM zur Untersuchung des Agrarstrukturwandels. Es simuliert den Effekt unterschiedlicher Politiken auf den Agrarstrukturwandel (vgl. HAPPE et al. 2008, 432). Eine regionale Landwirtschaftsstruktur setzt sich dabei aus drei Komponenten zusammen: den landwirtschaftlichen Betrieben in der Region, der Landschaft, in der sich diese befinden, sowie den Märkten für In- und Outputs. Jeder Betrieb in der Region ist durch einen Agenten repräsentiert und mit einem Verhaltensmodell ausgestattet, welches sich auch nach den Betriebseigenschaften wie dem Alter der

Betriebsleiterin oder des Betriebsleiters richtet. Es werden Wechselwirkungen zwischen Agenten, zwischen Komponenten sowie zwischen Komponenten und Agenten simuliert. Auch technologischer Fortschritt sowie politische Veränderungen werden berücksichtigt (vgl. HAPPE et al. 2006, s.p.). AgriPoliS erlaubt dadurch Rückschlüsse auf strukturelle, allokativen und distributive Effekte durch die Veränderung politischer Rahmenbedingungen auf den Agrarstrukturwandel in einer Region. Auch der Effekt unterschiedlicher Politiken auf die Verteilung der landwirtschaftlichen Betriebe auf verschiedene Größenklassen kann abgeschätzt werden (vgl. HAPPE et al. 2008, 432).

Die Entwicklung der Betriebsgrößen sowie anderer Indikatoren des Strukturwandels kann, neben anderen Modellen, auch mittels ökonomischer Modelle untersucht werden. Im Folgenden wird nur jene Literatur betrachtet, die sich mit der Betriebsgrößenentwicklung oder der Entwicklung der Anzahl an Betrieben in der Landwirtschaft (bzw. der Entscheidung, den Betrieb aufzugeben) als abhängige Variablen auseinandersetzen. Welches ökonomische Modell angewandt wird, hängt unter anderem ab von der Datenstruktur (z.B. Querschnittsdaten, Paneldaten), der zu untersuchenden abhängigen Variable (z.B. Betriebswachstum, Betriebsaufgabeentscheidung) sowie der Ebene, auf der Daten zur Verfügung stehen (z.B. auf Betriebsebene oder aggregiert auf Gemeindeebene).

Liegen Daten auf Betriebsebene vor, wird häufig als abhängige Variable die Entscheidung, einen Betrieb aufzugeben oder weiterzuführen untersucht. Es handelt dann um eine diskrete abhängige Variable mit zwei möglichen Ausprägungen, die mit Logit- oder Probit-Modellen untersucht werden kann (z.B. AUBERT und PERRIER-CORNET 2009, FERJANI et al. 2015, KEY und ROBERTS 2007b, SAINT-CYR et al. 2019, STORM et al. 2014). Dabei wird beispielsweise das Ergebnis „Landwirtin oder Landwirt gibt Betrieb auf“ mit 0 und das Gegenereignis, „Landwirtin oder Landwirt führt Betrieb weiter“, mit 1 kodiert (vgl. FERJANI et al. 2015, 64). Damit die abhängige Variable nur einen Wert zwischen 0 und 1 annehmen kann, wird die Funktion der unabhängigen Variablen entsprechend transformiert. Im Falle des Logit-Modells wird die logistische Verteilung, im Falle des Probit-Modells die Normalverteilung herangezogen (vgl. WOOLDRIDGE 2020 561).

Logit-Modelle werden mitunter auch verwendet, wenn die Betriebsgröße als abhängige Variable herangezogen wird (z.B. AKIMOWICZ et al. 2013, BARTOLINI und VIAGGI 2013). Sie können so transformiert werden, dass diskrete abhängige Variablen mit mehr als zwei Ausprägungen untersucht werden können. Es handelt sich dann um multinomiale Logit-Modelle (vgl. GREENE 2012 803f.). AKIMOWICZ et al. (2013) untersuchen mit solch einem Modell den Effekt von betriebseigenen Eigenschaften, den Eigenschaften der Landwirtin oder des Landwirts sowie Standortfaktoren darauf, ob sich die landwirtschaftliche Fläche eines Betriebes vergrößert hat, verkleinert hat oder konstant geblieben ist (vgl. AKIMOWICZ et al. 2013, 264), BARTOLINI und VIAGGI (2013) gehen ähnlich vor.

Logit- bzw. Probit-Modelle eignen sich also zur Analyse des Agrarstrukturwandels, jedoch nur, wenn Daten auf Betriebsebene zur Verfügung stehen. Da im Rahmen dieser Arbeit nur Daten auf Gemeindeebene verwendet werden können, müssen andere Methoden gewählt werden. Liegen Querschnittsdaten auf einer räumlich aggregierten Ebene vor, werden häufig einfache Regressionsanalysen durchgeführt, wie in Kapitel 4.2.1 erläutert (z.B. BREUSTEDT und GLAUBEN 2007, GLAUBEN et al. 2006, NIEDERMAYR et al. 2015). BREUSTEDT und GLAUBEN (2007) beispielsweise regressieren die Ausstiegsrate in 110 Regionen in Westeuropa auf unabhängige Variablen wie Alter der Betriebsleiterin bzw. des Betriebsleiters oder Arbeitslosenrate in der Region mittels Methode der gewöhnlichen kleinsten Quadrate (vgl. BREUSTEDT und GLAUBEN 2007, 116 ff.).

Eine Methode, welche häufig zum Einsatz kommt, wenn räumlich aggregierte Paneldaten vorliegen ist die Markov-Kette (z.B. BEN ARFA et al. 2015, STORM und HECKELEI 2015, ZIMMERMANN und HECKELEI 2012). In Markov-Ketten wird der Übertritt eines landwirtschaftlichen Betriebes von einer Kategorie in eine andere Kategorie (z.B. von einer Betriebsgrößenkategorie in die nächsthöhere) als stochastischer Prozess betrachtet. Jeder mögliche Übertritt von einer Kategorie in eine andere ist gekennzeichnet durch eine Übertrittswahrscheinlichkeit. Die Anzahl an landwirtschaftlichen Betrieben n in einer Kategorie j im Jahr t ergibt sich dann aus der Anzahl der Betriebe in allen Kategorien i im Vorjahr $t - 1$ multipliziert mit der Übertrittswahrscheinlichkeit p_{ij} (vgl. GOCHT et al. 2012, 127). In einer stationären Markov-Kette bleiben die Übertrittswahrscheinlichkeiten über alle Zeitpunkte hinweg gleich, eine nicht-stationäre Markov-Kette erlaubt über die Zeit variable Übertrittswahrscheinlichkeiten (vgl. GOCHT et al. 2012, 128).

ZIMMERMANN und HECKELEI (2012) ermitteln die Übertrittswahrscheinlichkeiten zwischen vier Betriebsgrößenkategorien von Milchbetrieben sowie einer Kategorie für *exit* (= Betrieb wurde aufgegeben). Anschließend wird der Effekt verschiedener unabhängiger Variablen wie Milchpreis oder Bevölkerungsdichte in der Region auf die Übertrittswahrscheinlichkeiten mittels Regression bestimmt (vgl. ZIMMERMANN und HECKELEI 2012, 584ff.). Sie können so feststellen, ob bestimmte unabhängige Variablen einen positiven oder negativen Effekt auf die Wahrscheinlichkeit des Übertritts beispielsweise von Betriebsgrößenkategorie 1 in Kategorie 2 haben.

Um Markov-Ketten anwenden zu können, muss jedoch die Betriebsgrößenstruktur bekannt sein. Der für diese Arbeit verwendete Datensatz gibt jedoch lediglich Aufschluss über die durchschnittliche Betriebsgröße in jeder Gemeinde und beinhaltet keine Informationen zur Verteilung über verschiedene Größenklassen. Markov-Ketten können deshalb nicht zur Anwendung kommen.

2.2. Räumliche Effekte im Agrarstrukturwandel

Es können zwei Arten von räumlichen Effekten, welche sich auf den Agrarstrukturwandel auswirken, unterschieden werden: räumliche Heterogenität und räumliche Abhängigkeiten (vgl. ANSELIN 2001, 311). Räumliche Heterogenität entsteht durch räumlich nicht konstante Variablen, wie beispielsweise jährliche Niederschlagssummen. Räumliche Abhängigkeiten hingegen entstehen durch die Wechselwirkungen zwischen sich in räumlicher Nähe befindlichen landwirtschaftlichen Betrieben (vgl. SCHMIDTNER et al. 2012, 665). In zahlreichen wissenschaftlichen Arbeiten werden die Regionen, in welchen sich Betriebe befinden, als Dummy-Variable berücksichtigt oder regionale Charakteristika wie die Arbeitslosenquote als erklärende Variablen miteinbezogen (siehe Kapitel 2.3) und somit ein Teil der regionalen Heterogenität berücksichtigt.

SAINT-CYR et al. (2019) erkennen in der Literatur zwei Klassen von räumlichen Abhängigkeiten, die zwischen benachbarten Betrieben entstehen können. Einerseits stehen landwirtschaftliche Betriebe im Wettbewerb, vor allem um landwirtschaftlich nutzbaren Boden und beeinflussen sich so in ihren Handlungsmöglichkeiten. Andererseits können benachbarte Betriebe aber auch als Vorbild und Motivations- sowie Informationsquelle für die Adoption von Produktionsalternativen wirken (vgl. SAINT-CYR et al. 2019, 240). Beide Klassen von Interaktionen werden, wie der Agrarstrukturwandel im Allgemeinen, mittels ABM (z.B. BERGER 2001, BALMANN 1997) oder ökonometrischen Modellen (z.B. LÄPPLE und KELLEY 2015, STORM und HECKELEI 2018) untersucht. Vor allem in ABMs wurden bislang räumliche Effekte bedingt durch die Immobilität des Bodens,

die räumliche Lage von Betrieben und die Wechselwirkungen zwischen benachbarten Betrieben über den Wettbewerb um nutzbaren Boden berücksichtigt. Ökonometrische Methoden hierzu sind bislang rar (vgl. STORM et al. 2014, 1193). Da ABM aus den in Kapitel 2.1 genannten Gründen als Methode für diese Arbeit nicht in Frage kommt, liegt der Fokus im Folgenden auf der Analyse jener Literatur, die räumliche Abhängigkeiten in ökonometrischen Modellen berücksichtigt.

Räumliche Effekte auf die Adoption von Produktionsalternativen

Befinden sich landwirtschaftliche Betriebe in unmittelbarer Nähe, äußern sich räumliche Abhängigkeiten durch ähnliches Entscheidungsverhalten unter Landwirtinnen und Landwirten, wenn diese nicht als Konkurrenten, sondern Motivations- und Informationsquelle gesehen werden. Die Kommunikation untereinander führt unter anderem zu steigendem Bewusstsein oder sich ändernden Präferenzen für Produktionsalternativen wie beispielsweise der biologischen Landwirtschaft (zertifiziert biologische Landwirtschaft im Sinne der EU-Bio-Verordnung) (vgl. LÄPPLÉ und KELLEY 2015, 316). Zunehmende Spezialisierung ist ein weiteres Phänomen des Agrarstrukturwandels (vgl. NEUENFELDT et al. 2019, 714). In der wissenschaftlichen Literatur wird häufig die Spezialisierung auf die biologische Produktion unter der Berücksichtigung von den genannten räumlichen Abhängigkeiten untersucht. LÄPPLÉ und KELLEY (2015) untersuchen auf Basis von Daten auf Betriebsebene, ob räumliche Abhängigkeiten und sogenannte Spill-Over-Effekte bei der Einführung der biologischen Produktion unter rinder- und/oder schafhaltenden Betrieben (ohne Milchvieh) in Irland bestehen. Sie gehen davon aus, dass der Betrieb dann auf biologische Landwirtschaft umgestellt wird, wenn sich daraus ein größerer Nutzen als aus der konventionellen Produktion erwartet wird. Findet Kommunikation statt, wird dieser Nutzen auch vom Nutzen benachbarter Landwirtinnen und Landwirte beeinflusst, wodurch räumliche Abhängigkeiten entstehen. Darüber hinaus gibt es möglicherweise aber weitere räumliche Effekte durch unbeobachtete und räumlich korrelierte Variablen. Ein ökonometrisches Modell, welches beide Effekte berücksichtigt, soll deshalb angewandt werden (vgl. LÄPPLÉ und KELLEY 2015, 316ff.).

Im Modell von LÄPPLÉ und KELLEY (2015, 318) ist die abhängige Variable dabei der Nutzen der biologischen Produktion minus dem Nutzen der konventionellen Produktion. Ist das Ergebnis größer Null, wird sich die Landwirtin oder der Landwirt dazu entscheiden, auf die biologische Produktion umzusteigen (vgl. LÄPPLÉ und KELLEY 2015, 318). LÄPPLÉ und KELLEY verwenden ein bayesianisches räumliches Durbin Probit-Modell. Dieses berücksichtigt, unter der Verwendung einer räumlichen Gewichtungsmatrix, die Entscheidung zur Umstellung benachbarter Betriebe, die Eigenschaften des Betriebes selbst sowie die räumlich gewichteten Eigenschaften benachbarter Betriebe (vgl. LÄPPLÉ und KELLEY 2015, 320). Durch dieses Modell können sogenannte räumliche Spill-Over-Effekte beobachtet werden. Sie können berechnet werden, indem die direkten Effekte der Veränderung einer Variable auf einen Betrieb i vom Gesamteffekt der Veränderung einer Variable auf alle Betriebe abgezogen werden (vgl. LÄPPLÉ und KELLEY 2015, 323). Die Ergebnisse der Studie zeigen, dass Spill-Over-Effekte zwar existieren, jedoch klein sind und mit zunehmender Distanz zwischen den Betrieben abnehmen. Beispielsweise stellen LÄPPLÉ und KELLEY (2015, 328) fest, dass Betriebe in der Umgebung von intensiv geführten Betrieben ihren Betrieb weniger wahrscheinlich auf die biologische Produktion umstellen. Kennt eine Landwirtin oder ein Landwirt einen anderen, biologisch bewirtschafteten Betrieb, erhöht sich die Wahrscheinlichkeit, selbst den Betrieb umzustellen um 10,9% und die der benachbarten Landwirtinnen und Landwirte um 1,7% (Spill-Over-Effekt). Auch wenn eine Landwirtin oder ein Landwirt ihr bzw. sein Umweltbewusstsein erhöht, steigt damit die Wahrscheinlichkeit, dass benachbarte Betriebe auf die biologische Produktion umstellen (vgl. LÄPPLÉ und KELLEY 2015,

330). LÄPPLÉ und KELLEY (2015) können damit bestätigen, dass räumliche Abhängigkeiten bei der Einführung der biologischen Produktion bestehen.

Ebenfalls mit räumlichen Abhängigkeiten bezüglich der biologischen Produktionsweise setzen sich SCHMIDTNER et al. (2012) auseinander. Sie untersuchen die Verteilung der biologischen Landwirtschaft in Deutschland auf räumliche Abhängigkeiten und verwenden auf Kreisebene aggregierte Daten. Ihre Hypothese ist, dass neben klassischen Standortfaktoren auch Agglomerationseffekte einen Effekt auf die Verteilung biologischer Landwirtschaft haben und räumliche Abhängigkeiten existieren (vgl. SCHMIDTNER et al. 2012, 662f.). Dabei vermuten sie bei den meisten Variablen räumliche Heterogenität sowie bei manchen auch räumliche Abhängigkeit (vgl. SCHMIDTNER et al. 2012, 665ff.) Beides wird durch die Verwendung des SAC (*spatial autoregressive combined*)-Modells berücksichtigt. Auch sie kommen zu dem Ergebnis, dass räumliche Abhängigkeiten existieren. Steigt der Anteil biologisch wirtschaftender Betriebe in einer Region um einen Prozentpunkt, steigt jener in der Nachbarregion um 0.44 Prozentpunkte (vgl. SCHMIDTNER et al. 2012, 678).

In ihrer Arbeit verwenden SCHMIDTNER et al. (2012) auf regionaler Ebene aggregierte Daten. SCHMIDTNER et al. (2015) argumentieren, dass die Ergebnisse je nach gewählter räumlicher Auflösung unterschiedlich ausfallen könnten und untersuchen in einer weiteren Studie räumliche Abhängigkeiten im biologischen Landbau in Süddeutschland auf zwei unterschiedlichen räumlichen Ebenen (vgl. SCHMIDTNER et al. 2015, 175ff.). Sie verwenden dasselbe räumlich-ökonomische Modell wie SCHMIDTNER et al. (2012) und wenden dies für Daten auf Kreis- sowie Gemeindeebene an. Sie kommen zu dem Schluss, dass die Verwendung von aggregierten Daten das Ergebnis der räumlichen Analyse nicht verzerrt. Die räumlichen Abhängigkeiten sind auf beiden Ebenen erkennbar und werden nicht durch die Aggregation der Daten künstlich erzeugt (vgl. SCHMIDTNER et al. 2015, 186). Im Hinblick auf die Tatsache, dass auch im Rahmen dieser Arbeit räumlich aggregierte Daten verwendet werden, ist dies ein wichtiger Hinweis.

Ebenfalls auf der Basis auf Gemeindeebene aggregierter Daten analysieren NIEDERMAYR et al. (2016) den Einfluss von regionalen Charakteristika und räumlichen Abhängigkeiten auf den Ölkürbis-anbau als Produktionsalternative in Österreich. Im Unterschied zu LÄPPLÉ und KELLEY (2015) und SCHMIDTNER et al. (2012) wenden sie das *Spatial Lag of X* (SLX) Modell an um Spill-Over-Effekte zu beobachten. Dieses berücksichtigt im Gegensatz zu anderen häufig verwendeten räumlich-ökonomischen Modellen nicht globale, sondern lokale Spill-Over-Effekte (vgl. NIEDERMAYR et al. 2016, 278). Anders als bei globalen Spill-Over-Effekten gibt es bei lokalen Spill-Over-Effekten keine Rückkoppelungseffekte und die Effekte beschränken sich nur auf benachbarte Einheiten (vgl. LESAGE 2014, 3f.). NIEDERMAYR et al. (2016, 281) betrachten zwei Untersuchungsregionen in getrennten Modellen je in einem nicht räumlichen Tobit- und dem SLX-Modell. Sie stellen zum einen fest, dass sich die direkten Effekte, beispielsweise durch den Anteil an direktvermarktenden Betrieben, in den beiden Untersuchungsregionen teils deutlich voneinander unterscheiden. Zum anderen stellt sich nur eine der räumlich gewichteten Variablen in einer der beiden Regionen als statistisch signifikant heraus: steigt der Anteil an direktvermarktenden Betrieben in benachbarten Gemeinden um einen Prozentpunkt, steigt der Anteil der mit Ölkürbis bebauten Ackerfläche in einer Gemeinde um 0,26 Prozentpunkte (vgl. NIEDERMAYR et al. 2016, 283).

Räumliche Effekte durch Wettbewerb

Räumliche Effekte zeigen sich nicht nur in der Adoption von Produktionsalternativen sondern insbesondere auch im Wettbewerb, vor allem um landwirtschaftlich nutzbaren Boden, zwischen benachbarten Betrieben (vgl. SAINT-CYR et al. 2019, 240). In der wissenschaftlichen Literatur wird vor allem der Effekt von Agrarförderung auf diesen Wettbewerb untersucht, wobei die Anzahl an landwirtschaftlichen Betrieben sowie Betriebsgrößen als zu erklärende Variablen herangezogen werden (z.B. STORM und HECKELEI 2018, STORM et al. 2014).

Eine der ersten Studien, welche den Effekt von Agrarförderungen auf den Agrarstrukturwandel unter der Berücksichtigung räumlicher Effekte untersucht, ist jene von STORM et al. (2014). Sie untersuchen dies unter der Verwendung von Daten auf Betriebsebene in Norwegen. Die Autoren erklären das Entstehen von Abhängigkeiten zwischen benachbarten Betrieben vor allem über die Zahlungsbereitschaft (WTP) für Boden seitens der Landwirtinnen und Landwirte. Landwirtschaftlich nutzbarer Boden ist ein begrenztes Gut und Betriebe stehen im Wettbewerb um diesen. Abhängigkeiten zwischen Betrieben entstehen, weil die Entscheidung, Boden zu kaufen oder zu verkaufen bzw. zu pachten oder zu verpachten auch von der WTP für Boden von benachbarten Landwirtinnen und Landwirten abhängt. Transaktionen von Boden zwischen diesen entstehen nämlich durch unterschiedlich hohe WTPs seitens der Landwirtinnen und Landwirte (vgl. STORM et al. 2014, 1193 f.). Eine Vielzahl an Faktoren, beispielsweise die Produktivität des Betriebes, beeinflusst diese. Von besonderem Interesse ist für die Autoren der Einfluss von Direktzahlungen an die Landwirtinnen und Landwirte auf die WTP. Durch sie können finanzielle Engpässe überbrückt werden und die WTP für Boden wird höher (vgl. KEY und ROBERTS 2006, 391). Aufgrund dieser Zusammenhänge nehmen STORM et al. (2014, 1195) an, dass die Charakteristika eines benachbarten Betriebes einen genau gegenteiligen Effekt auf die WTP einer Landwirtin oder eines Landwirtes haben, als die Charakteristika des eigenen Betriebes. So haben beispielsweise höhere Direktzahlungen an eine Landwirtin oder einen Landwirt einen positiven Effekt auf deren oder dessen eigene WTP, aber einen negativen Effekt auf die WTP der benachbarten Landwirtinnen und Landwirte (vgl. STORM et al. 2014, 1195).

STORM et al. (2014, 1195 f.) untersuchen die Effekte von Direktzahlungen an einen Betrieb und benachbarte Betriebe anhand eines räumlichen Probit-Modells. Ihrem Modell liegt eine latente Variable y^* zugrunde, die über Weiterbestehen ($y_i = 1$, wenn $y_i^* > 0$) oder Ausstieg ($y_i = 0$, wenn $y_i^* \leq 0$) des Betriebes entscheidet. y^* ist dabei eine lineare Funktion aus den Charakteristika eines Betriebes und den Charakteristika der benachbarten Betriebe, wobei die der benachbarten Betriebe mit einer räumlichen Gewichtungsmatrix multipliziert werden. Sie wenden hierfür ein SLX- sowie ein SDEM (*Spatial Durbin Error Model*) an, wobei letzteres auch räumliche Autokorrelation erlaubt (STORM et al. 2014, 1196). Anhand der räumlichen Gewichtungsmatrix wird festgelegt, welche Betriebe mit welcher Gewichtung als Nachbarn eines Betriebes festgelegt werden. Norwegen ist, ähnlich wie Österreich, die Struktur der Landwirtschaft betreffend ein heterogenes Land. Die Autoren gehen deshalb davon aus, dass sich die Distanzen, über welche hinweg landwirtschaftliche Betriebe um Boden konkurrieren, je nach Region voneinander unterscheiden. Als Radius um einen Betrieb, innerhalb dessen weitere Betriebe als Nachbarn gelten, wählen die Autoren den Median der Distanzen zwischen den Betrieben und deren am weitesten entfernten Felder in einer Gemeinde. Die Anzahl an Nachbarn wird außerdem auf 20 begrenzt und diese werden nach ihrer inversen Distanz gewichtet (vgl. STORM et al. 2014, 1198f.).

STORM et al. (2014, 1199ff.) vergleichen die Ergebnisse eines nicht-räumlichen Probit-Modells mit jenen des SLX- und SDEM-Modells. Das Ignorieren des räumlich autokorrelierten Fehlers im SLX-

Modell führt nicht zu einer wesentlichen Verzerrung desselben und die nicht räumlich gewichteten Variablen unterscheiden sich zwischen den drei Modellen kaum. Den größten Einfluss auf die abhängige Variable zeigen jene Variablen, die die Größe der Betriebe in absoluten Zahlen messen: in Hektar, in der Höhe der Direktzahlungen sowie der notwendigen Arbeitskraft (vgl. STORM et al. 2014, 1199). Durch das Berücksichtigen von räumlich gewichteten Variablen erhöht sich der Anteil an korrekten Vorhersagen der räumlichen Modelle gegenüber dem nicht-räumlichen Modell kaum, dennoch lassen sie einen wichtigen Rückschluss zu: während die Wahrscheinlichkeit des Fortbestehens für flächenmäßig größere Betriebe steigt, sinkt sie, je höher die Summe an Direktzahlungen ist, die benachbarte Betriebe erhalten. Das nicht-räumliche Modell lässt den Schluss zu, dass durch höhere Direktzahlungen die Wahrscheinlichkeit des Fortbestehens für alle Betriebe steigt. Im räumlichen Modell wird jedoch deutlich: erhält nur ein Betrieb höhere Direktzahlungen, sinkt die Wahrscheinlichkeit des Fortbestehens der Betriebe in dessen Nachbarschaft (vgl. STORM et al. 2014, 1202). Anhand von Politiksimulationen kommen STORM et al. (2014, 1203) außerdem zu dem Schluss, dass räumliche Abhängigkeiten nicht zu berücksichtigen zu einer Überschätzung der Wirkung von Direktzahlungen führt.

Dass räumliche Effekte eine Rolle spielen, stellen STORM und HECKELEI (2018) auch in einer weiteren Studie auf derselben Datengrundlage fest. Anders als STORM et al. (2014) ziehen sie als abhängige Variable das Wachstum landwirtschaftlicher Betriebe heran und nicht die Ausstiegsrate (vgl. STORM und HECKELEI 2018, 4). Sie entwickeln das Modell weiter, in dem sie nicht nur eine sondern zwei unterschiedliche räumliche Gewichtungsmatrizen, eine lokale sowie eine regionale, integrieren. Ihre Motivation dabei ist es, mögliche Verzerrungen der marginalen Effekte durch korrelierte unbeobachtete Variablen zu minimieren (vgl. STORM und HECKELEI 2018, 1). So hängt die Entscheidung von Landwirtinnen und Landwirten, ihren Betrieb zu vergrößern zwar einerseits von der Größe benachbarter Betriebe ab, andererseits aber auch von unbeobachteten Effekten auf einer größeren räumlichen Ebene, wie beispielsweise der Geographie oder dem historischen Hintergrund der Region (vgl. STORM und HECKELEI 2018, 2).

In einem ersten Schritt zeigen die Autoren, dass die Definition der räumlichen Gewichtungsmatrix die beobachteten räumlichen Abhängigkeiten wesentlich beeinflusst. Wird die Nachbarschaft durch einen Radius von etwa 30 Kilometer um einen Betrieb definiert, haben die Direktzahlungen an benachbarte Betriebe einen negativen Effekt auf das Betriebswachstum. Ab einem Radius von 30 Kilometer kehrt sich das Vorzeichen um und es ist ein positiver Effekt zu beobachten. Ein ähnlicher Effekt zeigt sich bei dem Anteil an Milchviehbetrieben ab: bis zu einem Radius von etwa 30 Kilometer ist eine positive Korrelation zu beobachten, wird die Nachbarschaft großzügiger definiert, kehrt sich der Effekt auch hier um (vgl. STORM und HECKELEI 2018, 5). STORM und HECKELEI (2018, 6) führen dies darauf zurück, dass neben direkten räumlichen Effekten auf lokaler Ebene (wie die Konkurrenz um Boden oder Informations- bzw. Wissensweitergabe) auch unbeobachtete räumliche Effekte auf einer größeren räumlichen Ebene wirken und sowohl Betriebscharakteristika als auch -wachstum beeinflussen.

Um sowohl lokal als auch regional wirkende räumliche Effekte berücksichtigen zu können und so die Verzerrung durch unbeobachtete Variablen zu reduzieren, integrieren STORM und HECKELEI (2018) zwei räumliche Gewichtungsmatrizen in ihr SLX-Modell. Sie definieren eine lokale Räumliche Gewichtungsmatrix (W_L) als Kreis mit einem Radius zwischen 0,5 und 30 Kilometer um einen Betrieb sowie eine regionale Gewichtungsmatrix (W_R) als Ring zwischen 30 und 60 Kilometer um diesen Betrieb (vgl. STORM und HECKELEI 2018, 6). Die Ergebnisse der Regression zeigen, dass sich die Koeffizienten für die räumliche Abhängigkeit zwischen W_L und W_R deutlich voneinander unterscheiden. Für Direktzahlungen weist W_L einen negativen Koeffizienten auf, W_R

jedoch einen positiven. Dies stützt die Hypothese der Autoren, dass Direktzahlungen auf lokaler Ebene zu einer erhöhten Konkurrenz um Fläche und so zu einem geringeren Betriebswachstum führen, auf einer größeren räumlichen Ebene jedoch regionale Charakteristika zum Tragen kommen die einen gegenteiligen Effekt auf das Betriebswachstum haben (vgl. STORM und HECKELEI 2018, 6f.). Eine Umkehr des Vorzeichens des Koeffizienten zwischen W_L und W_R tritt auch beim Anteil an Milchviehbetrieben auf: auf der regionalen Ebene hat ein hoher Anteil an Milchviehbetrieben einen negativen Effekt auf das Betriebswachstum, was darauf schließen lässt, dass in Regionen mit einem hohen Anteil an Milchviehbetrieben das Betriebswachstum schwächer ist. Dies könnte laut den Autoren darauf zurückzuführen sein, dass Milchviehbetriebe eher aus dem Betrieb aussteigen was zu einer geringeren Konkurrenz um Flächen und damit die Möglichkeit zum Wachstum für verbleibende Betriebe führt (vgl. STORM und HECKELEI 2018, 7).

Um ihre Annahme, dass die Verzerrung durch unbeobachtete Variablen durch das Integrieren von zwei räumlichen Gewichtungsmatrizen verringern werden kann, zu überprüfen, führen STORM und HECKELEI (2018) eine Monte-Carlo-Simulation durch. In Monte-Carlo-Simulationen werden entlang von festgelegten Regeln Zufallszahlen erzeugt, sodass Experimente beobachtet werden können, deren Durchführung in größerem Umfang in der Realität nicht umsetzbar wäre (vgl. NAHRSTEDT 2015, 1ff.). Die Ergebnisse der Monte-Carlo-Simulation deuten darauf hin, dass so die Verzerrung durch unbeobachtete Variablen verringert werden kann, insbesondere dann, wenn die unbeobachtete Variable stark räumlich korreliert ist (vgl. STORM und HECKELEI 2018, 14f.).

STORM et al. (2014) sowie STORM und HECKELEI (2018) implizieren, dass alle Landwirtinnen und Landwirte in ihrer Reaktion auf das Verhalten benachbarter Betriebe gleich sind. SAINT-CYR et al. (2019, 238) halten dem entgegen, dass sie sich womöglich in Bezug auf ihr Verhalten gegenüber benachbarten Betrieben unterschiedlichen Typen zuordnen lassen und somit unbeobachtete Heterogenität unter den Betrieben besteht. Sie definieren deshalb drei Kategorien von Betrieben und untersuchen dann, wie sich die Größe benachbarter Betriebe jeweils auf die Ausstiegsrate unter den Betrieben in den Kategorien auswirkt. SAINT-CYR et al. (2019) vermuten, dass eine positive Korrelation zwischen der Größe benachbarter Betriebe und der Wahrscheinlichkeit, dass ein Betrieb aufgegeben wird, besteht, wenn die Konkurrenz um Boden treibende Kraft in der Interaktion zwischen Betrieben ist (Typ 1). Eine negative Korrelation könnte hingegen bestehen, wenn große Betriebe andere zur Adaption von neuen Technologien motivieren (Typ 2). Für eine dritte Kategorie (Typ 3) ist kein signifikanter Zusammenhang zu erkennen. Dies könnte zutreffen für Landwirtinnen und Landwirte, deren Verhalten nicht von finanziellen Anreizen geprägt ist oder für Betriebe, deren optimale Betriebsgröße bereits erreicht ist (vgl. SAINT-CYR et al. 2019, 240ff.). SAINT-CYR et al. (2019, 256) können 52% der Betriebe dem Typ 2 zuordnen, 29% dem Typ 3 und 19% dem Typ 1. Es zeigt sich, dass die Ausstiegsrate unter den Betrieben der Typen 2 und 3 geringer ist, als unter jenen des Typs 1 (vgl. SAINT-CYR et al. 2019, 257). Da für dieses Vorgehen jedoch Daten auf einzelbetrieblicher Ebene vorliegen müssen, kann dieser Zusammenhang im Rahmen der vorliegenden Arbeit nicht berücksichtigt werden.

2.3. Einflussfaktoren auf den Agrarstrukturwandel

Die Entwicklung der Betriebszahlen bzw. der Ausstiegsrate sowie der Betriebsgrößen wird beeinflusst von Faktoren unterschiedlicher Kategorien und räumlicher Ebenen. Die herangezogenen Kategorien und Variablen sind meist ähnlich, unabhängig davon, welche Methode angewandt wird. FERJANI et al. (2015, 62) beispielsweise unterscheiden zwischen

Faktoren des Humankapitals, der Betriebsstruktur, dem strukturellen Umfeld sowie sozioökonomischen Faktoren. BARTOLINI und VIAGGI (2013, 131) definieren die Kategorien Geografie, Haushaltscharakteristik, Charakteristik der Landwirtinnen und Landwirte sowie Betriebscharakteristik. AKIMOWICZ et al. (2013, 249) ziehen Variablen aus den Kategorien Betriebsstrukturmerkmale, Charakteristik der Landwirtinnen und Landwirte sowie territoriale Merkmale heran.

Ein weiterer Faktor, welcher den Strukturwandel in allen Sektoren aber insbesondere auch in der Landwirtschaft beeinflusst, ist der technologische Fortschritt. Er ermöglicht beispielsweise massive Steigerungen in der Flächenproduktivität und effizientere Produktionsverfahren. Für die Landwirtschaft bedeutet dies, dass weniger Arbeitskraft benötigt wird, um dieselbe Menge an Produkten zu erzeugen und es folglich weniger Landwirtinnen und Landwirte gibt. Technologischer Fortschritt kann nicht direkt gemessen werden, spiegelt sich aber beispielsweise in Produktivitätskennzahlen wider (vgl. GOCHT et al. 2012, 26).

Im Folgenden sollen die den Agrarstrukturwandel beeinflussenden Faktoren in die drei Kategorien „Betriebsstruktur“, „Humankapital“ sowie „standortabhängige Faktoren“ eingeteilt werden. Faktoren, welche sich in den meisten Studien als nicht signifikant erwiesen haben, werden nicht besprochen. Da ein besonderer Fokus dieser Arbeit auf Agrarförderungen liegt, wird diesen eine eigene Kategorie „Agrarförderungen“ gewidmet und der bisherige Stand der Forschungen zum Effekt von Agrarförderungen auf den Agrarstrukturwandel in dieser zusammengefasst.

Humankapital

Grundsätzlich scheint der Einfluss des Humankapitals eines Betriebes auf dessen Größenentwicklung und Wahrscheinlichkeit der Betriebsaufgabe ambivalent. Einerseits ermöglicht ein größeres Humankapital stärkeres Betriebswachstum und senkt somit auch die Wahrscheinlichkeit, dass ein Betrieb aufgegeben wird. Andererseits steigen durch ein größeres Humankapital die Verdienstmöglichkeiten außerhalb der Landwirtschaft, was dazu führt, dass die Wahrscheinlichkeit der Betriebsaufgabe steigt (vgl. WEISS 1999, 108). Bestimmte Merkmale des Humankapitals landwirtschaftlicher Betriebe haben einen wesentlichen Einfluss darauf, ob ein Betrieb wächst oder aus der Landwirtschaft aussteigt und damit auch auf den Agrarstrukturwandel insgesamt. Wesentliche Merkmale sind dabei das Geschlecht der Person, welche den Betrieb leitet, Alter und Ausbildung derselben Person, die Anzahl der weiteren Familienmitglieder sowie das Vorhandensein einer ihm oder ihr in der Leitung nachfolgenden Person (vgl. FERJANI et al. 2015, 60).

Nach FERJANI et al. (2015, 66f.) erhöht ein junges Alter der betriebsleitenden Person die Wahrscheinlichkeit, dass der Betrieb aufgegeben wird. Die Wahrscheinlichkeit sinkt mit zunehmendem Alter der betriebsleitenden Person, steigt aber etwa ab einem Alter von 55 Jahren wieder sprunghaft an. Diese Entwicklung kann eventuell durch fehlende Erfahrung und Wissen in jungen Jahren sowie einer steigenden Wahrscheinlichkeit des Eintretens in den Ruhestand im fortgeschrittenen Alter erklärt werden (vgl. FERJANI et al. 2015, 66f.). Einen ähnlichen Effekt erkennen KEY und ROBERTS (2007b, 337). Auch auf regionaler Ebene führt ein hoher Anteil an älteren Betriebsleiterinnen und Betriebsleitern zu einer höheren Ausstiegsrate in einer Region (vgl. GLAUBEN et al. 2006, 112). AKIMOWICZ et al. (2013, 254) untersuchen den Einfluss des Alters der betriebsleitenden Person auf die Betriebsgröße bzw. die Betriebsgrößenentwicklung. Auch sie stellen einen signifikanten Einfluss fest. Je älter die Betriebsleiterinnen und Betriebsleiter,

desto größer deren Betriebe. Andererseits zeigt sich, dass das Betriebswachstum mit zunehmendem Alter der betriebsleitenden Person abnimmt, während die Betriebe junger Betriebsleiterinnen und Betriebsleiter am stärksten wachsen (vgl. AKIMOWICZ et al. 2013, 254).

Neben dem Alter zeigt auch das Geschlecht der betriebsleitenden Person in Studien einen signifikanten Einfluss auf Betriebswachstum und -aufgabewahrscheinlichkeit. Durch Frauen geführte Betriebe wachsen signifikant weniger (vgl. WEISS 1999, 110) und die Betriebsaufgabewahrscheinlichkeit ist erhöht (vgl. FERJANI et al. 2015, 69). Der in der Literatur oft angenommene Grund hierfür ist, dass sich Frauen durch ihre meist tragende Rolle im Haushalt dem Betrieb nicht in ausreichendem Umfang widmen können (vgl. FERJANI et al. 2015, 69; WEISS 1999, 110).

Besitzt die betriebsleitende Person eine landwirtschaftliche Ausbildung, hat dies positive Effekte sowohl auf die Größenentwicklung als auch die Wahrscheinlichkeit des Weiterbestehens eines landwirtschaftlichen Betriebes (vgl. WEISS 1999, 110). Betriebsleitende Personen mit landwirtschaftlicher Ausbildung besitzen wahrscheinlich auch die Fähigkeit, größere Betriebe zu leiten (vgl. AKIMOWICZ et al. 2013, 258). Der generelle Bildungsstand von betriebsleitenden Personen zeigt meist keinen signifikanten Effekt (vgl. WEISS 1999, 110; AKIMOWICZ et al. 2013, 258).

Ein ebenfalls positiver signifikanter Zusammenhang besteht zwischen der Größe der Familie der betriebsleitenden Person sowie der Wahrscheinlichkeit des Weiterbestehens eines Betriebes. FERJANI et al. (2015, 68) stellen fest, dass mit jedem zusätzlichen Familienmitglied die Wahrscheinlichkeit, dass der Betrieb aufgegeben wird, um 1,44% sinkt. Auf räumlich aggregierter Ebene erkennen auch BREUSTEDT und GLAUBEN (2007, 121) den gleichen Effekt für die Anzahl an mitarbeitenden Familienmitgliedern. WEISS (1999, 110) erkennt einen ähnlichen Effekt auch auf das Wachstum von landwirtschaftlichen Betrieben auf Betriebsebene. Außerdem stellt er einen signifikant positiven Effekt für den Fall, dass die betriebsleitende Person verheiratet ist, fest (vgl. WEISS 1999, 110). Auch das Vorhandensein einer Hofnachfolgerin oder eines Hofnachfolgers wirkt sich positiv aus (vgl. GLAUBEN et al. 2006, 112; WEISS 1999, 110). Tabelle 1 fasst die Effekte von Indikatoren des Humankapitals auf Ausstiegsrate und Betriebswachstum zusammen.

Indikatoren des Agrarstrukturwandels

| Kategorie | unabhängige Variable | abhängige Variable | Ebene | verm. Einfluss | Quelle(n) u.a. |
|--------------|--|--------------------|---------|----------------|--|
| Humankapital | Alter Betriebsleiterin | Ausstiegsrate | Betrieb | + / - | FERJANI et al. 2015; KEY und ROBERTS 2007b |
| | | | Region | + | GLAUBEN et al. 2006 |
| | | Betriebswachstum | Betrieb | + / - | AKIMOWICZ et al. 2013 |
| | Betriebsleiterin (weiblich) | Ausstiegsrate | Betrieb | + | FERJANI et al. 2015 |
| | | Betriebswachstum | Betrieb | - | WEISS 1999 |
| | Landwirtschaftliche Ausbildung d. Betriebsleiterin | Ausstiegsrate | Betrieb | - | FERJANI et al. 2015 |
| | | Betriebswachstum | Betrieb | + | AKIMOWICZ et al. 2013; WEISS 1999 |
| | Familiengröße | Ausstiegsrate | Betrieb | - | FERJANI et al. 2015 |
| | | | Region | - | BREUSTEDT und GLAUBEN 2007 |
| | | Betriebswachstum | Betrieb | + | WEISS 1999 |

Tabelle 1: Einflussfaktoren des Humankapitals auf den Agrarstrukturwandel. Quelle: Eigene Darstellung.

Betriebsstruktur

Neben den Eigenschaften des Humankapitals eines Betriebes hat auch dessen wirtschaftliche Struktur und Ausrichtung einen wesentlichen Einfluss auf den Fortbestand und die Größenentwicklung. Vor allem Ausgangsgröße, Rechtsstatus, vorhandene Betriebszweige, die eingesetzte Arbeit sowie ob der Betrieb im Haupt- oder Nebenerwerb geführt wird sind entscheidende Faktoren.

Die Ausgangsgröße eines landwirtschaftlichen Betriebes bzw. die Betriebsgrößenstruktur in der Region wird in der Literatur fast immer als erklärende Variable herangezogen und erweist sich meist als signifikante Variable. Die Größe eines Betriebes wird dabei nicht immer in Hektar gemessen, sondern beispielsweise auch in Großvieheinheiten (GVE) (vgl. WEISS 1999, 107) oder Bruttogewinn (vgl. BREUSTEDT und GLAUBEN 2007, 120). WEISS (1999, 111), STORM et al. (2014, 1199), SAINT-CYR et al. (2019, 254), MANN (2003, 35) und andere Autorinnen und Autoren stellen fest, dass die Wahrscheinlichkeit des Fortbestehens mit zunehmender Betriebsgröße signifikant zunimmt. Dieser Effekt ist auch auf räumlich aggregierter Ebene zu beobachten (vgl. BREUSTEDT und GLAUBEN 2007, 121; GLAUBEN et al. 2006, 111). Im Unterschied dazu ist zwischen der Betriebsgröße und der Betriebsgrößenentwicklung kein linearer Zusammenhang zu erkennen. Nach AKIMOWICZ et al. (2013, 252) ist die Wahrscheinlichkeit für Wachstum unter den kleinen Betrieben am höchsten, ein Rückgang der Betriebsgröße betrifft am ehesten große Betriebe. Zu einem ähnlichen Ergebnis kommen auch BARTOLINI und VIAGGI (2013, 132).

Nicht nur der Umfang der LF eines Betriebes scheint einen Einfluss zu haben, sondern auch die Besitzverhältnisse bezüglich dieser Flächen. In Regionen, in denen der Anteil an gepachteten Flächen eher gering ist, zeigt sich eine geringe Wahrscheinlichkeit, dass Betriebe aufgeben (vgl. BREUSTEDT und GLAUBEN 2007, 123; GLAUBEN et al. 2006, 111).

Eine ebenfalls häufig herangezogene erklärende Variable ist der Betriebstyp. Unter Betriebstyp versteht sich dabei die spezifische Produktionsausrichtung eines Betriebes, beispielsweise die Haltung von Milchvieh und/oder biologische Landwirtschaft. FERJANI et al. (2015, 67) erkennen teils deutliche Unterschiede in der Betriebsaufgabewahrscheinlichkeit zwischen Betrieben unterschiedlichen Typs. Beispielsweise sinkt diese für Biobetriebe und Mutterkuhbetriebe und ist für Betriebe mit Pferden deutlich höher (vgl. FERJANI et al. 2015, 67). Auch auf regionaler Ebene sind diese Effekte zu beobachten. Ein hoher Anteil an Betrieben mit Dauerkulturen oder Schweinen etwa wirkt sich negativ auf die Ausstiegsrate einer Region aus (vgl. GLAUBEN et al. 2006, 110). Auch in der Betriebsgrößenentwicklung unterscheiden sich Betriebe unterschiedlichen Typs. Nach BARTOLINI und VIAGGI (2013, 133) ist die Wahrscheinlichkeit zu schrumpfen für Biobetriebe deutlich verringert und Betriebe, die sich auf Feldfrüchte spezialisieren wachsen eher. GLAUBEN et al. (2006, 111) untersuchen darüber hinaus, welchen Einfluss ein hoher Anteil an Betrieben mit Ferienunterkünften hat. Sie stellen dabei fest, dass in Regionen mit einem hohen Anteil dieser die Ausstiegsrate signifikant geringer ist.

Eine unter den Betriebstypen häufig herangezogene Variable ist das Halten von (Milch-) Vieh. Für Norwegen stellen STORM et al. (2014, 1200) fest, dass die Ausstiegsrate unter Milchviehbetrieben höher ist. Dagegen erkennen STORM und HECKELEI (2018) einen ambivalenten Effekt. Auf regionaler Ebene betrachtet bremst ein hoher Anteil an Milchviehbetrieben das Betriebswachstum, auf lokaler Ebene ist ein gegenteiliger Effekt sichtbar. Dies könnte aber damit zusammenhängen, dass Milchviehbetriebe eine höhere Ausstiegsrate aufweisen. Dies ermöglicht ein stärkeres Wachstum für weiter bestehende Betriebe auf lokaler Ebene (vgl. STORM und HECKELEI 2018, 7). BREUSTEDT und GLAUBEN (2007) berücksichtigen nicht nur Milchviehbetriebe, sondern ziehen als Variable die Viehbesatzdichte heran. Ihrer Studie zufolge geht mit einer höheren Viehbesatzdichte eine geringere Ausstiegsrate landwirtschaftlicher Betriebe einher.

Ein ähnlicher Zusammenhang zeichnet sich auch in Bezug auf den Anteil an Ackerflächen an der gesamten LF auf einem Betrieb bzw. in einer Region ab. Für Österreich erkennen NIEDERMAYR et al. (2015, 281), dass sich ein hoher Anteil an Ackerflächen in einer Region negativ auf die Entwicklung der Betriebsanzahl in den Alpenregionen auswirkt. Für Norwegen erkennen wiederum STORM und HECKELEI (2018,7), dass ein hoher Anteil an Ackerflächen auf lokaler Ebene einen positiven Effekt auf das Betriebswachstum auf dieser Ebene hat.

Auf regionaler Ebene in Westeuropa ermitteln BREUSTEDT und GLAUBEN (2007) einen negativen Zusammenhang zwischen der Ausstiegsrate und dem Anteil an viehhaltenden Betrieben in einer Region. Regionen mit einem hohen Anteil an solchen Betrieben verloren gegenüber anderen Regionen weniger Betriebe (vgl. BREUSTEDT und GLAUBEN 2007, 122). Sie kommen damit zu einem ähnlichen Ergebnis wie GLAUBEN et al. (2006, 110).

Ob ein Betrieb als Haupt- oder Nebenerwerbsbetrieb geführt wird, wird in der Literatur ebenfalls häufig als erklärende Variable herangezogen. Die Wahrscheinlichkeit der Betriebsaufgabe scheint für im Haupterwerb geführte Betriebe deutlich niedriger (vgl. FERJANI et al. 2015, 69; WEISS 1999, 108). Gleichzeitig stellen sowohl NIEDERMAYR et al. (2015, 281) als auch BREUSTEDT und GLAUBEN (2007, 122) fest, dass mit einem höheren Anteil an Nebenerwerbsbetrieben in einer Region eine

geringere Ausstiegsrate einhergeht. WEISS (1999, 108) stellt außerdem fest, dass im Haupterwerb geführte Betriebe eher wachsen.

Neben dem Erwerbsstatus der betriebsleitenden Person spielen auch die insgesamt zur Verfügung stehenden Arbeitskräfte eines Betriebes eine signifikante, aber ambivalente Rolle in der Literatur. Eine höhere Anzahl an Angestellten sowie an Arbeitskräften je Hektar (inkl. Familienmitglieder) erhöhen nach FERJANI et al. (2015, 67) die Wahrscheinlichkeit, dass der Betrieb aufgegeben wird. STORM et al. (2014, 1200) erkennen jedoch einen positiven Zusammenhang investierter Arbeitskraft sowie geschätztem Arbeitsbedarf und der Wahrscheinlichkeit, dass ein Betrieb weiterbesteht. Je höher jedoch das Ausmaß an investierter Arbeitskraft im Verhältnis zum geschätzten Arbeitsbedarf, desto niedriger ist diese Wahrscheinlichkeit (vgl. STORM et al. 2014, 1200). Bezogen auf die Betriebsgröße stellen BARTOLINI und VIAGGI (2013,133) fest, dass das Vorhandensein von externen Arbeitskräften die Wahrscheinlichkeit verringert, dass ein Betrieb seine LF ausweitet.

Über den Einfluss des Rechtsstatus eines Betriebes (Personengemeinschaft, juristische Person o.Ä.) kann auf Basis der Literatur keine eindeutige Aussage getroffen werden. KEY und ROBERTS (2007b, 339) kommen zu dem Ergebnis, dass im Vergleich zum Familienbetrieb alle anderen Rechtsformen mit einer sinkenden Wahrscheinlichkeit des Fortbestehens einhergehen. Dagegen stellen SAINT-CYR et al. (2019, 255) fest, dass als Personengemeinschaft geführte Betriebe weniger wahrscheinlich den Betrieb aufgeben. Dagegen stellen sowohl AKIMOWICZ et al. (2013, 252) als auch KEY und ROBERTS (2007b, 340) fest, dass Personengemeinschaften meist größere bzw. stärker wachsende Betriebe führen. In Tabelle 2 sind die Effekte von Indikatoren der Betriebsstruktur auf die abhängigen Variablen Ausstiegsrate und Betriebswachstum zusammengefasst.

Indikatoren des Agrarstrukturwandels

| Kategorie | unabhängige Variable | abhängige Variable | Ebene | verm. Einfluss | Quelle(n) u.a. |
|----------------------|--|--------------------|---------|--|---|
| Betriebs-struktur | Betriebsgröße | Ausstiegsrate | Betrieb | - | WEISS 1999; STORM et al. 2014; SAINT-CYR et al. 2019; MANN 2003 |
| | | | Region | - | GLAUBEN et al. 2006; BREUSTEDT und GLAUBEN 2007 |
| | | Betriebswachstum | Betrieb | + | AKIMOWICZ et al. 2013; BARTOLINI und VIAGGI 2013 |
| | Anteil gepachteter Flächen | Ausstiegsrate | Region | + | BREUSTEDT und GLAUBEN 2007; GLAUBEN et al. 2006 |
| | Biobetrieb | Ausstiegsrate | Betrieb | - | FERJANI et al. 2015 |
| | | Betriebswachstum | Betrieb | + | BARTOLINI und VIAGGI 2013 |
| | Milchviehbetrieb | Ausstiegsrate | Betrieb | + | STORM et al. 2014 |
| | | Betriebswachstum | Betrieb | +/- | STORM und HECKELEI 2018 |
| | GVE/ha | Ausstiegsrate | Region | - | BREUSTEDT und GLAUBEN 2007 |
| | Ackerflächen | Ausstiegsrate | Region | + | NIEDERMAYR et al. 2015 |
| | | Betriebswachstum | Betrieb | + | STORM und HECKELEI 2018 |
| | Anteil Betriebe mit Ferienunterkünften | Ausstiegsrate | Region | - | GLAUBEN et al. 2006 |
| | Haupterwerbsbetrieb | Ausstiegsrate | Betrieb | - | FERJANI et al. 2015; WEISS 1999 |
| | | | Region | - | BREUSTEDT und GLAUBEN 2007; NIEDERMAYR et al. 2015 |
| | | Betriebswachstum | Betrieb | + | WEISS 1999 |
| | Arbeitskraft | Ausstiegsrate | Betrieb | + / - | FERJANI et al. 2015; STORM et al. 2014 |
| Personengemeinschaft | Ausstiegsrate | Betrieb | + / - | KEY und ROBERTS 2007b; SAINT-CYR et al. 2019 | |
| | Betriebswachstum | Betrieb | + | AKIMOWICZ et al. 2013; KEY und ROBERTS 2007b | |

Tabelle 2: Einflussfaktoren der Betriebsstrukturen auf den Agrarstrukturwandel. Quelle: eigene Darstellung.

Standortabhängige Faktoren

Zu den standortabhängigen Faktoren zählen jene die Struktur der Landwirtschaft einer Region beeinflussende Faktoren, welche sich nicht aus den Eigenschaften der landwirtschaftlichen Betriebe ergeben, sondern aus den Eigenschaften des geographischen Raumes, in welchem sich die Betriebe befinden. Dieser Einfluss ergibt sich durch die, beispielsweise politisch-administrative, Region, in der sich ein Betrieb befindet, sowie deren geographische und soziodemographische Eigenschaften. Hierzu zählen beispielsweise die durchschnittliche Hangneigung oder die Bevölkerungsdichte in einer Region.

Häufig werden in der Literatur die Effekte, die sich durch die räumliche Lage ergeben, mittels Verwendung von Dummy-Variablen für die Region, in der sich die Betriebe befinden, berücksichtigt. MANN (2003, 34) erkennt beispielsweise, dass die Anzahl an landwirtschaftlichen Betrieben in manchen schweizerischen Kantonen signifikant rascher sinkt als in anderen, GLAUBEN et al. (2006, 112) erkennen dieses Muster teilweise auch für deutsche Bundesländer. Auch die Betriebsgrößenentwicklung betreffend lassen sich deutlich regionale Unterschiede erkennen (vgl. AKIMOWICZ et al. 2013, 258f.; BARTOLINI und VIAGGI 2013, 131ff.).

Mit jeder Region sind auch soziodemographische Merkmale verbunden, die Auswirkungen auf den Agrarstrukturwandel haben. Ein wichtiges soziodemographisches Merkmal von Regionen ist deren Bruttoinlandsprodukt (BIP). GLAUBEN et al. (2006, 112) stellen fest, dass mit einem höheren BIP in einer Region ein größerer Rückgang in der Anzahl an landwirtschaftlichen Betrieben in Westdeutschland verbunden ist; BREUSTEDT und GLAUBEN (2007, 121) stellen jedoch keinen signifikanten Zusammenhang fest. Häufiger wird die Arbeitslosenquote einer Region als möglicher Einflussfaktor herangezogen. SAINT-CYR et al. (2019, 255) stellen etwa in Frankreich eine positive Korrelation zwischen Arbeitslosenquote und der Anzahl an weitergeführten Betrieben fest. Sie vermuten, dass eine hohe Arbeitslosenquote mit weniger Einkommensalternativen verbunden ist, was Landwirtinnen und Landwirte veranlasst, ihren Betrieb nicht aufzugeben (vgl. SAINT-CYR et al. 2019, 255). Zu einem anderen Ergebnis kommen GLAUBEN et al. (2006). Sie stellen fest, dass in westdeutschen Regionen mit einer hohen Arbeitslosenquote auch die Ausstiegsrate höher ist (vgl. GLAUBEN et al. 2006, 112). Dieser Effekt ist auch in den Ergebnissen von BREUSTEDT und GLAUBEN (2007, 121) für Westeuropa zu erkennen. In der Schweiz dagegen stellt MANN (2003, 35) keinen signifikanten Zusammenhang fest.

Mehrere Autorinnen und Autoren untersuchen auch den Effekt der Bevölkerungsdichte auf den Agrarstrukturwandel, mit unterschiedlichen Ergebnissen. Während BREUSTEDT und GLAUBEN (2007, 124) feststellen, dass mit einer höheren Bevölkerungsdichte ein Rückgang in der Betriebsanzahl verbunden ist, erkennen GLAUBEN et al. (2006, 112) einen gegenteiligen Effekt. NIEDERMAYR et al. (2015, 281) erkennen jedoch keinen signifikanten Zusammenhang zwischen der Bevölkerungsdichte und der Anzahl an landwirtschaftlichen Betrieben im Alpenraum. Mit der Bevölkerungsdichte eng verbunden ist die Unterscheidung zwischen städtischen und ländlichen Regionen beziehungsweise Gemeinden. AKIMOWICZ et al. (2013, 252) unterscheiden zwischen städtischen, stadtnahen, ländlichen und sehr ländlichen Gemeinden im Südwesten Frankreichs. Sie kommen zu dem Ergebnis, dass die Größenentwicklung besonders dynamisch in städtischen Gemeinden verläuft. Betriebe in ländlichen Gemeinden sind tendenziell kleiner als in sehr ländlichen Gemeinden, wachsen jedoch stärker (vgl. AKIMOWICZ et al. 2013, 259).

BARTOLINI und VIAGGI (2013) berücksichtigen auch geographische Faktoren und fügen ihrem Modell Dummy-Variablen für flache, hügelige sowie Gebirgsregionen hinzu. Der einzige

Indikatoren des Agrarstrukturwandels

signifikante Zusammenhang, den sie feststellen ist, dass für Betriebe in Gebirgsregionen die Wahrscheinlichkeit höher ist, ihre LF zu reduzieren (vgl. BARTOLINI und VIAGGI 2013, 133). Eng mit den geographischen Bedingungen verknüpft ist die Lage in einem im Rahmen der GAP definierten benachteiligten Gebiet (vgl. BMNT 2018, 95f.). BARTOLINI und VIAGGI (2013, 133) berücksichtigen dies ebenfalls anhand einer Dummy-Variablen und kommen zu dem Ergebnis, dass die Wahrscheinlichkeit für Betriebe zu wachsen in benachteiligten Gebieten signifikant geringer ist. Tabelle 3 fasst die hier beschriebenen Effekte von Standortfaktoren auf Ausstiegsrate und Betriebswachstum zusammen.

| Kategorie | unabhängige Variable | abhängige Variable | Ebene | verm. Einfluss | Quelle(n) u.a. |
|----------------------------|------------------------|--------------------|-------|----------------|--|
| standortabhängige Faktoren | BIP | Ausstiegsrate | | + | GLAUBEN et al. 2006 |
| | Arbeitslosenquote | Ausstiegsrate | | + / - | SAINT-CYR et al. 2019; GLAUBEN et al. 2006; BREUSTEDT und GLAUBEN 2007 |
| | Bevölkerungsdichte | Ausstiegsrate | | + / - | GLAUBEN et al. 2006; BREUSTEDT und GLAUBEN 2007 |
| | urbanes Gebiet | Betriebswachstum | | + / - | AKIMOWICZ et al. 2013 |
| | Berggebiet | Betriebswachstum | | - | BARTOLINI und VIAGGI 2013 |
| | Benachteiligtes Gebiet | Betriebswachstum | | - | BARTOLINI und VIAGGI 2013 |

Tabelle 3: Einflussfaktoren des Standortes auf den Agrarstrukturwandel. Quelle: eigene Darstellung.

Agrarförderungen

Ein Teil der Literatur setzt sich auch mit dem Einfluss von Agrarförderungen als erklärende Variable für Ausstiegsraten und Größenentwicklung landwirtschaftlicher Betriebe auseinander. Nach ROBERTS und KEY (2018, 629) können in der Theorie keine eindeutigen Aussagen darüber getroffen werden, wie sich Agrarförderungen auf das Wachstum und die Überlebensrate von landwirtschaftlichen Betrieben auswirken. In einem Modell mit perfektem Markt ist die Menge an verfügbaren Boden fix, aber Arbeit und Kapital mobil zwischen dem landwirtschaftlichen Sektor und nicht-landwirtschaftlichen Sektoren. Zusätzliche Gewinne führen dann zu einer Steigerung des Landpreises, aber nicht zu Betriebswachstum (vgl. ROBERTS und KEY 2008, 630). Die Realität ist aber geprägt von Marktunvollkommenheiten und Transaktionskosten. Dies führt zu Mechanismen, über die Agrarförderungen die Struktur der Landwirtschaft beeinflussen können (vgl. KEY und ROBERTS 2007b, 332). Erhalten nicht alle Betriebe Förderbeträge je Hektar in gleicher Höhe, ergeben sich unterschiedlich hohe WTPs für Boden. Durch eine höhere WTP für Boden seitens einiger Betriebe erhöht sich der Preis für Boden. Dadurch werden andere Betriebe

möglicherweise gezwungen zu schrumpfen oder ihren Betrieb aufzugeben (vgl. KEY und ROBERTS 2007b, 332). Eine ungleiche Verteilung der absoluten Agrarförderungen je Betrieb, führt möglicherweise zu einem ähnlichen Effekt. Betriebe mit einem höheren Nettovermögen erhalten günstigere Kredite. Anhand dieser ist es für sie leichter, ihren Betrieb zu vergrößern, was wiederum andere Betriebe in ihren Entwicklungsmöglichkeiten bremst (vgl. ROBERTS und KEY 2008, 630). Auf der anderen Seite könnten höhere Agrarförderungen dazu führen, dass Betriebe Arbeit gegen Freizeit substituieren und damit ihr Bedarf an Boden sinkt, was wiederum zu sinkenden Bodenpreisen führt. Dies könnte kleinere Betriebe veranlassen, zu wachsen (vgl. KEY und ROBERTS 2007b, 332f.).

KEY und ROBERTS (2007a) untersuchen in mehreren Studien, wie sich Agrarförderungen in den USA tatsächlich auf das Wachstum und die Ausstiegsrate landwirtschaftlicher Betriebe auswirken. In ihrer Datengrundlage erkennen sie eine Zunahme der Anzahl an kleinen sowie großen Betrieben einerseits und andererseits einen Rückgang in der Anzahl an mittelgroßen Betrieben und vermuten einen Grund auch in der Gestaltung der Agrarförderungen (vgl. KEY und ROBERTS 2007a, 32f.). Tatsächlich erkennen sie einen positiven Zusammenhang zwischen der Höhe der Agrarförderungen je Fläche und der Wahrscheinlichkeit des Weiterbestehens eines Betriebes. Dieser Effekt nimmt mit zunehmender Ausgangsgröße eines Betriebes zu (vgl. KEY und ROBERTS 2007b, 340). Auch ein positiver Zusammenhang zwischen Agrarförderungen und Betriebswachstum ist erkennbar. Dieser ist jedoch nur gering, wenn nur über den gesamten Beobachtungszeitraum bestehende Betriebe betrachtet werden (vgl. KEY und ROBERTS 2007b, 340ff.). Zu ähnlichen Ergebnissen kommen auch KEY und ROBERTS (2006) und ROBERTS und KEY (2008).

Bei der Analyse der Abwanderung landwirtschaftlicher Betriebe in Westdeutschland zwischen 1991 und 1999 berücksichtigen GLAUBEN et al. (2006) sektorbezogene Subventionszahlungen, definieren diese jedoch nicht genauer. Sie können erkennen, dass mit höheren Subventionszahlungen geringere Ausstiegsraten einhergehen, der Zusammenhang ist jedoch nicht signifikant (vgl. GLAUBEN et al. 2006, 112). Zum selben Schluss kommen BREUSTEDT und GLAUBEN (2007) auch bei der Analyse der Ausstiegsraten zwischen 1993 und 1997 unter der Berücksichtigung von Subventionszahlungen je Betrieb in westeuropäischen Regionen, auch hier besteht jedoch kein signifikanter Zusammenhang (vgl. BREUSTEDT und GLAUBEN 2007, 122).

STORM et al. (2014) sowie STORM und HECKELEI (2018) untersuchen den Einfluss von Direktzahlungen auf den Agrarstrukturwandel in Norwegen. Räumliche Abhängigkeiten nicht berücksichtigt, erkennen sie eine positive, signifikante Korrelation zwischen der Höhe der Direktzahlungen und der Wahrscheinlichkeit des Weiterbestehens von landwirtschaftlichen Betrieben (vgl. STORM et al. 2014, 1199f.), der auch in STORM und HECKELEI (2018, 7) in Bezug auf das Betriebswachstum erkennbar ist. Dass Direktzahlungen den Agrarstrukturwandel wahrscheinlich bremsen, erkennt auch MANN (2003, 35).

KIRCHWEGER und KANTELHARDT (2015) untersuchen den Effekt von staatlich gestützten Investitionen auf den Agrarstrukturwandel in Österreich. Diese werden im Rahmen der zweiten Säule der GAP gefördert, um die Wettbewerbsfähigkeit der Land- und Forstwirtschaft zu stärken (vgl. BMNT 2018, 97). Neben weiteren abhängigen Variablen untersuchen KIRCHWEGER und KANTELHARDT (2015) auch den Effekt, den diese Investitionen auf die Entwicklung der Betriebsgröße in Form von LF haben. Sie erkennen, dass investierende Betriebe im Vergleich zu nicht-investierenden, vergleichbaren Betrieben ihre LF stärker vergrößern (vgl. KIRCHWEGER und KANTELHARDT 2015, 86). Agrarförderungen in Form von Investitionsförderungen beschleunigen

Indikatoren des Agrarstrukturwandels

damit wahrscheinlich den Agrarstrukturwandel. Untenstehende Tabelle 4 gibt einen Überblick der beschriebenen Effekte von Agrarförderungen auf Ausstiegsrate und Betriebswachstum.

| Kategorie | unabhängige Variable | abhängige Variable | Ebene | verm. Einfluss | Quelle(n) u.a. |
|------------------|----------------------|--------------------|---------|----------------|---|
| Agrarförderungen | Agrarförderungen | Ausstiegsrate | Betrieb | - | KEY und ROBERTS 2007a; MANN 2003; STORM et al. 2014 |
| | | | Region | - | GLAUBEN et al. 2006; BREUSTEDT und GLAUBEN 2007 |
| | | Betriebswachstum | Betrieb | +/- | KEY und ROBERTS 2007b; KEY und ROBERTS 2006; ROBERTS und KEY 2008; KIRCHWEGER und KANTELHARDT 2015; STORM und HECKELEI 2018 |

Tabelle 4: Einfluss von Agrarförderungen auf den Agrarstrukturwandel. Quelle: eigene Darstellung.

2.4. Wesentliche Indikatoren des Agrarstrukturwandels in Österreich

Mit dem Fortschreiten des Agrarstrukturwandels sind nicht nur Strukturveränderungen innerhalb der Landwirtschaft verbunden. Er hat ebenso Auswirkungen auf die Produktivität und Effizienz der Landwirtschaft, die Nachfrage nach staatlichen Dienstleistungen, die Anforderungen an die Infrastruktur sowie das Wohlbefinden der Bevölkerung in ländlichen Gemeinden (vgl. WEISS 1999, 103). Der Rückgang in der Anzahl an landwirtschaftlichen Betrieben bedingt auch einen Rückgang der Bevölkerung in ländlichen Gebieten und hat damit Konsequenzen für die nicht-landwirtschaftliche Wirtschaft sowie den Tourismus. Der Agrarstrukturwandel ist deshalb Interessensgegenstand von Wirtschafts- und Politikwissenschaftlerinnen (vgl. WEISS 1999, 103f.).

Obwohl die österreichische Landwirtschaft im internationalen Vergleich nach wie vor als kleinstrukturiert bezeichnet werden kann (vgl. BMNT 2018, 58), unterliegt auch sie seit Jahrzehnten einem steten Wandel. Die Hauptursachen dieses Wandels sind die Veränderung der agrarpolitischen Rahmenbedingungen seit Mitte des 20. Jahrhunderts, die Abnahme von Arbeitsplätzen in ländlichen Regionen, und damit Erosion von Infrastruktur, der zunehmende Druck durch nicht-landwirtschaftliche Flächennutzung sowie der (auch durch die Globalisierung verursachte) Wertewandel auch in ländlichen Regionen, mit dem traditionelle Hofnachfolgemuster in Frage gestellt werden (vgl. GROIER 2004, 2). Der Agrarstrukturwandel spiegelt sich wider im Wachstum und der Entwicklung der Anzahl der Betriebe, in der Spezialisierung oder Diversifizierung der Betriebe sowie der Zu- oder Abnahme kapitalintensiver Bewirtschaftungsweisen (vgl. KIRCHWEGER und KANTELHARDT 2015, 73).

Im Jahr 1951 gab es in Österreich noch rund 427.000 Betriebe mit landwirtschaftlich genutzter Fläche. Die letzte Agrarstrukturerhebung 2016 ergab eine Anzahl von nur mehr rund 134.500

Betrieben (vgl. BMNT 2018, 165). In den letzten 70 Jahren haben somit knapp 70% der Landwirtinnen und Landwirte ihren Betrieb aufgegeben. Die Geschwindigkeit dieses Betriebsrückgangs hat sich in den letzten Jahren jedoch verlangsamt und noch immer sind über 90% der Betriebe familiengeführt (vgl. BMNT 2019, 62). Betrug die jährliche Abnahmerate zwischen 1999 und 2013 im Hochalpengebiet, im Voralpenland sowie am Alpenostrand nur bis zu - 1,9%, ging die Anzahl an Betrieben im südöstlichen sowie im nordöstlichen Flach- und Hügelland um fast -4% jährlich zurück (vgl. WAGNER 2015, 80). Als Motivationen für die Betriebsaufgabe nennt GROIER (2004) das Fehlen einer Hofnachfolgerin oder eines Hofnachfolgers, Arbeitsüberlastung (vor allem bei Nebenerwerbsbetrieben), fehlende Rentabilität des Betriebes und/oder Überschuldung, das Vorhandensein einer außerlandwirtschaftlichen Ausbildung, die agrarpolitischen Rahmenbedingungen sowie das in der Wahrnehmung der Landwirtinnen und Landwirte gesunkene Ansehen des Berufsbildes in der Gesellschaft (vgl. GROIER 2004, 4ff.).

Während die Anzahl an landwirtschaftlichen Betrieben zwischen 1951 und 2016 um insgesamt rund 70% zurückging, reduzierte sich die landwirtschaftlich genutzte Fläche nur um knapp 35% (vgl. BMNT 2018, 165). Dementsprechend ist die LF je Betrieb im selben Zeitraum deutlich gestiegen. 1951 bewirtschaftete ein Betrieb im Schnitt 9,6 ha LF, bis zum Jahr 2016 ist die durchschnittliche Betriebsgröße auf 19,8 ha gewachsen und hat sich somit mehr als verdoppelt. Machte der Anteil an Betrieben mit einer Fläche von weniger als 20 ha 1980 noch 73,1% aus, so sank der Anteil dieser Betriebe bis 2015 auf 56,8%. Im gleichen Zeitraum nahm der Anteil an Betrieben mit einer Größe von über 50 ha von 5% auf 15,7% zu (vgl. BMNT 2018, 165).

WEISS (1999) untersuchte den Agrarstrukturwandel anhand von 50.000 landwirtschaftlichen Betrieben in Oberösterreich. Er zieht dabei Daten aus den Jahren 1980, 1985 und 1990 heran und betrachtet als abhängige Variablen einerseits das Betriebswachstum (in GVE) und andererseits das Weiterbestehen von Betrieben (vgl. WEISS 1999, 105ff.). Er erkennt dabei eine Polarisierung in den Wachstumsraten von Betrieben. Kleinere Betriebe wachsen schneller als größere Betriebe, jedoch nur bis zu einem gewissen Schwellenwert. Mittelgroße und größere Betriebe über diesem Schwellenwert wachsen langsamer (vgl. WEISS 1999, 113f.). Diese Beobachtung bestätigt eine Studie von SCHMID (2007). In den Jahren von 1998 bis 2002 wuchsen Betriebe mit einer Größe von weniger als zehn Hektar prozentuell am stärksten. Mit Blick auf das land- und forstwirtschaftliche Markteinkommen in derselben Periode wird deutlich, dass kleine Betriebe auf Produktionsalternativen mit höherer Wertschöpfung je Flächeneinheit setzen, die jedoch mit steigender Betriebsgröße abnimmt (vgl. SCHMID 2007, 81f.).

Ein Drittel aller landwirtschaftlichen Betriebe in Österreich produziert Milch und zwei Drittel aller Grünlandflächen werden von Betrieben mit Milchkuhhaltung bewirtschaftet. Dieser somit sehr bedeutende Sektor ist im internationalen Vergleich in Österreich kleinstrukturiert, gleichzeitig besteht angesichts der zunehmenden Liberalisierung und dem damit verschärften Wettbewerb ein starker Anpassungsdruck (vgl. KIRNER 2004, 53). Eine Studie darüber, welche Anpassungsstrategien Milchviehalterinnen verfolgen, liefert weitere Hinweise über den Verlauf des Agrarstrukturwandels in Österreich. Es zeigt sich, dass der Strukturwandel in der Milchwirtschaft zwar voranschreitet, jedoch nicht mit derselben Dynamik wie in anderen europäischen Ländern. 80% der befragten Milchbäuerinnen und Milchbauern wollen ihren Betrieb weiterführen, etwa die Hälfte möchte in Zukunft etwa gleich viel, ein Drittel mehr Milch produzieren (vgl. KIRNER 2004, 57). Anders als oft angenommen, wird die Milchproduktion in Berggebieten eher nicht zurückgehen sondern sich sogar stärker in die Gunstlagen der Bergregionen verlagern. Ein Grund hierfür könnte unter anderem in fehlende

Einkommensalternativen in diesen Regionen liegen (vgl. KIRNER 2004, 60f.). Wie auch in der Studie von WEISS (1999) ist erkennbar, dass Haupterwerbsbetriebe stärker wachsen (vgl. KIRNER 2004, 57).

Ein Großteil Österreichs ist Teil der Alpen. In diesen Bergregionen unterliegt die Landwirtschaft besonderen Herausforderungen und ist geprägt von traditionellen Wirtschaftsweisen. Obwohl der Schluss nahe liegt, dass insbesondere in den naturgemäß benachteiligten Bergregionen der Agrarstrukturwandel rascher voranschreitet als in Gunstlagen, zeichnen verschiedene Studien ein anderes Bild. Wie bereits erwähnt, gewinnt etwa die Milchproduktion in den Bergregionen Österreichs sogar an Bedeutung (vgl. KIRNER 2004, 60f.). Insgesamt liegt die Betriebsaufgaberate im Alpenraum unter dem landesweiten Durchschnitt und auch im internationalen Vergleich ging die Anzahl an Betrieben nur vergleichsweise leicht zurück (vgl. STREIFENEDER 2009, 43).

Zu ähnlichen Ergebnissen kommt auch PENZ (2011) in seiner Studie. Er legt dar, dass die Anzahl an landwirtschaftlichen Betrieben in den Flachlandgemeinden inner- und außeralpin stärker abnimmt als in Gemeinden mit Bergbauernbetrieben. Je geringer der Erschwernisgrad, desto höher die Betriebsaufgaberate. Die Tatsache, dass die Betriebsaufgaberate in Gunstlagen höher ist als in Gemeinden mit dem stärksten Erschwernisgrad, lässt vermuten, dass auch soziale Faktoren einen Einfluss auf die Entscheidungen der Landwirtinnen und Landwirte haben. Möglicherweise spielen Leitvorstellungen der Industriegesellschaft, in der materielle Werte und ein hoher Lebensstandard im Vordergrund stehen, in den naturräumlichen Gunstlagen eine größere Rolle, während Bergbauern weiterhin Grundbesitz als beste Garantie für das Überstehen von Krisen sehen (vgl. PENZ 2011, 18ff.). Gleichzeitig lässt sich eine Tendenz zur Spezialisierung auf die Rinderhaltung innerhalb des Alpenraums erkennen. Dies ist möglicherweise dadurch zu erklären, dass mit dem Wegfall der Selbstversorgung der Landwirtinnen und Landwirte Ackerbau nicht mehr notwendig ist, für welchen im Alpenraum ohnehin nur wenig geeignete Flächen zur Verfügung stehen (vgl. PENZ 2011, 23).

Innerhalb Österreichs gibt es jedoch regionale Unterschiede. In den östlichen Bergregionen ist die Betriebsaufgaberate höher als in den westlichen Regionen (insbesondere Salzburg und Tirol). Mögliche Gründe hierfür liegen in der Wirtschaftsstruktur der jeweiligen Regionen. Während in manchen Regionen altindustrialisierte Wirtschaftsstrukturen bestehen, in denen sich kaum Neben- und Zuerwerbsmöglichkeiten für Landwirtinnen und Landwirte ergeben, bieten viele westliche, strukturstarke Regionen attraktive außerlandwirtschaftliche Einnahmequellen, insbesondere im Tourismus. Gleichzeitig lässt sich in manchen Regionen auch eine umgekehrte Entwicklung beobachten: in Kärnten und der Steiermark ist die Betriebsaufgaberate insbesondere in stadtnahen, strukturstarken Regionen hoch (vgl. STREIFENEDER 2009, 43ff.).

Regionale Unterschiede innerhalb Österreichs gibt es auch aufgrund der zunehmenden Spezialisierung. Während die Bedeutung der pflanzlichen Erzeugung in den meisten Bundesländern stabil ist, nimmt sie im Burgenland, Niederösterreich und Salzburg zu, im Burgenland steigt dazu die Bedeutung des Gemüseanbaus deutlich. Während die Schweinehaltung in den meisten Bundesländern an Gewicht verliert, legt sie in Oberösterreich zu, um nur einige Beispiele von Spezialisierungstendenzen aufzuzeigen (vgl. SINABELL 2004, 6f.).

Neben der Tendenz zur Spezialisierung zeigt sich auch eine Tendenz zur Diversifizierung in der Landwirtschaft. Zu Diversifizierungsaktivitäten zählen Aktivitäten, die mit dem Betrieb direkt in Verbindung stehen und auch wirtschaftliche Auswirkungen auf diesen haben (vgl. KIRNER 2019, 3). 2016 stammten bereits 9,1% des gesamten landwirtschaftlichen Produktionswertes in

Österreichs aus Aktivitäten im Diversifizierungsbereich. 35% der land- und forstwirtschaftlichen Betriebe erzielten Einkünfte aus diesem Bereich. Ein großer Anteil dieser Einkünfte stammt aus Be- und Verarbeitung von landwirtschaftlichen Erzeugnissen für den Verkauf sowie touristischen Aktivitäten. Die Direktvermarktung ist eine mögliche Form der Diversifizierung. Rund 27% der landwirtschaftlichen Betriebe betreiben Direktvermarktung, für 13% der Betriebe ist diese von hoher wirtschaftlicher Bedeutung. Auch insgesamt nimmt die Bedeutung der Direktvermarktung für Landwirtinnen und Landwirte zu (vgl. KIRNER 2019, 1 ff.).

Neben Diversifizierung und Spezialisierung ist die Nebenerwerbstätigkeit eine weitere Möglichkeit für Landwirtinnen und Landwirte zusätzliches Einkommen zu generieren und so wettbewerbsfähig bleiben zu können. Im Rahmen einer Befragung stellt WIESINGER (2005) fest, dass bereits die Hälfte aller Jungbäuerinnen und Jungbauern einer außerlandwirtschaftlichen Erwerbstätigkeit nachgeht, hauptsächlich aus finanziellen Gründen (vgl. WIESINGER 2005, 172). In der österreichischen Agrarpolitik wird die Nebenerwerbslandwirtschaft auch gefördert (vgl. WEISS 1999, 104). WEISS erkennt in seiner Studie jedoch, dass die Wahrscheinlichkeit, dass Betriebe aufgegeben werden unter Nebenerwerbsbetrieben deutlich höher und das Betriebswachstum deutlich geringer ist (vgl. WEISS 1999, 114). Eine Studie von VOGEL et al. aus dem Jahr 2004 bestätigt dies. Die Autoren untersuchen Bestimmungsgründe für Flächenausweitungspläne von Landwirtinnen und Landwirten in Berggebieten und erkennen eine signifikant negative Korrelation zwischen dem Vorhandensein von Flächenausweitungsplänen und dem Merkmal Nebenerwerbsbetrieb. Eine negative Korrelation ergab sich auch für Biobetriebe, für den Fall, dass Frauen den Betrieb leiten, wenn die Hofnachfolge nicht gesichert ist sowie für Betriebe, die lediglich Ersatzinvestitionen tätigen (vgl. VOGEL et al. 2004, 76).

Im Unterschied dazu wachsen Betriebe, die Investitionsförderungen in Anspruch nehmen stärker als andere Betriebe (vgl. KIRCHWEGER und KANTELHARDT 2015, 86). Investitionsförderungen sind ein Teil der zweiten Säule der GAP und somit auch Teil der in dieser Arbeit zur Erklärung des Agrarstrukturwandels herangezogenen Agrarförderungen. Betriebe, welche Investitionsförderungen erhalten haben, wachsen sowohl was die von ihnen bewirtschaftete Fläche betrifft als auch die Anzahl an gehaltenen GVE betreffend. Da sich der Wachstumseffekt stärker auf die Betriebsgröße in Vieheinheiten als in LF auswirkt, bringt dies eine aus umweltpolitischer Sicht unerwünschte Intensivierung der Landwirtschaft in Österreich mit sich (vgl. KIRCHWEGER und KANTELHARDT 2015, 86).

Einen Hinweis auf den Einfluss von Agrarförderungen im Rahmen der GAP auf den Agrarstrukturwandel in Österreich liefert auch WAGNER (2015) in seiner Untersuchung der regionalen Strukturveränderungen in Österreichs Landwirtschaft seit dem EU-Beitritt (1995). Seine Analysen zeigen, dass sich insgesamt die Abnahmerate der landwirtschaftlichen Betriebe seit dem EU-Beitritt verstärkt hat. Dabei ist aber die Abnahmerate der Haupterwerbsbetrieben von -3,16% jährlich auf -1,25% jährlich zurückgegangen während die Abnahmerate der Nebenerwerbsbetriebe von -0,98% auf 3,07% gestiegen ist (vgl. WAGNER 2015, 78). Ein Grund hierfür könnte sein, dass sich größere Betriebe, welche tendenziell eher im Hauptbetrieb geführt werden, besser an die Instrumente und Förderungen der GAP anpassen. Diese Annahme legt die Arbeit von SCHMID (2007) nahe. Er erkennt, dass die Einkommenswirkung bei Direktzahlungen, Ausgleichszulagen und ÖPUL (Österreichisches Programm für umweltgerechte Landwirtschaft)-Prämien für große Betriebe größer ist. Als mögliche Gründe hierfür nennt der Autor eine höhere Flexibilität bezüglich Managementauflagen seitens größerer Betriebe sowie Skaleneffekte (vgl. SCHMID 2007, 82f.).

Indikatoren des Agrarstrukturwandels

Seit ihrer Einführung spielen Agrarförderungen im Rahmen der GAP eine immer größere Rolle bei der Entscheidungsfindung von Landwirtinnen und Landwirten, vor allem in benachteiligten Gebieten. Viele Landwirtinnen und Landwirte in benachteiligten Regionen führen ihren Betrieb nicht mehr nach den Gesichtspunkten marktwirtschaftlicher Effizienz sondern treffen Entscheidungen so, dass eine optimale Menge an Förderungen generiert werden kann. Die EU ist für Landwirtinnen und Landwirte damit weniger ein zusätzlicher Markt als vielmehr eine Quelle von Fördermitteln (vgl. WIESINGER 2005, 170).

3. Daten

In vielen wissenschaftlichen Arbeiten, die die Effekte verschiedener Faktoren auf die Betriebsaufgabewahrscheinlichkeit und die Entwicklung der Betriebsgrößen untersuchen, werden Daten auf Betriebsebene herangezogen. Im Rahmen der vorliegenden Arbeit stehen jedoch nur auf Gemeindeebene aggregierte Daten zur Verfügung. Es ist deshalb wichtig, die Gefahr sogenannter „ökologischer Fehlschlüsse“ zu berücksichtigen und solche zu vermeiden. Diese entstehen, wenn Rückschlüsse von ökologischen Korrelationen auf individuelle Korrelationen gezogen werden. Individuelle Korrelationen liegen vor, wenn das beschriebene Individuum unteilbar ist, also beispielsweise ein landwirtschaftlicher Betrieb. In ökologischen Korrelationen sind die statistischen Beobachtungseinheiten Gruppen von Individuen, im Rahmen der vorliegenden Arbeit die landwirtschaftlichen Betriebe in einer Gemeinde. Die Variablen werden dann in Prozentsätzen beschreibender Eigenschaften von Gruppen ausgedrückt und nicht als Eigenschaften eines Individuums (vgl. ROBINSON 2009, 337). Bei auf einzelbetrieblicher Ebene vorliegenden Daten würden auf Gemeindeebene erkennbare Korrelationen von der absoluten Häufigkeit auftretender individueller Korrelationen abhängen. Die in der vorliegenden Arbeit analysierten ökologischen Korrelationen hängen jedoch von den Randhäufigkeiten individueller Korrelationen ab. Aus Randhäufigkeiten kann jedoch nicht auf die tatsächliche Anzahl auftretender individueller Korrelationen geschlossen werden. Deshalb kann es sein, dass individuelle und ökologische Korrelation übereinstimmen ROBINSON (2009) zeigt jedoch auf, dass dies jedoch nicht immer der Fall sein muss (vgl. ROBINSON 2009, 338 f.).

OPENSHAW (1984) kritisiert jedoch, dass ROBINSON in seiner 1950 erstmals veröffentlichten Arbeit eher extreme denn typische Situationen für Unterschiede zwischen ökologischen und individuellen Korrelationen aufzeigt (vgl. OPENSHAW 1984, 19). Er zeigt in seiner Arbeit auf, dass Regressionen unter der Verwendung derselben Variablen auf Basis individueller sowie auf Basis räumlich aggregierter Daten ein ähnlich hohes Bestimmtheitsmaß aufweisen. Dennoch dürfen auf aggregierter Ebene geschätzte Parameter nicht auf die individuelle Ebene übertragen werden (vgl. OPENSHAW 1984, 26). Aus im Rahmen dieser Arbeit gewonnenen Erkenntnissen können also keine Aussagen über einzelbetriebliches Verhalten getroffen werden.

3.1. Abhängige Variablen

Die Entwicklung der Anzahl an landwirtschaftlichen Betrieben sowie deren Größe sind die wesentlichen Indikatoren des Agrarstrukturwandels (vgl. WEISS 1999, 103). In der wissenschaftlichen Literatur wird meist entweder die Anzahl an landwirtschaftlichen Betrieben bzw. deren Ausstiegsrate (z.B. STORM et al. 2014, FERJANI et al. 2015) oder die Entwicklung der Betriebsgrößen (z.B. STORM und HECKELEI 2018, AKIMOWICZ et al. 2013) als abhängige Variable gewählt. In manchen Studien wird jedoch auch der Effekt der abhängigen Variablen auf beide Indikatoren geschätzt (z.B. WEISS 1999), wie es auch in Rahmen dieser Arbeit erfolgen soll. Ein Grund dafür ist auch, dass die Daten nur auf Gemeinde-, nicht aber Betriebsebene vorliegen. Wenn ein Betrieb aufgibt, ohne dass dessen Flächen in einen anderen Betrieb übergehen, so spiegelt sich dies zwar in der Entwicklung der Anzahl an Betrieben in der Gemeinde wider. In der Entwicklung der durchschnittlichen Betriebsgrößen könnte diese Entwicklung möglicherweise aber unbeobachtet bleiben, wenn der aussteigende Betrieb eine in etwa durchschnittliche Betriebsgröße hatte. Der Vergleich des geschätzten Einflusses der abhängigen Variablen auf beide Indikatoren soll die Ergebnisse belastbarer machen.

Die Daten für sowohl die Anzahl der Betriebe als auch deren durchschnittliche Betriebsgröße können über die Gemeindedatenbank der BAB (Bundesanstalt für Agrarwirtschaft und Bergbauernwirtschaft) (2020) bezogen werden. Für die Anzahl an Betrieben werden die Hauptbetriebe nach INVEKOS (Integriertes Verwaltungs- und Kontrollsystem) herangezogen, jedoch minus der Anzahl an Gemeinschaftsalmen. Das Verwenden von INVEKOS-Daten hat gegenüber jenen der Agrarstrukturerhebung den Vorteil, dass Daten aus mehreren, aufeinanderfolgenden Jahren vorliegen. Gemeinschaftsalmen werden abgezogen, da diese von mehreren Betrieben bewirtschaftet werden, die so mehrmals in der Statistik aufscheinen würden.

Die durchschnittliche Betriebsgröße je Gemeinde ergibt sich aus der LF (ohne Alm) durch die Anzahl an Betrieben. Für die LF wurde die LF ohne Alm nach Betriebssitz herangezogen. Ohne Almen wiederum deshalb, weil diese möglicherweise als Gemeinschaftsalmen betrieben werden. Die Lage nach Betriebssitz wurde gewählt, da Betriebe möglicherweise auch Flächen außerhalb der eigenen Gemeinde besitzen, die sonst jenen Betrieben in dieser Gemeinde zugerechnet würden. Sowohl die Anzahl an landwirtschaftlichen Betrieben als auch die durchschnittliche Betriebsgröße in einer Gemeinde wurden aufgrund ihrer Verteilung sowie um eine aussagekräftigere Interpretation zu ermöglichen logarithmiert.

3.2. Unabhängige Variablen

Betriebsstruktur

Anteil Biobetriebe

Gegenüber dem Jahr 2000 hat die Anzahl an Biobetrieben um mehr als 25% zugenommen, gleichzeitig nahm aber der Anteil an biologisch bewirtschafteter LF an der gesamten LF ab (vgl. BMNT 2019, 175). Dies lässt darauf schließen, dass Biobetriebe weniger wahrscheinlich aus dem Betrieb aussteigen, aber ihr Betriebswachstum geringer ist. Ein hoher Anteil an Biobetrieben in einer Gemeinde wirkt sich deshalb wahrscheinlich positiv auf die Entwicklung der Betriebsanzahl und negativ deren durchschnittliche Betriebsgröße aus. Dieser vermutete Zusammenhang lässt sich auch in früheren Studien in anderen Regionen bereits erkennen. Laut FERJANI et al. (2015, 69) hat ein biologisch wirtschaftender Betrieb eine geringere Ausstiegswahrscheinlichkeit. BARTOLINI und VIAGGI (2013, 132) erkennen aber, dass diese eher von einer Reduzierung der LF betroffen sind. Daten über den Anteil an Biobetrieben entstammen ebenfalls der Gemeindedatenbank der BAB (2020) und werden in Prozent ausgedrückt. Anders als die Anzahl an landwirtschaftlichen Betrieben werden bei der Berechnung des Anteils an Biobetrieben Gemeinschaftsalmen berücksichtigt, und der Anteil an Biobetrieben wird auf Basis der Betriebe inkl. Gemeinschaftsalmen berechnet. Dies ist notwendig, da aus den Daten nicht hervorgeht, ob sich unter den Biobetrieben auch Gemeinschaftsalmen befinden. Es wird davon ausgegangen, dass der Anteil an Gemeinschaftsalmen unter den Biobetrieben ähnlich hoch ist wie unter den landwirtschaftlichen Betrieben insgesamt und somit nicht mit Verzerrungen zu rechnen ist.

Anteil Ackerflächen

Die Agrarstruktur einer Region spiegelt sich auch in der vorwiegenden Ausrichtung der landwirtschaftlichen Betriebe einer Region wider. Während sich im Osten Österreichs vor allem auf Ackerbau spezialisierte Betriebe befinden, spezialisieren sich Betriebe im alpinen Raum vor allem auf die (Milch-)Viehhaltung. In einigen wissenschaftlichen Arbeiten wurde bereits der Effekt der Ausrichtung eines Betriebes bzw. der vorwiegenden Betriebsausrichtung in einer

Region auf die Betriebsaufgabewahrscheinlichkeit bzw. das Wachstum von Betrieben untersucht und signifikante Effekte festgestellt (vgl. Kapitel 2.3). Für Österreich stellen NIEDERMAYR et al. (2015, 281) beispielsweise fest, dass sich ein hoher Anteil an Ackerflächen in einer Region negativ auf die Betriebsanzahl in einer Region im alpinen Raum auswirkt.

Als erklärende Variable für die vorwiegende Betriebsausrichtung in einer Gemeinde wird der Anteil der Ackerfläche an der gesamten LF in einer Gemeinde herangezogen. In der Literatur wird häufig der Anteil an Betrieben mit Viehhaltung herangezogen. Dabei werden aber auch Betriebe berücksichtigt, die nur eine geringe Anzahl an Tieren halten und deren hauptsächliche Betriebsausrichtung aber beispielsweise auch Ackerbau sein kann. Der Anteil an Ackerflächen an der gesamten LF in einer Gemeinde scheint deshalb als die hauptsächliche Betriebsausrichtung einer Gemeinde darstellende Variable geeigneter. Die entsprechenden Daten können ebenfalls über die Gemeindedatenbank (BAB 2020) bezogen werden und werden in Prozent berechnet. Herangezogen werden zur Berechnung die gesamte LF sowie die Ackerflächen nach Betriebssitz, damit den sich in einer Gemeinde befindlichen Betrieben auch ihre entsprechenden Flächen zugeordnet werden.

GVE je Hektar

Eine weiterer die Betriebsstruktur in einer Gemeinde widerspiegelnde Variable ist der Viehbesatz, meist ausgedrückt in GVE je Hektar LF. Rinder, Schweine oder Geflügel haltende Betriebe unterliegen anderen Produktionsbedingungen als vorwiegend auf den Ackerbau ausgerichtete Betriebe, was sich auch auf deren Ausstiegsrate und Größenentwicklung auswirken könnte. So stellen BREUSTEDT und GLAUBEN (2007, 121) beispielsweise fest, dass ein höherer Anteil an Vieh haltenden Betrieben sich negativ auf die Ausstiegsrate von landwirtschaftlichen Betrieben in einer Region auswirkt, während in Regionen mit einem höheren Anteil an Ackerbau die Anzahl an landwirtschaftlichen Betrieben stärker zurückgeht. Wird der Anteil an Betrieben mit Viehhaltung berücksichtigt, werden jedoch auch Betriebe berücksichtigt, welche nur eine geringe Anzahl an Nutztieren halten, was den geschätzten Effekt verzerren könnte. Deshalb werden im Rahmen dieser Arbeit die GVE je Hektar LF (nach Betriebssitz) herangezogen.

Standortabhängige Faktoren

LF

Eine wesentliche Variable, welche vor allem die Anzahl an landwirtschaftlichen Betrieben in einer Gemeinde beeinflusst, ist der Umfang der von den Betrieben einer Gemeinde bewirtschafteten LF. Es ist eine positive Korrelation zu erwarten: je mehr LF von den Betrieben in einer Gemeinde bewirtschaftet wird, desto höher ist die Anzahl an Betrieben in dieser Gemeinde. Ist die abhängige Variable eines Modells die Anzahl an Betrieben in einer Gemeinde, ist die bewirtschaftete LF auch deshalb zu berücksichtigen, weil sie die Größe einer Gemeinde widerspiegelt. Diese beeinflusst wiederum stark die Anzahl an landwirtschaftlichen Betrieben in dieser Gemeinde: je größer eine Gemeinde, desto mehr landwirtschaftliche Betriebe sind zu erwarten. Herangezogen wird die landwirtschaftliche Nutzfläche nach Betriebssitz (ohne Almen). Die Daten hierzu entstammen der Gemeindedatenbank (BAB 2020). Aufgrund ihrer Verteilung und um eine einfachere Interpretation der Ergebnisse zu ermöglichen, wird diese Variable logarithmiert.

Bruttoregionalprodukt (BRP) pro Kopf

Mit dem Bruttoregionalprodukt sollen die makroökonomischen Rahmenbedingungen, in welchem sich die landwirtschaftlichen Betriebe bewegen erfasst werden. Ein hohes bzw. niedriges BRP pro Kopf könnte sich über unterschiedliche Effekte auf den Agrarstrukturwandel in einer Region auswirken. Einerseits geht mit einem hohen bzw. niedrigen BRP wahrscheinlich auch eine niedrige bzw. hohe Arbeitslosenquote in einer Region einher (Daten zu Arbeitslosenquote konnten nicht in ausreichendem Umfang bezogen werden). Eine hohe Arbeitslosenquote könnte Landwirtinnen und Landwirte davon abhalten, ihren Betrieb aufzugeben, da sie möglicherweise auch keine anderen Einkommensmöglichkeiten finden würden. Eine niedrige Arbeitslosenquote hingegen könnte sich einerseits positiv auf die Betriebsanzahl auswirken, da durch es durch ausreichend Einkommensmöglichkeiten außerhalb der Landwirtschaft für die Landwirtinnen und Landwirte leichter ist, ihren Betrieb zu erhalten. Andererseits wird es aber auch attraktiver für sie, aus der Landwirtschaft auszusteigen und sich ihr Einkommen gänzlich außerhalb der Landwirtschaft zu erwirtschaften (vgl. FERJANI et al. 2015; GLAUBEN et al. 2006, 112). Einen weiteren Effekt könnte das BRP auch über den Wettkampf um Boden auf den Agrarstrukturwandel haben. So entsteht möglicherweise in einer wirtschaftlich starken Region ein intensiverer Wettkampf um Flächen, der zu einem höheren Bodenpreis und damit eingeschränkten Wachstumsmöglichkeiten für landwirtschaftliche Betriebe führt.

Die Daten für das BRP pro Kopf können über STATISTIK AUSTRIA (2019) bezogen werden. Es wird das BRP pro Kopf in tausend Euro herangezogen, sodass die Werte für alle Regionen vergleichbar sind und nicht für große bzw. einwohnerreiche Regionen überbewertet werden. Die Daten liegen auf NUTS3 (*Nomenclature des unités territoriales statistiques* – räumliche Bezugseinheiten der EU-Statistiken) -Ebene vor, jede NUTS3-Region umfasst dabei ein bis fünf Bezirke. Die Variable wird logarithmiert, um eine einfachere Interpretation der Schätzer zu ermöglichen.

Höhe über Normalnull (NN)

Ein großer Teil Österreichs liegt im alpinen Raum. Dort herrschen im Gegensatz zum Flach- und Hügelland andere geographische und klimatische Bedingungen, die sich beispielsweise über andere Fördermöglichkeiten (z.B. AZ) und Produktionsbedingungen auch auf den Agrarstrukturwandel auswirken. Bisherige Studien konnten keinen Effekt der Lage in einem benachteiligten und/oder Berggebiet auf die Entwicklung der Betriebsanzahl erkennen, wohl aber, dass das Betriebswachstum in Gebirgsregionen weniger stark ausgeprägt ist (vgl. BARTOLINI und VIAGGI 2013, 133).

Herangezogen wird der Median der Seehöhe bezogen auf die landwirtschaftliche Nutzfläche jeder Gemeinde. Hierzu werden zuerst die Gemeindegrenzen (BEV 2019, online) mit den INVEKOS Schlägen Österreichs 2018 (AMA 2018, online) verschnitten, sodass die landwirtschaftliche Nutzfläche je Gemeinde als ein Polygon vorliegt. Der nächste Schritt ist die Verschneidung dieser Daten mit dem digitalen Geländemodell Österreichs (GEOLAND.AT 2020, online). Der so berechnete Median der Seehöhe wird skaliert, sodass eine Einheit 100 Meter entspricht, was eine aussagekräftigere Interpretation der Schätzer ermöglichen soll. Die durchschnittliche Seehöhe wird deshalb gewählt, weil diese die in der Realität herrschenden Bedingungen besser widerspiegelt als etwa die Zugehörigkeit einer Gemeinde zur Alpenkonvention und Daten für alle Gemeinden vorhanden sind.

Bevölkerungsdichte

In dicht besiedelten Gemeinden ist die Konkurrenz um Boden und damit Bodenpreise höher, was sich auch auf die Entwicklungsmöglichkeiten von landwirtschaftlichen Betrieben auswirkt. Es wird angenommen, dass deshalb Betriebe in dünn besiedelten Gemeinden stärker wachsen als in urbaneren Gemeinden, wie dies auch AKIMOWICZ et al. (2013) in ihrer Arbeit erkennen. Der mögliche Einfluss der Bevölkerungsdichte auf die Entwicklung der Betriebsanzahl lässt sich aus der vorhandenen Literatur nicht ableiten. Möglich ist, dass sich verschiedene Effekte aufheben. So gibt es in bevölkerungsreichen Gemeinden beispielsweise gut ausgebaute Infrastruktur und Akteursnetzwerke, jedoch könnte der angesprochene höhere Bodenpreis Landwirtinnen und Landwirte dazu veranlassen, ihre Flächen zu veräußern bzw. zu verpachten. Die Daten zur Bevölkerungsdichte können ebenfalls über die Gemeindedatenbank (BAB 2020) bezogen werden. Auch bei dieser Variablen erfolgt eine Skalierung, sodass eine Einheit 100 Einwohnerinnen und Einwohner (EW) je Quadratkilometer entspricht.

Übernachtungsintensität

Die Diversifizierung von Tätigkeiten und Produktionsverfahren in landwirtschaftlichen Betrieben ist ein Ausdruck des Agrarstrukturwandels (vgl. KIRCHWEGER und KANTELHARDT 2015, 73). Vermutet wird, dass sich besonders in touristisch geprägten Regionen viele Möglichkeiten zur Diversifizierung ergeben und somit die Wahrscheinlichkeit der Betriebsaufgabe geringer ist als in weniger touristischen Regionen. Beispielsweise kann durch das Anbieten von Ferienunterkünften auf dem Betrieb zusätzliches Einkommen generiert werden und viele Touristinnen und Touristen in der Region bedeuten bessere Absatzmöglichkeiten in der Direktvermarktung. Ein gegenläufiger Effekt von einem hohen Tourismusaufkommen könnte jedoch gesteigerte Flächenkonkurrenz sein, was einen negativen Effekt auf das Wachstum von landwirtschaftlichen Betrieben haben könnte.

Herangezogen wird als Kennzahl die Übernachtungsintensität, also die Anzahl an Übernachtungen (ÜN) je Einwohnerin und Jahr. Diese Kennzahl kann ebenfalls anhand der in der Gemeindedatenbank (BAB 2020) verfügbaren Daten zur Anzahl an EW und Übernachtungen in einer Gemeinde berechnet werden. Die Variable wird, um eine aussagekräftigere Interpretation der Ergebnisse zu ermöglichen, skaliert, sodass eine Einheit zehn ÜN je EW und Jahr entspricht.

Agrarförderungen

Agrarförderungen stellen heute einen wichtigen Bestandteil des Einkommens landwirtschaftlicher Betriebe dar (vgl. BMNT 2019, 102). Insbesondere bäuerliche Familienbetriebe, die noch heute 90% der landwirtschaftlichen Betriebe Österreichs ausmachen, wären ohne diese wohl nicht mehr konkurrenzfähig. Sie zu erhalten, und damit den Agrarstrukturwandel zu bremsen, kann als eines der Ziele der GAP identifiziert werden (vgl. QUENDLER 2015, 60f.). Tatsächlich lassen sich in der wissenschaftlichen Literatur Effekte von Agrarförderungen auf den Agrarstrukturwandel erkennen (vgl. Kapitel 2.3).

Im Rahmen dieser Arbeit stehen Daten zu den Agrarförderungen aus der GAP, aggregiert auf Gemeindeebene, zur Verfügung. Agrarförderungen im Rahmen der GAP setzen sich aus zwei Säulen zusammen. Die 1. Säule umfasst Marktordnungsausgaben, darunter insbesondere die Direktzahlungen (Basis- und Greening-Prämie, Förderungen für Junglandwirte, Umverteilungsprämien, Einkommensstützungen und gekoppelte Zahlungen) an die Betriebe sowie weitere Zahlungen (z.B. Beihilfen für den Weinbau) (vgl. BMNT 2019, 104f.). Ziel der

Zahlungen aus der 2. Säule der GAP ist die Entwicklung des ländlichen Raumes. Zahlungen aus dieser Säule werden nicht nur an landwirtschaftliche Betriebe (z.B. im Rahmen der AZ für benachteiligte Gebiete) sondern auch an sonstige Firmen und Institutionen ausbezahlt (z.B. im Rahmen des LEADER (*Liaison entre actions de développement de l'économie rurale* – Maßnahmenprogramm der EU zur ländlichen Entwicklung) -Programms) (vgl. BMNT 2019, 105f.). Der Effekt der Agrarförderungen im Rahmen der GAP soll für die 1. und 2. Säule getrennt untersucht werden. Während Förderungen der 1. Säule direkt an die Betriebe ausbezahlt werden und so einen direkten Effekt auf deren betriebliche Entscheidungen haben, könnten sich Zahlungen aus der 2. Säule auch über andere Mechanismen auf die Entscheidung der Landwirtinnen und Landwirte in einer Gemeinde auswirken.

Aus diesem Grund werden die Agrarförderungen der 1. Säule als eine Variable herangezogen, die Effekte der 2. Säule werden anhand von drei unterschiedlichen Variablen untersucht: erstens die Summe der Zahlungen im Rahmen des ÖPUL und der AZ für naturbedingte Nachteile, zweitens die Förderungen für materielle Investitionen und drittens die Summe aus fünf verschiedenen Fördermaßnahmen, die nicht nur an landwirtschaftliche Betriebe ausbezahlt werden, sondern an verschiedenste Zahlungsempfänger mit dem Ziel, die ländliche Entwicklung zu fördern.

Bei diesen fünf Förderungen handelt es sich um die Fördermaßnahmen Wissenstransfer und Information, Beratungsdienste, Basisdienstleistung und Dorferneuerung, Zusammenarbeit sowie LEADER. Die 2. Säule der Agrarförderungen im Rahmen der GAP enthält noch weitere Fördermaßnahmen, die jedoch im Rahmen dieser Arbeit nicht berücksichtigt werden. Diese Maßnahmen werden überwiegend direkt an individuelle (landwirtschaftliche) Betriebe ausbezahlt und umfassen jeweils nur maximal rund 3% des Budgets der 2. Säule pro Jahr. Auch um die Komplexität des Modells zu verringern und einen Overfit zu vermeiden werden diese Zahlungen nicht berücksichtigt. ÖPUL und AZ umfassen je nach Jahr in Summe zwischen 66 und 86%, Zahlungen für materielle Investitionen zwischen 4 und 16%, und die Summe aus den weiteren genannten Maßnahmen für ländliche Entwicklung zwischen 5 und 20% des Budgets der 2. Säule (vgl. BAB 2020, s.p.).

Unklar ist, ob der Effekt der Agrarförderungen anhand ihrer absoluten Höhe oder relativ, also als Förderintensität beispielsweise je Hektar, geschätzt werden sollte (vgl. STORM et al. 2014, 1194). Im Rahmen dieser Arbeit soll, aus zwei Gründen, die relative Förderintensität herangezogen werden. Ein Grund ist, dass mögliche ceteris-paribus-Folgerungen aussagekräftiger sind, da die Daten auf Gemeindeebene aggregiert sind und somit Aussagen über Gruppen von Betrieben getroffen werden. Ein weiterer Grund liegt in den statistischen Eigenschaften der vorliegenden Daten. Werden Förderintensitäten berechnet, führt dies zu weniger einflussreichen Ausreißern, die Verteilung der Daten liegt näher an der Normalverteilung und der Variationskoeffizient ist deutlich geringer.

Agrarförderungen der 1. Säule sowie im Rahmen von ÖPUL und AZ sind überwiegend flächenbezogen. Die Förderintensität dieser beiden Variablen wird deshalb in tausend Euro je Hektar ausgedrückt. Förderungen für materielle Investitionen hingegen sind nicht flächenbezogen und werden deshalb in tausend Euro je Betrieb berechnet. Die weiteren Förderungen der 2. Säule richten sich meist an die gesamte Bevölkerung einer Gemeinde. Aus diesem Grund soll diese Variable in tausend Euro je Einwohnerin ausgedrückt werden. Die Datengrundlage für alle Variablen im Bezug auf Agrarförderungen ist ebenfalls die Gemeindedatenbank (BAB 2020). Die Daten werden logarithmiert, um den Effekt von Ausreißern zu minimieren und um eine einfachere Interpretation der Modellergebnisse zu ermöglichen.

3.3. Deskriptive Statistik

Die Datengrundlage der vorliegenden Arbeit umfasst die Beobachtungen der in Tabelle 5 angeführten Variablen in 2.066 österreichischen Gemeinden. Der Beobachtungszeitraum umfasst 15 Jahre (2003 bis 2017). In diesem Zeitraum sind in allen Jahren Daten für alle berücksichtigten Variablen verfügbar. Dies ergibt in Summe 30.990 Beobachtungen. Insgesamt 29 Gemeinden wurden nicht berücksichtigt. Darunter befinden sich alle Gemeinden, in denen sich keine LF befindet und/oder während eines Großteils des Beobachtungszeitraums kein oder nur ein landwirtschaftlicher Betrieb seinen Sitz in dieser Gemeinde hat. Einige Gemeinden wurden nicht berücksichtigt, da sie sich aufgrund sehr hoher Summen an Agrarförderungen als einflussreiche Ausreißer erwiesen. Grund hierfür waren entweder hohe Summen an Förderungen der 1. Säule je Hektar (beispielsweise aufgrund hoher Beihilfen an Erzeugerorganisationen in einzelnen Jahren) oder hohe Summen an Förderungen für materielle Investitionen in einzelnen Jahren.

Die abhängigen Variablen, das Bruttoregionalprodukt je Einwohnerin, die LF (nach Sitz) in einer Gemeinde so wie alle die Agrarförderungen betreffenden Variablen wurden log-transformiert. Hierfür wurde für alle Beobachtungen und transformierten Beobachtungen zuerst eine Konstante von eins addiert, um zu vermeiden, dass das Vorliegen von Nullen bei einzelnen Beobachtungen zu Fehlwerten führt (vgl. WOOLDRIDGE 2012, 193). Darüber hinaus wurden negative Werte in Null umgewandelt. Dies war jedoch nur bei wenigen Beobachtungen erforderlich, wenn Rückzahlungen von Agrarförderungen, die in diesem Jahr ausbezahlten Agrarförderungen überstiegen.

Tabelle 5 fasst die deskriptive Statistik aller Variablen zusammen und zeigt das vermutete Vorzeichen der Korrelation zwischen den abhängigen und den unabhängigen Variablen auf. Zur besseren Verständlichkeit sind alle zur Schätzung der ökonometrischen Modelle logarithmierten Variablen in dieser Tabelle nicht logarithmiert.

Daten

| Variable (wenn nicht anders angegeben auf Gemeindeebene) | verm. Einfluss auf Anzahl Betriebe | verm. Einfluss auf Ø Betriebsgröße | Minimum | Maximum | Mittelwert | Median | Standardabw. |
|--|------------------------------------|------------------------------------|---------|-----------|------------|--------|--------------|
| erklärte Variablen | | | | | | | |
| Anzahl Betriebe | | | 0 | 633 | 61,70 | 49,00 | 52,92 |
| Ø Betriebsgröße in ha | | | 2,44 | 344,69 | 20,61 | 16,71 | 15,79 |
| erklärende Variablen | | | | | | | |
| Anteil Biobetriebe (%) | + | - | 0,00 | 100,00 | 15,86 | 11,11 | 0,96 |
| Anteil Acker an LF (%) | - | + | 0,00 | 100,00 | 46,89 | 46,71 | 0,77 |
| Seehöhe über NN (in 100m) | + | - | 1,16 | 25,64 | 6,88 | 5,03 | 5,24 |
| BRP pro Kopf (Tsd. €) auf NUTS3 Ebene | - | + | 14,90 | 54,50 | 30,51 | 28,60 | 8,57 |
| (EW je km ²) / 100 | ? | ? | 0,01 | 27,58 | 1,22 | 0,68 | 1,61 |
| LF | + | | 7,19 | 12.093,89 | 1.119,06 | 841,72 | 1.025,61 |
| GVE je ha | + | - | 0,00 | 6,40 | 1,07 | 1,15 | 0,60 |
| (Nächtigungen je EW und Jahr) / 10 | + | - | 0,00 | 148,66 | 2,84 | 0,20 | 3,02 |
| Förderungen Säule 1 je ha (Tsd. €) | + | - | 0,00 | 1,68 | 0,26 | 0,28 | 0,11 |
| ÖPUL + AZ je ha (Tsd. €) | + | - | 0,00 | 3,25 | 0,42 | 0,33 | 0,29 |
| Investitionsförderung je Betrieb (Tsd. €) | - | + | 0,00 | 91,11 | 0,76 | 0,25 | 2,07 |
| Weitere Förderungen Säule 2 je EW (Tsd. €) | + | - | 0,00 | 2,63 | 0,02 | 0,00 | 0,06 |

Tabelle 5: Zusammenfassung der deskriptiven Statistik. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

4. Methoden

4.1. Konzeptioneller Rahmen

Auf welche Art und Weise und in welcher Geschwindigkeit sich der Agrarstrukturwandel in Österreich entwickelt hängt letztendlich von den betrieblichen Entscheidungen der Landwirtinnen und Landwirte ab. Wie diese Entscheidungen ausfallen ist wiederum abhängig von verschiedensten Faktoren, wie sie in Kapitel 2.3 zusammengefasst wurden (wobei hierbei kein Anspruch auf Vollständigkeit besteht). Sie werden im Rahmen dieser Arbeit zusammengefasst als Faktoren des Humankapitals, der Betriebsstruktur, standortabhängige Faktoren sowie den Agrarförderungen. Ob eine Landwirtin oder ein Landwirt den Betrieb aufgibt oder weiterführt sowie Entscheidungen bezüglich der bewirtschafteten Fläche lassen sich deshalb als Funktion der genannten Faktoren ausdrücken:

$$y_i \text{ bzw. } \Delta LF = f(\text{Humankapital}, \text{Betriebsstruktur}, \text{Standortfaktoren}, \text{Agrarförderungen})$$

wobei die y_i zwei mögliche Ausprägungen besitzt (Betrieb weiterführen oder Betrieb aufgeben) und die abhängige Variable ΔLF die Änderung in der bewirtschafteten landschaftlichen Nutzfläche eines Betriebes beschreibt.

Landwirtinnen und Landwirte agieren dabei nicht isoliert, sondern sind (neben weiteren Mechanismen wie beispielsweise einem Informationsnetzwerk) insbesondere über den Wettkampf um Boden auch von den Entscheidungen benachbarter Landwirtinnen und Landwirte abhängig. Landwirtschaftlich nutzbarer Boden ist ein Gut, welches nur in einer bestimmten, fixen Menge verfügbar ist. Weitet ein Betrieb seine LF aus, muss ein anderer weichen (vgl. STORM et al. 2014, 1193f.). Entscheidend dafür, ob eine Einheit LF die Pächterin oder den Pächter bzw. die Besitzerin oder den Besitzer wechselt, ist die WTP der am Bodenmarkt beteiligten Betriebe. Abhängigkeiten zwischen den beteiligten Betrieben entstehen dadurch, dass die Entscheidung, Boden zu (ver-)pachten oder (ver-)kaufen abhängig davon ist, wie hoch die eigene WTP im Verhältnis zur WTP benachbarter Betriebe ist (vgl. STORM et al. 2014, 1193).

Die WTP für eine Einheit LF kann gleichgesetzt werden mit dem Grenznutzen aus der Bewirtschaftung dieser Einheit nach Abzug aller Kosten, die der Landwirtin oder dem Landwirt durch die Bewirtschaftung entstehen (vgl. STORM et al. 2014, 1194). Sie ist damit abhängig von Betriebseigenschaften wie dem Humankapital und der Betriebsstruktur, die bereits eingangs als Einflussfaktoren auf die betrieblichen Entscheidungen beschrieben wurden. Einen Einfluss auf die WTP haben daneben standortabhängige Faktoren wie beispielsweise die Bevölkerungsdichte oder das BRP in der Region, in welcher sich ein Betrieb befindet. So stellen SAINT-CYR et al. (2019, 255) beispielsweise fest, dass in Regionen mit einer hohen Arbeitslosenquote Betriebe eher weniger wahrscheinlich ihren Betrieb aufgeben. Dies könnte dadurch erklärt werden, dass es in der Region wenig Einkommensalternativen zur Landwirtschaft gibt und damit die Opportunitätskosten für das Weiterführen des Betriebes sinken und im Umkehrschluss die WTP für LF steigt.

Einen wesentlichen Einfluss auf die WTP haben die Agrarförderungen (im Fall der vorliegenden Arbeit jene Agrarförderungen im Rahmen der GAP), sie sind im Rahmen dieser Arbeit von besonderem Interesse. Zahlungen an die Landwirtinnen und Landwirte erhöhen deren Liquidität, erhöhen den Nettowert eines Betriebes, wodurch diese auch leichter Kredite aufnehmen können und machen Landwirtschaft profitabler gegenüber außerlandwirtschaftlichen Einkommensarten.

Dies führt dazu, dass Agrarförderungen die WTP für LF erhöhen und sich somit Bodenpreise erhöhen (vgl. KEY und ROBERTS 2006, 383). Damit haben nicht nur die Agrarförderungen, die ein Betrieb erhält, einen Einfluss auf die Betriebsentscheidungen, sondern über die WTP auch die Agrarförderungen, die Nachbarbetriebe erhalten.

Da aber nicht nur Agrarförderungen, sondern auch die Faktoren des Humankapitals, der Betriebsstruktur sowie Standortfaktoren die betrieblichen Entscheidungen benachbarter Landwirtinnen und Landwirte bzw. jene der Landwirtinnen und Landwirte in der Region beeinflussen, soll, zumindest explorativ, auch der Einfluss weiterer Faktoren auf lokaler bzw. regionaler Ebene untersucht werden, wenn auch der Schwerpunkt auf der Analyse des Einflusses der Agrarförderungen liegt. Die eingangs vorgestellte Funktion sollen also erweitert werden:

$$y_i \text{ bzw. } \Delta LF = f(\text{Humankapital, Betriebsstruktur, Standortfaktoren, Agrarförderungen, Humankapital_Nachbarbetriebe, Betriebsstruktur_Nachbarbetriebe, Standortfaktoren_Nachbarbetriebe, Agrarförderungen_Nachbarbetriebe})$$

Es ist anzunehmen, dass höhere Zahlungen an Nachbarbetriebe zu einer höheren WTP für LF und damit höheren Bodenpreisen führt, was den Grenznutzen und damit die WTP für LF beim betrachteten Betrieb verringert. Damit erhöht sich möglicherweise die Wahrscheinlichkeit, dass dieser aus der Landwirtschaft aussteigt oder den Umfang der bewirtschafteten LF reduziert. Auf lokaler Ebene könnten Agrarförderungen also, entgegen ihres eigentlichen Ziels, dazu führen, dass der Strukturwandel rascher voranschreitet (vgl. STORM et al. 2014, 1195). Auf einer höheren Ebene betrachtet hat sich jedoch gezeigt, dass Agrarförderungen ihr Ziel erreichen, möglichst viele landwirtschaftliche Betriebe zu erhalten (z.B. GLAUBEN et al. 2006, BREUSTEDT und GLAUBEN 2007, MANN 2003).

STORM und HECKELEI (2018) vermuten, dass unbeobachtete Effekte, welche auf der höheren, regionalen Ebene wirken, für diese unterschiedlichen Vorzeichen des Einflusses von Agrarförderungen auf lokaler und regionaler Ebene verantwortlich sind. Sie nehmen deshalb zusätzlich zu den Agrarförderungen auf einzelbetrieblicher Ebene die Agrarförderungen an Betriebe in der Nachbarschaft sowie Betriebe in der Region als Faktoren in ihr Modell auf, mit welchem das Wachstum von Betrieben erklärt werden soll. Sie überprüfen so, ob sich ihre Vermutung bewahrheiten lässt und durch das Berücksichtigen der Agrarförderungen auf lokaler und regionaler Ebene als Faktoren diese unbeobachteten Effekte berücksichtigt werden können (vgl. STORM und HECKELEI 2018, 1f.). Tatsächlich zeigen ihre Ergebnisse, dass Agrarförderungen auf lokaler Ebene einen negativen Effekt haben, während dieser auf der regionalen Ebene positiv ist (vgl. STORM und HECKELEI 2018, 6). STORM und HECKELEI (2018) untersuchen diesen Zusammenhang in Norwegen auf Basis der dort ausbezahlten Agrarförderungen und nicht im Rahmen der Förderungen aus der GAP. Darüber hinaus haben sie Zugriff auf einzelbetriebliche Daten.

Im Rahmen der vorliegenden Arbeit werden jene Agrarförderungen herangezogen, welche im Rahmen der GAP an die Betriebe ausbezahlt werden. Darüber hinaus stehen keine Daten auf einzelbetrieblicher Ebene zur Verfügung, sondern lediglich auf Gemeindeebene und damit bereits auf einer lokalen Ebene aggregierte Daten. Beobachtungseinheit sind deshalb nicht individuelle Betriebe, sondern jeweils die Gruppe der landwirtschaftlichen Betriebe einer Gemeinde. Abbildung 1 zeigt in grafischer Form die hier erläuterten, vermuteten Zusammenhänge.

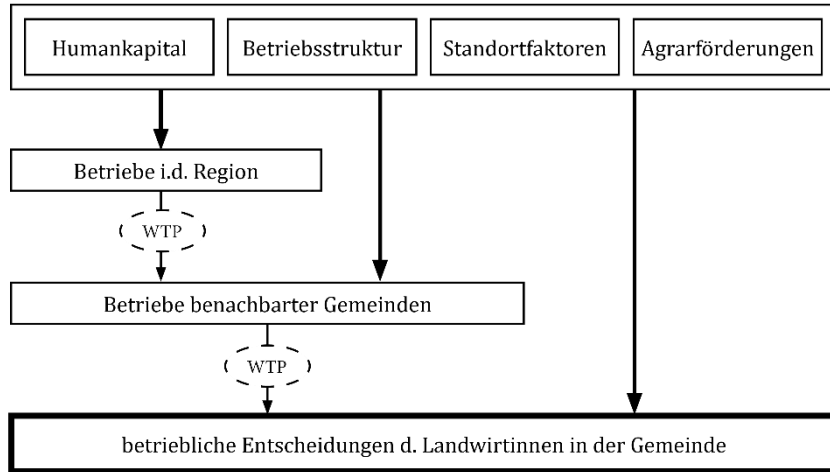


Abbildung 1: Theoretische Annahmen. Quelle: eigene Darstellung.

4.2. Lineare Regressionsmodelle

4.2.1. Das OLS-Regressionsmodell

Die in Kapitel 4.1 getroffenen theoretischen Annahmen können mit Hilfe von ökonometrischen Modellen untersucht werden. Hierzu müssen Funktionen der Form

$$y = f(x_1, x_2, \dots, x_k) \quad (4.1)$$

in ökonometrische Modelle der Form

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u \quad (4.2)$$

umgewandelt werden (vgl. WOOLDRIDGE 2020, 3f.). Dabei kann y als abhängige Variable und x_1, x_2, \dots, x_n als deren beschreibende, unabhängige Variablen bezeichnet werden. $\beta_0, \beta_1, \dots, \beta_k$ sind Parameter, die den Einfluss von x_1, x_2, \dots, x_k auf y beschreiben. k ist die Anzahl an unabhängigen Variablen. Der Fehlerterm u beinhaltet unbeobachtete Variablen, welche jedoch ebenfalls einen Einfluss auf y_i haben (vgl. WOOLDRIDGE 2020, 3).

Anhand eines statistischen Schätzverfahrens wird nun der Einfluss der unabhängigen Variablen x_1, x_2, \dots, x_k abgeschätzt. Dieses benötigt ein Kriterium, mit dem die Güte der Schätzung ermittelt wird. Sehr häufig wird die Methode der gewöhnlichen kleinsten Quadrate (eng. *Ordinary Least Squares* = OLS) gewählt (vgl. ECKEY et al. 2011 24). Das Kriterium, das hierbei für die Schätzung der Parameter $\beta_0, \beta_1, \dots, \beta_k$ herangezogen wird, ist die Summe der quadrierten Fehlerterme (= Residuen):

$$\sum_{i=1}^n \hat{u}_i^2 = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik})^2 \quad (4.3)$$

wobei die geschätzten Parameter $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$ so gewählt werden, dass die Summe der quadrierten Residuen $\sum_{i=1}^n \hat{u}_i^2$ möglichst klein ist (vgl. WOOLDRIDGE 2012, 30). Das Ergebnis der Schätzung ist eine Regressionsgleichung der Form

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik} \quad (4.4)$$

wobei \hat{y} der geschätzte Wert der abhängigen Variable y ist (vgl. WOOLDRIDGE 2012, 30).

Um zu messen, wie gut die so geschätzte Funktion die tatsächlich beobachteten Werte widerspiegelt, kann das R^2 , oft auch Determinationskoeffizient oder Bestimmtheitsmaß genannt (vgl. ECKEY et al. 2011, 50), herangezogen werden (vgl. WOOLDRIDGE 2012, 37f.):

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.5)$$

oder in der Kurzform

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST} \quad (4.6)$$

wobei SST die Summe der gesamten Abweichungsquadrate, SSE die Summe der erklärten Abweichungsquadrate und SSR die Summe der quadrierten Residuen umfasst (vgl. ECKEY et al. 2011, 109; WOOLDRIDGE 2012, 37f.). Da SSE nicht größer sein kann als SST, bewegt sich R^2 immer zwischen null und eins. Je näher das R^2 an eins liegt, desto besser wird die Streuung der Werte von y_i durch die mittels OLS geschätzten Werte \hat{y}_i erklärt. Ein niedriges R^2 bedeutet jedoch nicht unbedingt, dass die geschätzte OLS-Regressionsgleichung wertlos ist. Ceteris paribus Aussagen über den Zusammenhang zwischen den unabhängigen Variablen und den abhängigen Variablen können möglicherweise dennoch gut geschätzt werden (vgl. WOOLDRIDGE 2020, 35).

Nach dem Gauß-Markov-Theorem liefert OLS den besten, linearen, unverzerrten Schätzer (*best linear unbiased estimator* – *BLUE*) unter den folgenden Annahmen für das geschätzte Modell (vgl. WOOLDRIDGE 2020 95):

1. Es ist linear in seinen Parametern und kann in der Form $y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u$ geschrieben werden. Nichtlineare Einflüsse können dabei trotzdem auf unterschiedliche Weise, z.B. durch logarithmieren von Variablen modelliert werden (vgl. WOOLDRIDGE 2020, 80).
2. Es handelt sich um eine per Zufall gezogene Stichprobe aus der Grundgesamtheit mit dem Umfang n (vgl. WOOLDRIDGE 2020, 80). Dies bedeutet, dass die Ziehungen über die Grundgesamtheit gleich verteilt sein müssen (vgl. WOOLDRIDGE 2020, 56). In der vorliegenden Arbeit wird die Grundgesamtheit herangezogen, weshalb diese Annahme erfüllt ist, auch wenn die Stichproben nicht zufällig gezogen wurden.
3. Keine perfekte Kollinearität zwischen abhängigen Variablen liegt vor und keine der abhängigen Variablen ist konstant (vgl. WOOLDRIDGE 2020, 80).
4. Jeder Fehler u hat einen Erwartungswert von null für alle Werte der unabhängigen Variablen: $E(u|x_1, x_2, \dots, x_k) = 0$ (vgl. WOOLDRIDGE 2012, 86).
5. Die Varianz der Fehler u ist für alle Werte der unabhängigen Variablen konstant (Homoskedastie): $Var(u|x_1, x_2, \dots, x_k) = \sigma^2$ (vgl. WOOLDRIDGE 2012, 93).

4.2.2. Panelökonometrische Modelle

Abhängig von der Datenverfügbarkeit und der Fragestellung können unterschiedliche ökonometrische Methoden angewendet werden. Das im vorhergehenden Kapitel vorgestellte OLS-Regressionsmodell kann dabei als Ausgangspunkt verstanden werden.

Bei den im Rahmen dieser Arbeit verwendeten Daten handelt es sich um einen Paneldatensatz. Im Falle von Paneldaten können Annahmen 4 und 5 des Gauß-Markov-Theorems verletzt werden, weshalb geeignete ökonometrische Methoden gewählt werden müssen (vgl. WOOLDRIDGE 2012,

412f.). Paneldaten können Auskunft über zwei Dimensionen der Variablen geben, nämlich sowohl über die Querschnitts- als auch über die Zeitdimension. In der Querschnittsdimension können Erkenntnisse über Zusammenhänge durch Betrachtung der einzelnen Individuen gewonnen werden, ohne die Zeitreihendimension zu berücksichtigen. In der Zeitreihendimension können die Zusammenhänge für ein Individuum untersucht werden, indem dessen Zeitreihendaten herangezogen werden. In Panelmodellen werden beide Dimensionen gleichzeitig berücksichtigt (vgl. ECKEY et al. 2011, 285).

Paneldaten und damit Paneldatenmodelle haben gegenüber Zeitreihen- und Querschnittsdaten einige Vorteile. Der Hauptvorteil von panelökonometrischen Modellen ist, dass unbeobachtete Effekte abgeschätzt werden können (vgl. GREENE 2012, 385). Sie sind in der Lage, auf unbeobachtete, über die Zeit oder für ein Individuum konstante Effekte zu kontrollieren. Zeitreihen- oder Querschnittsmodelle erlauben dies nicht, was zu Verzerrungen führen kann (vgl. BALTAGI 2005, 4f.). Panelökonometrische Modelle erlauben durch ihren größeren Umfang an Daten mehr Rückschlüsse, mehr Variabilität, können Kollinearität mindern und produzieren verlässlichere Schätzer (vgl. BALTAGI 2005, 5). Außerdem werden über die zeitliche Dimension Entwicklungen über die Zeit und der Effekt von - beispielsweise politischen - Änderungen sichtbar (vgl. BALTAGI 2005, 6).

Die Regression für einen Paneldatensatz mit $i = 1, \dots, N$ Beobachtungen an $t = 1, \dots, T$ Zeitpunkten kann in der Form

$$y_{it} = \alpha + \beta'x_{it} + u_{it} \quad (4.7)$$

geschrieben werden, wobei α der für alle Beobachtungen konstante Term ist (vgl. ECKEY et al. 2011, 286). Die verschiedenen Individuen werden dabei gemeinsam betrachtet, weshalb das Modell als **gepooltes Regressionsmodell** bezeichnet wird. Durch das Pooling von Querschnittsdaten aus Beobachtungen zu unterschiedlichen Zeitpunkten wird der Datensatz größer, was effizientere Schätzer erlaubt (vgl. ECKEY et al. 2011, 286; vgl. WOOLDRIDGE 2020, 427). Unterscheiden sich Regressionsparameter der einzelnen Individuen jedoch, das heißt die Individuen sind heterogen, gilt dies nicht und die Schätzer der gepoolten Regression sind verzerrt. Es müssten dann N einzelne Regressionsanalysen durchgeführt werden (vgl. ECKEY et al. 2011, 286). Ob unbeobachtete Heterogenität vorliegt, kann anhand eines Lagrange-Multiplier (LM)-Tests geprüft werden, der von Breusch und Pagan entwickelt wurde. Ist die Teststatistik signifikant, muss die Nullhypothese (es liegt keine Korrelation zwischen den Beobachtungen eines Individuums zu unterschiedlichen Zeitpunkten und damit keine unbeobachtete Heterogenität vor) abgelehnt werden und eine gepoolte Regression liefert verzerrte Schätzer (vgl. GREENE 2012, 416). Auf individuen- oder zeitspezifische Effekte kann im Rahmen einer gepoolten Regression kontrolliert werden, indem Dummy-Variablen in das Modell integriert werden (vgl. WOOLDRIDGE 2020 427). Halten für das gepoolte Regressionsmodell die in Kapitel 4.2.1 getroffenen Annahmen liefert OLS effiziente und unverzerrte Schätzer (vgl. GREENE 2012 389).

Um die Heterogenität unter den Individuen berücksichtigen zu können und so verzerrte Schätzer zu vermeiden, müssen andere panelökonometrische Modelle herangezogen werden. Generell lässt sich ein **unobserved-effects-Modell** wie folgt schreiben (vgl. WOOLDRIDGE 2010, 285):

$$y_{it} = c_i + \beta'x_{it} + u_{it} \quad (4.8)$$

wobei c_i die unbeobachteten und über die Zeit konstanten individuellen Effekte beschreibt. In der Literatur wird diskutiert, ob c_i als zufälliger Effekt (**random effect**) oder fixer Effekt (**fixed effect**)

zu behandeln ist. c_i wird dann als „random effect“ bezeichnet, wenn die unbeobachteten individuellen Effekte als zufällige Variable behandelt werden. Werden diese Effekte als Parameter behandelt, die für jede Beobachtung geschätzt werden müssen, werden sie als „fixed effects“ bezeichnet (vgl. WOOLDRIDGE 2010, 285). Im Folgenden werden drei Modelle vorgestellt, mit welchen unbeobachtete individuelle Effekte berücksichtigt werden können: der first-difference-Schätzer, das fixed-effects- sowie das random-effects-Modell.

Der **first-difference-Schätzer** beseitigt unbeobachtete Effekte, indem er die Differenz einer Beobachtung im Zeitpunkt t und im Zeitpunkt $t-1$ heranzieht um β zu schätzen (vgl. WOOLDRIDGE 2010, 316):

$$\Delta y_{it} = \beta' \Delta x_{it} + \Delta u_{it} \quad (4.9)$$

wobei $\Delta y_{it} = y_{it} - y_{i,t-1}$ und $\Delta x_{it} = x_{it} - x_{i,t-1}$. Der Einfluss über die Zeit konstanter Effekte kann mit dem first-difference-Schätzer daher nicht geschätzt werden (vgl. WOOLDRIDGE 2010, 316).

Ein anderes Modell, mit dem unbeobachtete Effekte berücksichtigt werden können ist das **fixed-effects-Modell**. Anders als beim first-difference-Schätzer wird für das fixed-effects-Modell der Durchschnitt über die Zeit herangezogen, um unbeobachtete Effekte zu beseitigen (vgl. WOOLDRIDGE 2020, 463):

$$\bar{y}_i = c_i + \beta' \bar{x}_i + \bar{u}_i \quad (4.10)$$

Subtrahiert man die Gleichung 4.10 von der Gleichung 4.8 ergibt sich

$$y_{it} - \bar{y}_i = \beta' (x_{it} - \bar{x}_i) + u_{it} - \bar{u}_i \quad (4.11)$$

was sich auch in der Form

$$\dot{y}_{it} = \beta' \dot{x}_{it} + \dot{u}_{it} \quad (4.12)$$

schreiben lässt (vgl. WOOLDRIDGE 2020, 463). Die zeitlich konstanten, individuellen Effekte c_i wurden damit beseitigt und 4.12 kann mittels gepoolter OLS geschätzt werden. Ein gepoolter OLS-Schätzer wird fixed-effects-Schätzer oder within-Schätzer genannt. Allerdings können auch mit diesem Modell die Effekte von über die Zeit konstanten Variablen nicht geschätzt werden (vgl. WOOLDRIDGE 2020, 463).

Wird angenommen, dass c_i unkorreliert mit allen erklärenden Variablen zu allen Beobachtungszeitpunkten ist, wird das **random-effects-Modell** verwendet. Es behandelt die unbeobachteten individuellen Effekte als zufällige Variable. Wird jedoch angenommen, dass c_i mit mindestens einer der erklärenden Variablen korreliert, ist das fixed-effects-Modell heranzuziehen. Es wird also angenommen, dass

$$Cov(x_{itj}, c_i) = 0, t = 1, 2, \dots, T; j = 1, 2, \dots, k \quad (4.13)$$

(vgl. WOOLDRIDGE 2020, 470). Das Modell kann dann wie folgt geschrieben werden (vgl. ECKEY et al. 2011, 293):

$$y_{it} = \alpha + \beta' x_{it} + v_{it} \text{ mit } v_{it} = c_i + u_{it} \quad (4.14)$$

Da sich c_i jetzt im zusammengesetzten Fehlerterm befindet, kommt es zu einer Autokorrelation im Fehlerterm. Der gepoolte OLS-Schätzer ignoriert dies und kann deshalb nicht verwendet werden (vgl. WOOLDRIDGE 2020, 470). Eine Methode, die zur Schätzung des Modells herangezogen werden kann, ist die verallgemeinerte Methode der kleinsten Quadrate (*Generalized Least Squares* – GLS) (vgl. ECKEY et al. 2011 294; WOOLDRIDGE 2020, 470). Diese soll im Rahmen dieser Arbeit

nicht näher erläutert werden und wird beispielsweise in WOOLDRIDGE 2010 Kapitel 10.4 oder ECKEY et al. 2011 Kapitel 2.12.4 beschrieben.

Random-effects- sowie fixed-effects-Modelle können als one-way oder two-ways effects-Modelle berechnet werden. In two-ways-Modellen werden auch unbeobachtete Zeiteffekte berücksichtigt, die für alle Individuen gleich sind, während one-way-Modelle nur individuelle Effekte berücksichtigen, die über die Zeit konstant sind. In two-ways-fixed-effects- oder random-effects-Modellen werden somit auch Effekte, die in einzelnen Jahren auftreten und alle Individuen betreffen berücksichtigt (vgl. BALTAGI 2005, 33).

Die Hauptannahme des random-effects-Modells, $Cov(x_{itj}, c_i) = 0$, kann mit dem **Hausman-Test** überprüft werden. Für den Fall $Cov(x_{itj}, c_i) \neq 0$ ist das fixed-effects-Modell zwar konsistent, das random-effects-Modell jedoch nicht. Signifikante Unterschiede zwischen den Schätzern des fixed- und des random-effects-Modell deuten deshalb darauf hin, dass die Nullhypothese abgelehnt und das fixed-effects-Modell verwendet werden muss (vgl. WOOLDRIDGE 2010 328 f.). Auch wenn der Fall, dass $Cov(x_{itj}, c_i) = 0$ nur selten anzutreffen und das fixed-effects- dem random-effects-Modell meist vorzuziehen ist, werden in der Praxis meist beide Modelle angewendet und im Anschluss daran der Hausman-Test durchgeführt. Auch im Rahmen dieser Arbeit soll auf diese Weise vorgegangen werden. Ein Grund hierfür ist, dass das random-effects-Modell anders als das fixed-effects-Modell auch das Schätzen von über die Zeit konstanten Variablen erlaubt (vgl. WOOLDRIDGE 2020 473).

4.3. Räumliche Regressionsmodelle

4.3.1. Räumliche Autokorrelation und Nachbarschaft

Im Allgemeinen wird angenommen, dass die beobachteten Individuen unabhängig voneinander sind. Diese Annahme ist insbesondere schwer zu halten, wenn es sich um geographisch verortete Beobachtungseinheiten oder räumliche Einheiten, wie Gemeinden, handelt (vgl. GIBBONS und OVERMAN 2012, 4). Unter den Beobachtungseinheiten können räumliche Abhängigkeiten (bzw. im Folgenden als räumliche Autokorrelation bezeichnet) auftreten oder aber räumliche Heterogenität. So beeinflussen sich landwirtschaftliche Betriebe benachbarter Gemeinden beispielsweise über ihre Konkurrenz um Flächen (räumliche Autokorrelation) oder unterscheiden sich voneinander durch unterschiedliche topographische Bedingungen (räumliche Heterogenität). Räumlicher Heterogenität kann meist mit herkömmlichen ökonomischen Methoden, wie sie im vorherigen Kapitel dargestellt wurden, beigegeben werden (vgl. ANSELIN 2001, 311). Räumliche Autokorrelation wird in räumlichen Regressionsmodellen, wie sie in diesem Kapitel vorgestellt werden, berücksichtigt.

Während bei Zeitreihendaten zeitverzögerte Variablen mit $t - 1$ versehen werden, kommt die Autokorrelation in räumlichen Regressionsmodellen durch die räumliche Gewichtungsmatrix W (*Spatial Weights Matrix* - SWM) zum Ausdruck (vgl. ELHORST 2014, 1). Statt einer Verschiebung entlang der Zeitachse wird anhand dieser eine „räumliche Verzögerungsvariable“ (im Folgenden *spatial lag* bzw. *spatial-lag-Variable* bezeichnet) errechnet. Sie ergibt sich aus einem gewichteten Mittel der Variablen benachbarter Beobachtungseinheiten (vgl. ANSELIN 2001, 312).

Die räumliche Gewichtungsmatrix W weist die Dimension $N \times N$ auf und legt für jede Beobachtungseinheit (z.B. Gemeinde) fest, welche der weiteren Gemeinden als Nachbarn der

Gemeinde i gelten. Hierfür werden in jeder Zeile, die je für eine Gemeinde i stehen, jene Spalten, die jeweils eine weitere Gemeinde j repräsentieren, ausgewählt, die als Nachbarn einen Wert von w_{ij} aufweisen, der nicht Null ist. w_{ij} ist null für alle Gemeinden, die nicht Nachbarn der Gemeinde i sind (vgl. ANSELIN 2001, 313). Verteilen sich beispielsweise vier Gemeinden (1-4), vereinfacht dargestellt, in der Form

| | |
|---|---|
| 1 | 2 |
| 3 | 4 |

im Raum, kann die zugehörige Nachbarschaftsmatrix geschrieben werden als

$$W = \begin{bmatrix} 0 & 1 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 0 & 1 & 1 & 0 \end{bmatrix} \quad (4.15)$$

wenn als Kriterium für eine Nachbarschaft eine gemeinsame Grenze herangezogen wird (vgl. PLANT 2012, 80). In diesem Fall wurde die Nachbarschaft als Rooks-Nachbarschaft definiert, bei der sich Polygone an zwei oder mehr Punkten berühren müssen, um als Nachbarn zu gelten. In Queens-Nachbarschaften gelten auch jene Polygone als Nachbarn, die sich nur an einem Punkt berühren (vgl. BIVAND 2020, 2). In diesem Fall wäre also jede der Gemeinden 1-4 der obigen Darstellung mit allen weiteren Gemeinden benachbart.

Der spatial lag der abhängigen Variable y einer Gemeinde i ergibt sich dann durch

$$[Wy]_i = \sum_{j=1, \dots, N} w_{ij} \cdot y_j \quad \text{bzw. in der Matrixform } Wy \quad (4.16)$$

(vgl. ANSELIN 2001, 313). Damit sich durch 4.16 der Durchschnittswert aller Nachbarn ergibt, wird die SWM reihenstandardisiert, sodass die Summe aller w_{ij} je Zeile eins ergibt (vgl. ELHORST 2014, 12).

Neben einer gemeinsamen Grenze kann als Kriterium für die Definition der Nachbarschaft auch die Lage innerhalb einer gewissen Distanz zur betrachteten Gemeinde herangezogen werden (vgl. ANSELIN 2001, 313). Diese Definition eignet sich vor allem für punktförmig vorliegende Daten, bei denen die Grenzen der einzelnen beobachteten Individuen nicht bekannt sind (vgl. PLANT 2012, 81). Nach ELHORST (2014, 10f.) gibt es drei verschiedene SWM, die auch in der facheinschlägigen Literatur angewendet werden. Erstens binäre Kontiguitätsmatrizen, die Nachbarn ersten, zweiten oder höheren Grades berücksichtigen (z.B. GELLRICH und ZIMMERMANN 2007; NIEDERMAYR et al. 2016; SCHMIDTNER et al. 2015). Zweitens SWM, die den inversen Abstand der einzelnen Beobachtungseinheiten heranziehen (z.B. LÄPPLE und KELLEY 2015; NIEDERMAYR et al. 2016; SCHMIDTNER et al. 2015). Drittens kann eine fixe Anzahl an Nachbarn definiert werden, die der Beobachtungseinheit am nächsten liegen (z.B. SCHMIDTNER et al. 2015). Werden räumlich aggregierte Daten verwendet, kommen meist binäre Kontiguitätsmatrizen (z.B. GELLRICH und ZIMMERMANN 2007) oder der Vergleich von mehreren SWM (z.B. NIEDERMAYR et al. 2016; SCHMIDTNER et al. 2015; SCHMIDTNER et al. 2012) zur Anwendung. Zwar werden binäre Kontiguitätsmatrizen häufig verwendet, sie sind jedoch unflexibel und ignorieren die tatsächlich gegebene Topographie und deren Heterogenität (vgl. GETIS 2009, 405ff.). Im Rahmen dieser Arbeit wird deshalb, trotz des Vorliegens räumlich aggregierter Daten, die Nachbarschaft distanzbasiert definiert. Dies erfolgt aus zwei Gründen. Erstens unterscheidet sich die Größe der einzelnen

Gemeinden innerhalb Österreichs teilweise stark. Binäre Kontiguitätsmatrizen würden damit zu sehr unterschiedlich großen Nachbarschaften führen. Zweitens kann es aufgrund der Geometrie der Gemeinden vorkommen, dass zwei Gemeinden sehr nahe aneinander liegen, ihre Grenzen sich jedoch an keiner Stelle berühren, weil sie durch einen Teil einer dritten Gemeinde räumlich getrennt werden.

Ein Problem bei der Definition der SWM ist, dass das wahre W im Allgemeinen unbekannt ist. Zwar kann die geographische Lage im Raum bestimmt werden, aber ob und zwischen welchen Gemeinden jedoch tatsächlich räumliche Autokorrelation auftritt, ist unbekannt (vgl. VEGA und ELHORST 2015, 340). Aus diesem Grund werden auch in dieser Arbeit die Modelle unter der Verwendung mehrerer Distanzen zur Definition der Nachbarschaft berechnet. Der Vergleich der Ergebnisse ermöglicht ebenso einen Robustheitscheck der Ergebnisse (siehe z.B. STORM und HECKELEI 2018).

Drei Formen von Interaktionen, auf welchen räumliche Autokorrelation beruht, lassen sich unterscheiden. Aus diesen lassen sich sieben räumliche Regressionsmodelle ableiten, in denen die SWM zur Berechnung des spatial lag an unterschiedlichen Stellen im Modell zum Einsatz kommt. Endogene Interaktion liegt vor, wenn die abhängige Variable y einer Gemeinde A vom y einer anderen Gemeinde B beeinflusst wird oder vice versa (vgl. ELHORST 2014, 7). Exogene Interaktionseffekte werden durch einen Zusammenhang zwischen einer unabhängigen Variable x einer Gemeinde A und dem y einer anderen Gemeinde B verursacht (vgl. ELHORST 2014, 8). Und Interaktionseffekte im Fehlerterm treten auf, wenn der Fehlerterm u einer Gemeinde A abhängig ist vom u einer anderen Gemeinde (vgl. ELHORST 2014, 8).

Alle drei Formen dieser Interaktionen werden mit dem **general-nesting-Modell (GNS)** berücksichtigt (vgl. ELHORST 2014, 8):

$$Y = \delta WY + \alpha + X\beta + WX\theta + u \quad (4.17)$$

$$u = \lambda Wu + \varepsilon \quad (4.18)$$

wobei Y ein $N \times 1$ Vektor bestehend aus einer Beobachtung für jede Einheit $i = 1, \dots, N$ und X eine $N \times K$ Matrix mit allen erklärenden Variablen ist. Es bezeichnet δ die endogenen Interaktionseffekte, θ die exogenen Interaktionseffekte und λ die Interaktionseffekte im Fehlerterm (vgl. ELHORST 2014, 7f.). Ausgehend von diesem Modell haben sich sechs räumlich-ökonomische Modelle etabliert, die jeweils unterschiedliche Interaktionseffekte oder Kombinationen von Interaktionseffekten berücksichtigen (vgl. Abb. 4):

Methoden

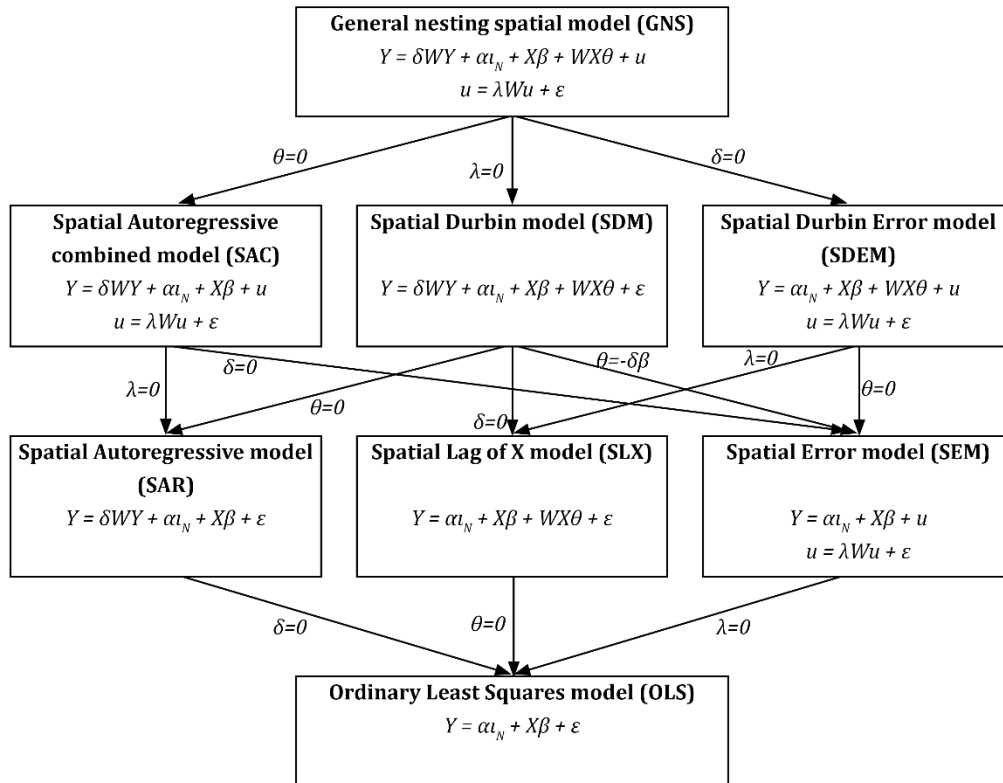


Abbildung 2: Übersicht räumlich-ökonomische Modelle. Eigene Darstellung nach ELHORST 2014, 9; VEGA und ELHORST 2015, 343.

Ob ein räumlich-ökonomisches Modell gegenüber einem nicht-räumlichen Modell präferiert werden sollte, kann anhand von Spezifikationstests überprüft werden. Mit Hilfe von Moran's I wird das Vorliegen von räumlicher Korrelation überprüft.

Moran's I ist der am häufigsten verwendete Test für räumliche Autokorrelation (vgl. ANSELIN 2001, 323), und ist definiert als das Verhältnis zwischen dem Produkt der abhängigen Variable mit dessen spatial lag und dem Kreuzprodukt der abhängigen Variable (vgl. BIVAND et al. 2013, 276):

$$I = \frac{n}{S_0} \frac{\sum_i \sum_j w_{ij} (Y_i - \bar{Y})(Y_j - \bar{Y})}{\sum_i (Y_i - \bar{Y})^2} \quad (4.19)$$

wobei $S_0 = \sum_i \sum_j w_{ij}$ ein Standardisierungsfaktor ist (vgl. PLANT 2012 104; ANSELIN 2001, 323). Unter der Nullhypothese, dass keine räumliche Autokorrelation vorliegt, liegt der erwartete Wert von I bei $-1/(n - 1)$. Weicht der Wert signifikant ab, liegt räumliche Autokorrelation vor (vgl. PLANT 2012, 105).

Bei I handelt es sich um das Global Moran's I. Da sich dieses jedoch aus den einzelnen Beziehungen der Individuen untereinander berechnet, lässt es sich auch herunterbrechen auf das sogenannte local Moran's I (vgl. BIVAND et al. 2013, 284f.):

$$I_i = \frac{(y_i - \bar{y}) \sum_{j=1}^n w_{ij} (y_j - \bar{y})}{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}} \quad (4.20)$$

Das local Moran's I wird für jedes Individuum berechnet und lässt erkennen, wo diese von Individuen mit ähnlichen oder abweichenden Charakteristiken umgeben sind (vgl. BIVAND et al. 2013, 284).

4.3.2. Das SLX-Modell

Das grundlegende Problem der räumlichen Ökonometrie ist, dass sich die verschiedenen räumlich-ökonometrischen Modelle in ihrer reduzierten Form kaum unterscheiden und die wahre räumliche Gewichtungsmatrix W nicht bekannt ist (vgl. VEGA und ELHORST 2015, 341; GIBBONS und OVERMAN 2012, 176f.). GIBBONS und OVERMAN (2012, 176ff.) stellen als einen Lösungsvorschlag vor, das SLX (*Spatial lag of X*)-Modell als Ausgangspunkt heranzuziehen, unter anderem deshalb, weil sich andere Modelle in ihrer reduzierten Form kaum von diesem unterscheiden. STORM et al. (2014), STORM und HECKELEI (2018) sowie SAINT-CYR et al. (2019), die sich in ihren Arbeiten ebenfalls mit räumlichen Abhängigkeiten im Agrarstrukturwandel unter der Verwendung ähnlicher Variablen wie in dieser Arbeit auseinandersetzen, haben diesen Vorschlag bereits aufgegriffen und verwenden in ihren Arbeiten das SLX-Modell.

Ein weiterer Aspekt, der für das Verwenden des SLX-Modells spricht, ist, dass vermutet wird, dass externe Effekte die räumliche Autokorrelation verursachen. Wie bereits in Kapitel 4.3.1 erwähnt, lassen sich drei Arten von Interaktionen, aus denen räumliche Autokorrelation entstehen kann, unterscheiden. LESAGE und PACE (2009, 25) sprechen von verschiedenen Motivationen, auf denen entsprechende räumliche Regressionsmodelle basieren. Wird angenommen, dass das Verhalten eines Individuums zum Zeitpunkt t das Verhalten eines benachbarten Individuums zum Zeitpunkt $t+1$ beeinflusst, liegt das Verwenden des Spatial Autoregressive model (SAR) nahe (vgl. LESAGE und PACE 2009, 25f.). Soll räumliche Heterogenität berücksichtigt werden, kann das Spatial Error model (SEM) verwendet werden (vgl. LESAGE und PACE 2009, 29). Das SLX-Modell soll dann angewendet werden, wenn die räumliche Autokorrelation in externen Effekten durch die Eigenschaften (bzw. die erklärenden Variablen) benachbarter Individuen vermutet wird (vgl. LESAGE und PACE 2009, 30). Im Falle dieser Arbeit liegt letztere Motivation vor, da vermutet wird, dass der Umfang der Agrarförderungen, die ein Betrieb erhält als erklärende Variable einen externen Effekt auch auf das Verhalten benachbarter Betriebe hat.

Für das Verwenden des SLX-Modells in der Form

$$Y = \alpha + X\beta + WX\theta + u \quad (4.21)$$

(vgl. ELHORST 2014, 9) sprechen neben der auf externen Effekten basierenden Motivation (vgl. LESAGE und PACE 2009, 30) weitere Gründe.

Ein Vorteil des SLX-Modells ist seine Flexibilität bezüglich der Schätzung von Spill-Over-Effekten. Spill-Over-Effekte (bzw. indirekte Effekte) liegen vor, wenn Verhalten oder Eigenschaften eines Individuums auch Effekte auf benachbarte Individuen haben (vgl. LESAGE 2014, 3). Demgegenüber sind direkte Effekte jene Effekte, die eine Veränderung in den erklärenden Variablen eines Individuums auf die abhängige Variable desselben Individuums hat (vgl. VEGA und ELHORST 2015, 344). Darüber hinaus ist zwischen lokalen und globalen Spill-Over-Effekten zu unterscheiden. Lokale Spill-Over-Effekte entstehen nur zwischen benachbarten Individuen (wobei hier als Nachbarschaft gilt, was zuvor als Nachbarschaft in der SWM definiert wurde). Es entstehen keine endogenen Rückkopplungseffekte. Globale Spill-Over-Effekte entstehen, wenn sich Effekte nicht

nur auf benachbarte Individuen auswirken, sondern auch auf deren Nachbarn und schlussendlich auf alle Beobachtungseinheiten. Hier entstehen endogene Rückkopplungseffekte. Darüber hinaus lassen sich im SLX-Modell direkte Effekte (β) und Spill-Over-Effekte (θ) separat und für jede der erklärenden Variablen einzeln messen. Diese Flexibilität ist ein weiterer Vorteil des SLX-Modells (vgl. ELHORST 2014, 22), der im Rahmen dieser Arbeit von Bedeutung ist, da sie sich insbesondere für den Spill-Over-Effekt einer erklärenden Variable (der Agrarförderungen) interessiert.

Die bisher getroffenen Annahmen beziehen sich auf das SLX-Modell unter der Verwendung von Querschnittsdaten. Bei dem dieser Arbeit zugrunde liegenden Datensatz handelt es sich um einen Paneldatensatz, für jede Beobachtungseinheit stehen Daten aus den Jahren 2003 bis 2017 zur Verfügung. Das SLX-Modell soll deshalb zu einem Modell erweitert werden, das raum- und zeitspezifische Effekte berücksichtigen kann. Das SLX-Modell der Gleichung 4.21 wird erweitert zu einem Raum-Zeit-Modell für ein Panel mit N Beobachtungseinheiten zu T Zeitpunkten (vgl. ELHORST 2014, 37f.):

$$Y_t = \alpha + X_t\beta + WX_t\theta + u_t \quad (4.22)$$

Wird dieses Modell geschätzt und die Daten damit gepoolt, bleiben jedoch mögliche raum- und zeitspezifische Effekte unberücksichtigt. Analog zu dem in Kapitel 4.2.2 beschriebenen gepoolten OLS-Modell, kann das Modell 4.22 zu einem random- oder fixed-effects-Modell erweitert werden (vgl. ELHORST 2014, 38).

Für Modelle, in denen räumliche Autokorrelation im Fehlerterm oder als exogener Effekt vorliegt (also auch das SLX-Modell), liefert OLS konsistente Schätzer (vgl. GIBBONS und OVERMAN 2012, 176). Dies gilt auch für fixed-effects-Modelle per se (vgl. WOOLDRIDGE 2012, 485). Die Methode der OLS wird deshalb für alle Modelle im Rahmen dieser Arbeit angewendet.

4.4. Modellbildung und geschätzte Modelle

Die Auswahl der berücksichtigten Variablen erfolgte in drei Schritten. Zum einen basiert sie auf der in Kapitel 2.3 durchgeführten Literaturrecherche. Variablen, welche zur Erklärung des Agrarstrukturwandels mittels ökonometrischer Studien in bisherigen wissenschaftlichen Arbeiten bereits häufiger angewendet wurden und deren Einfluss sich als signifikant herausgestellt hat, wurden in eine erste Vorauswahl übernommen. Eingeschränkt wurde diese Vorauswahl im Rahmen der Datenaufbereitung, da nicht für alle in Frage kommenden Variablen im Rahmen dieser Arbeit Daten verfügbar waren. In einer umfangreichen explorativen und deskriptiven Datenanalyse wurden letztlich die Auswahl der Variablen fixiert und teilweise notwendige Transformationen vorgenommen.

Im Anschluss an diese Schritte werden zunächst ökonometrische Modelle ohne räumlich verzögerte Variablen geschätzt. Aus dem beschriebenen Prozess der Variablenauswahl ergeben sich folgende Regressionsgleichungen als Ausgangsmodelle:

$$\begin{aligned} \ln(\text{betriebe})_{it} = & \beta_1 \text{bio_share100}_{it} + \beta_2 \text{acker_share100}_{it} + \beta_3 \ln(\text{LF_sitz})_{it} + \\ & \beta_4 \text{GVE_ha}_{it} + \beta_5 \ln(\text{BRP_pp_NUTS3})_{it} + \beta_6 \text{EW_km}_{it} + \beta_7 \text{tour_int}_{it} + \\ & \beta_8 \ln(\text{pile1_ha})_{it} + \beta_9 \ln(\text{oepul_az_ha})_{it} + \beta_{10} \ln(\text{invest_betrieb})_{it} + \\ & \beta_{11} \ln(\text{pile2_sub_EW})_{it} + u_{it} \end{aligned} \quad (4.23)$$

bzw.

$$\begin{aligned} \ln(LF_je_betrieb)_{it} = & \beta_1 bio_share100_{it} + \beta_2 acker_share100_{it} + \\ & \beta_3 GVE_ha_{it} + \beta_4 \ln(BRP_pp_NUTS3)_{it} + \beta_5 EW_km_{it} + \beta_6 tour_int_{it} + \\ & \beta_7 \ln(pile1_ha)_{it} + \beta_8 \ln(oepul_az_ha)_{it} + \beta_9 \ln(invest_betrieb)_{it} + \\ & \beta_{10} \ln(pile2_sub_EW)_{it} + u_{it} \end{aligned} \quad (4.24)$$

wobei:

betriebe = Anzahl der Betriebe je Gemeinde

LF_je_betrieb = Durchschnittliche LF (in ha) pro Betrieb je Gemeinde

bio_share100 = Anteil der Biobetriebe je Gemeinde (in %)

acker_share100 = Anteil der Ackerflächen an der gesamten LF je Gemeinde (in %)

LF_sitz = LF in ha je Gemeinde

GVE_ha = GVE je ha je Gemeinde

BRP_pp_NUTS3 = Bruttoregionalprodukt pro Person auf NUTS3-Ebene (in Tsd. €)

EW_km = Bevölkerungsdichte (je km²) je Gemeinde (eine Einheit: 100 Personen)

tour_int = Anzahl ÜN pro EW u. Jahr je Gemeinde (eine Einheit: 10 Übernachtungen)

pile1_ha = Summe der Förderungen aus Säule 1 d. GAP pro ha je Gemeinde (in Tsd. €)

oepul_az_ha = Summe der Förderungen aus ÖPUL u. AZ pro ha je Gemeinde (in Tsd. €)

invest_betrieb = Summe der Förderungen für materielle Investitionen pro Betrieb
je Gemeinde (in Tsd. €)

pile2_sub_EW = Summe der Förderungen für ländliche Entwicklung aus Säule 2 d. GAP pro EW je
Gemeinde (in Tsd. €)

u = Fehlerterm

Im Folgenden wird auf die bereits bekannte, vereinfachte Form

$$Y_t = X_t \beta + u_t \quad (4.26)$$

zurückgegriffen.

Um räumliche Effekte berücksichtigen zu können werden im nächsten Schritt SLX-Modelle (vgl. Kapitel 4.3.2) geschätzt:

$$Y_t = \alpha + X_t \beta + W X_t \theta + u_t \quad (4.27)$$

Die räumliche Gewichtungsmatrix **W** wird dabei als distanzbasierte Matrix definiert, wie in Kapitel 4.3.1 erläutert. Unterschieden wird dabei zwischen einer lokalen Nachbarschaftsmatrix und regionalen Nachbarschaftsmatrizen. Für die Definition der Nachbarschaftsmatrizen werden die Mittelpunkte der Gemeinden herangezogen. Gemeinden, deren Mittelpunkte sich im zuvor definierten Umkreis befinden, gelten als Nachbargemeinden. Für die lokale Nachbarschaftsmatrix wird zuerst jene Distanz ermittelt, für die jede Gemeinde mindestens eine Nachbargemeinde aufweist. Für die regionalen Nachbarschaftsmatrizen werden Distanzen von 25, 35, 45, 55, 65, und 75 km herangezogen. Durch das Schätzen der Modelle unter der Verwendung unterschiedlicher räumlicher Gewichtungsmatrizen kann einerseits die Robustheit der Modelle überprüft werden, andererseits erlaubt dies auch weitere Erkenntnisse über räumliche Abhängigkeiten. Wie in Kapitel 1 dargelegt, liegt die Vermutung nahe, dass diese räumlichen Abhängigkeiten aufgrund topographischer Gegebenheiten nicht in ganz Österreich gleichermaßen ausgeprägt sind. Um diese Vermutung zu überprüfen, werden die SLX-Modelle nicht nur für ganz Österreich geschätzt, sondern auch mit Teilmengen des Datensatzes. Diese

Teilmengen umfassen jeweils unterschiedliche Hauptproduktionsgebiete Österreichs, die sich in ihren topographischen Gegebenheiten stark voneinander unterscheiden.

Sowohl die nicht-räumlichen als auch das SLX-Modell können mittels OLS geschätzt werden (vgl. Kapitel 4.3.2). Die log-Transformation einiger Variablen, insbesondere der abhängigen Variablen, muss bei der Interpretation der Schätzer der Regressionskoeffizienten berücksichtigt werden. Ist nur die abhängige Variable log-transformiert und die unabhängige Variable nicht, wird der Regressionskoeffizient β_1 nach der Formel $\% \Delta y = (100\beta_1)\Delta x$ interpretiert. Dies wird auch als die Semi-Elastizität von y gegenüber x bezeichnet. Ist der Schätzer des Regressionskoeffizienten β_1 beispielsweise 0,25 führt eine Veränderung von x um eine Einheit zu einer Veränderung von 25% in y . Sind sowohl abhängige als auch unabhängige Variable log-transformiert, erfolgt die Interpretation von β_1 nach der Formel $\% \Delta y = \beta_1 \% \Delta x$. Man bezeichnet dies auch als die Elastizität von y in Bezug auf x . Ist der Schätzer von β_1 wiederum 0,25 ändert sich y um 0,25%, wenn sich x um ein Prozent verändert (vgl. WOOLDRIDGE 2012, 44).

Die grundlegende Aufbereitung der Daten erfolgt mit Microsoft Excel. Für alle weiteren Transformations- und Rechenschritte sowie die Schätzung aller ökonometrischen Modelle wird R, eine Programmiersprache bzw. Software für Statistik (R CORE TEAM 2018) in Kombination mit RStudio (RSTUDIO TEAM 2016), verwendet. Folgende Ergänzungen (Packages) kommen dabei zum Einsatz:

- „plm“: Linear Models for Panel Data (CROISSANT et al. 2019)
- „spdep“: Spatial Dependence: Weighting Schemes, Statistics (BIVAND 2019)
- „pastecs“: Package for Analysis of Space-Time Ecological Series (GROSJEAN und IBANEZ 2018)
- „rgdal“: Bindings for the „Geospatial“ Data Abstraction Library (BIVAND et al. 2019)
- „lmtest“: Testing Linear Regression Models (HOTHORN et al. 2019)
- „splm“: Econometric Models for Spatial Panel Data (MILLO und PIRAS 2018)
- „stargazer“: Well-Formatted Regression and Summary Statistics Tables (HLAVAC 2018)
- „ggplot2“: ggplot2: Create Elegant Data Visualisations Using the Grammar of Graphics (WICKHAM et al. 2020)
- „corrplot“: Visualisation of a Correlation Matrix (WEI und SIMKO 2017)

5. Ergebnisse

Den ersten Teil der im Folgenden beschriebenen Ergebnisse dieser Arbeit stellt eine ausführlichere und insbesondere kartographische dargestellte deskriptive Statistik der abhängigen und unabhängigen Variablen dar. Dies erlaubt Einblicke in die räumliche Verteilung der Ausprägungen aller erklärenden Variablen in Österreich und zeigt die Entwicklung der Betriebsanzahl und der durchschnittlichen Betriebsgröße je Gemeinde im Beobachtungszeitraum. Hierdurch lassen sich darüber hinaus bereits erste Hinweise über mögliche (räumliche) Zusammenhänge zwischen den abhängigen und unabhängigen Variablen ablesen. Mittels der Berechnung des global und local Moran's I wird überprüft, ob sich mögliche beobachtete räumliche Korrelationen auch statistisch belegen lassen und wo diese innerhalb Österreichs besonders ausgeprägt sind.

Nach dieser deskriptiven Beschreibung der Datengrundlage erfolgt eine Erläuterung des Vorgehens zur Auswahl des Modells und der Modellspezifikation. Im Anschluss daran werden die Ergebnisse der berechneten fixed-effects- und SLX-Modelle gegenübergestellt und beschrieben.

5.1. Räumlich-deskriptive Statistik und kartographische Darstellung

Eine zusammenfassende deskriptive Statistik für alle Variablen erfolgte bereits in Kapitel 3.3. An dieser Stelle soll eine detailliertere deskriptive Statistik insbesondere im Hinblick auf die räumliche Verteilung, sowie im Fall der abhängigen Variablen auch im Hinblick auf deren Entwicklung im Beobachtungszeitraum, erfolgen.

Eine der beiden abhängigen Variablen ist die Anzahl an landwirtschaftlichen Betrieben je Gemeinde. Im Durchschnitt nahm diese bis zum Jahr 2017 gegenüber dem Jahr 2003 um rund 25,7% ab, wobei die Schwankungsbreite zwischen - 82,9% und + 25,7% liegt. In 34 Gemeinden gibt es mehr neue landwirtschaftliche Betriebe zu verzeichnen als im selben Zeitraum aus dem Betrieb ausgestiegen sind. Abbildung 3 zeigt die Veränderung der Betriebsanzahl in allen 2.066 berücksichtigten Gemeinden im Beobachtungszeitraum. Anhand dieser Karte wird deutlich, dass die Entwicklung der Betriebsanzahlen nicht in allen Landesteilen mit der gleichen Dynamik stattfindet. In einigen Landesteilen, insbesondere im Norden und Osten des Landes, konzentrieren sich Gemeinden mit starken Abnahmeraten, während sich in anderen Landesteilen durchwegs Gemeinden mit geringeren Abnahmeraten befinden. Ähnliche Zusammenhänge hat beispielsweise auch STREIFENEDER (2009, 43) bereits in seiner Arbeit erkannt. Es scheint also eine räumliche Korrelation zu bestehen.

Auch bezüglich der zweiten abhängigen Variablen, der durchschnittlichen Betriebsgröße in Hektar je Gemeinde, lässt die kartographische Darstellung (Abbildung 4) räumliche Korrelationen vermuten. Gemeinden, in welchen die landwirtschaftlichen Betriebe im Schnitt mehr als 50 ha bewirtschaften befinden sich ausschließlich im Osten Österreichs. Ein Vergleich der durchschnittlichen Betriebsgrößen je Gemeinde im Jahr 2003 mit jenen des Jahres 2017 zeigt auch, dass die durchschnittlichen Betriebsgrößen dort und im Norden Österreichs verstärkt steigen. Dies hängt auch damit zusammen, dass diese Regionen einen besonders hohen Rückgang in der Anzahl an landwirtschaftlichen Betrieben verzeichnen (vgl. Abb. 3) und lässt die starke Abhängigkeit zwischen den Entwicklungen der Betriebsanzahl und der durchschnittlichen Betriebsgrößen erkennen. Im Durchschnitt wuchsen die landwirtschaftlichen Betriebe einer Gemeinde bis zum Jahr 2017 um 30,8% ihrer LF gegenüber dem Jahr 2003.

Ergebnisse

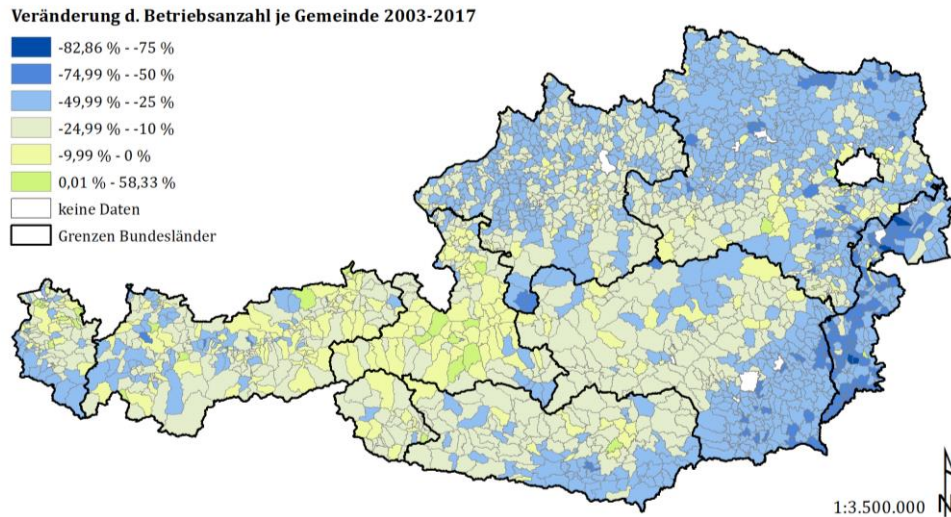


Abbildung 4: Veränderung der Betriebsanzahl in Prozent je Gemeinde 2003-2017. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

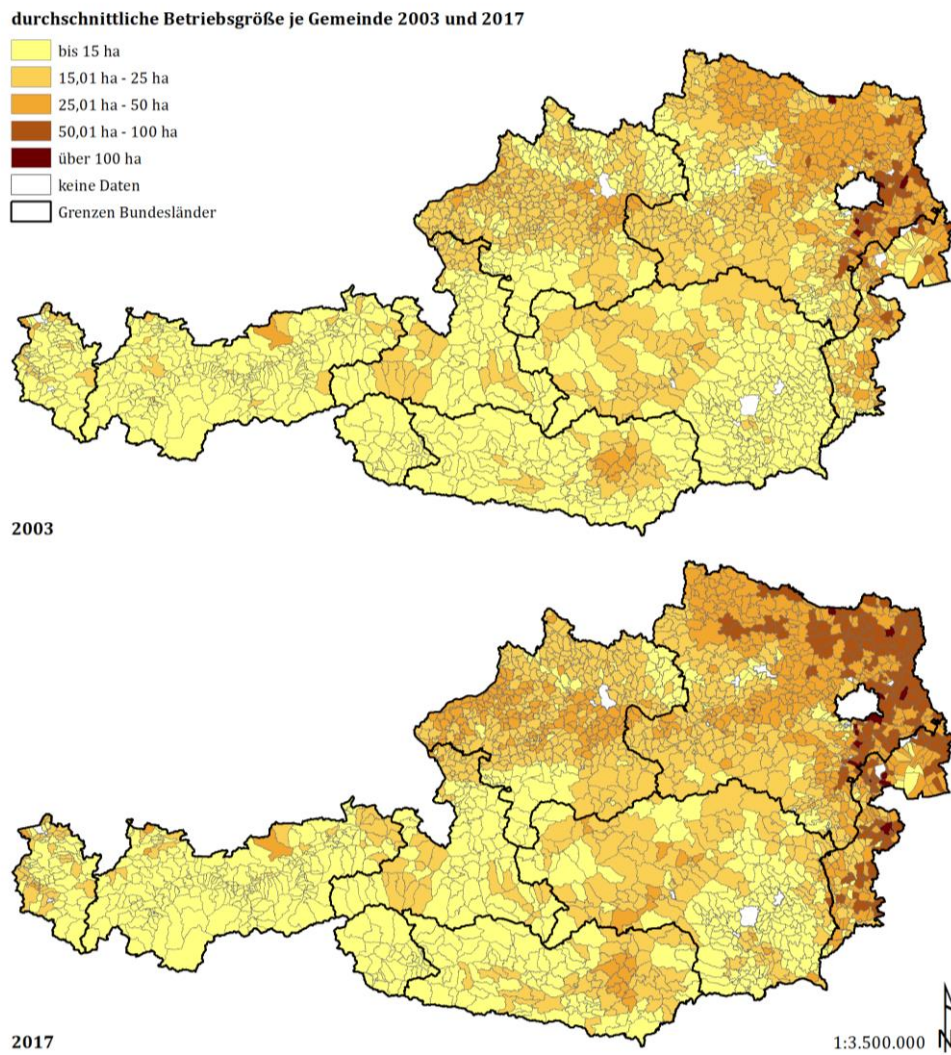


Abbildung 3: durchschnittliche Betriebsgrößen in ha je Gemeinde in den Jahren 2003 und 2017. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

Ergebnisse

Im Folgenden soll nun die räumliche Verteilung der durchschnittlichen Ausprägung (gemittelt über die Jahre 2003 bis 2017) ausgewählter unabhängiger Variablen aufgezeigt werden. Zwar erfolgte diese räumliche Analyse für alle unabhängigen Variablen, es werden an dieser Stelle jedoch lediglich jene Ergebnisse dargestellt, die Rückschlüsse auf mögliche Korrelationen zwischen den zuvor dargestellten abhängigen und unabhängigen Variablen erlauben. Kartographische Darstellungen der räumlichen Verteilung aller weiteren unabhängigen Variablen befinden sich im Anhang.

Abbildung 5 zeigt den über den Beobachtungszeitraum gemittelten Anteil an Biobetrieben je Gemeinde. Dieser beträgt im Durchschnitt 15,9% und weist bezüglich der räumlichen Verteilung ähnliche Muster wie die Entwicklung der Betriebsanzahl sowie der durchschnittlichen Betriebsgröße je Gemeinde auf. Da ein hoher Anteil an Biobetrieben vor allem in jenen Regionen vorzufinden ist, in denen die Betriebsanzahl nur in geringem Ausmaß sinkt, ist von einer positiven Korrelation zwischen der Anzahl an Betrieben und dem Anteil an Biobetrieben in einer Gemeinde auszugehen. Umgekehrt liegt in Regionen mit einem hohen Anteil mit Biobetrieben jedoch eine geringe durchschnittliche Betriebsgröße vor. Das Vorliegen einer negativen Korrelation zwischen durchschnittlicher Betriebsgröße und dem Anteil an Biobetrieben in einer Gemeinde liegt deshalb nahe.

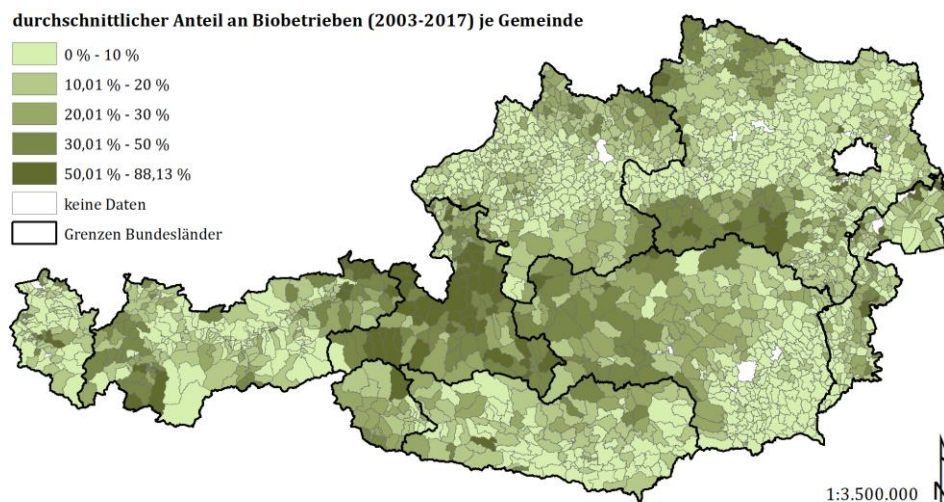


Abbildung 5: durchschnittlicher Anteil an Biobetriebe (2003-2017) je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

Eine weitere die Betriebsstruktur in einer Gemeinde repräsentierende Variable ist der Anteil an Ackerflächen an der gesamten LF einer Gemeinde. Die über den Beobachtungszeitraum gemittelte Ausprägung dieser Variable je Gemeinde ist in Abbildung 6 dargestellt. Auch die kartographische Darstellung dieser Variable legt eine starke räumliche Korrelation nahe. Der durchschnittliche Anteil an Ackerflächen je Gemeinde beträgt 46,9%, schwankt jedoch zwischen 0 und 100%. Der Vergleich mit den Abbildungen 3 und 4 legt nahe, dass mit einem hohen Anteil an Ackerflächen eine größere Abnahme der Anzahl an landwirtschaftlichen Betrieben (negative Korrelation) sowie eine große durchschnittliche Betriebsgröße (positive Korrelation) einhergeht.

Ergebnisse

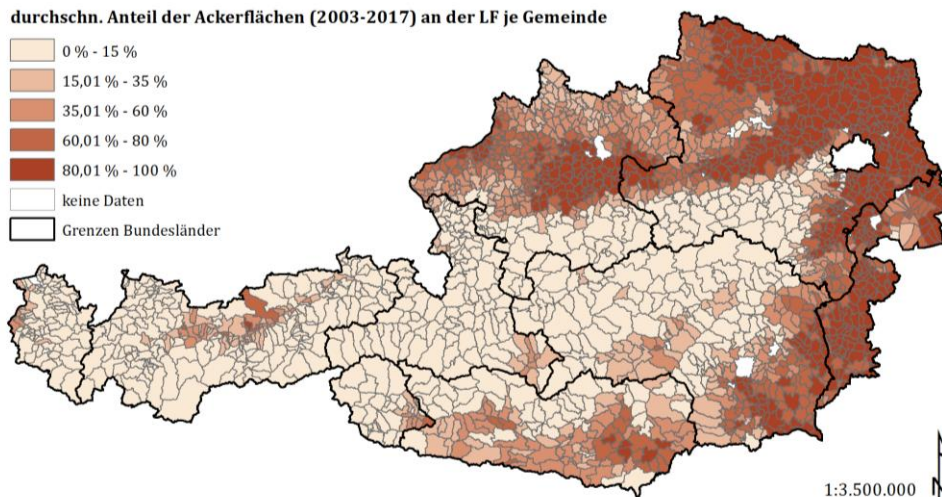


Abbildung 6: durchschnittlicher Anteil der Ackerflächen (2003-2017) an der LF je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

Über den Beobachtungszeitraum gemittelt schwankt die GVE-Dichte zwischen 0 und 4,6 GVE je ha, wobei der Durchschnitt bei 1,1 GVE je ha liegt. Die Viehbesatzdichte ist jedoch nicht in ganz Österreich gleich hoch, wie in Abbildung 7 ersichtlich wird. Vor allem im Osten des Landes zeigt sich eine sehr niedrige Besatzdichte, während diese im alpinen Raum sowie einigen Hotspots in Südosten und Nordwesten des Landes deutlich höher ist. Verglichen mit der räumlichen Verteilung der Ausstiegsrate landwirtschaftlicher Betriebe sowie der Verteilung der durchschnittlichen Betriebsgrößen lassen sich folgende Zusammenhänge beobachten: in Regionen mit hoher Viehbesatzdichte ist die durchschnittliche Betriebsgröße geringer (negative Korrelation), gleichzeitig nimmt die Anzahl an Betrieben zu (positive Korrelation zwischen GVE-Dichte je ha und der Anzahl an Betrieben).

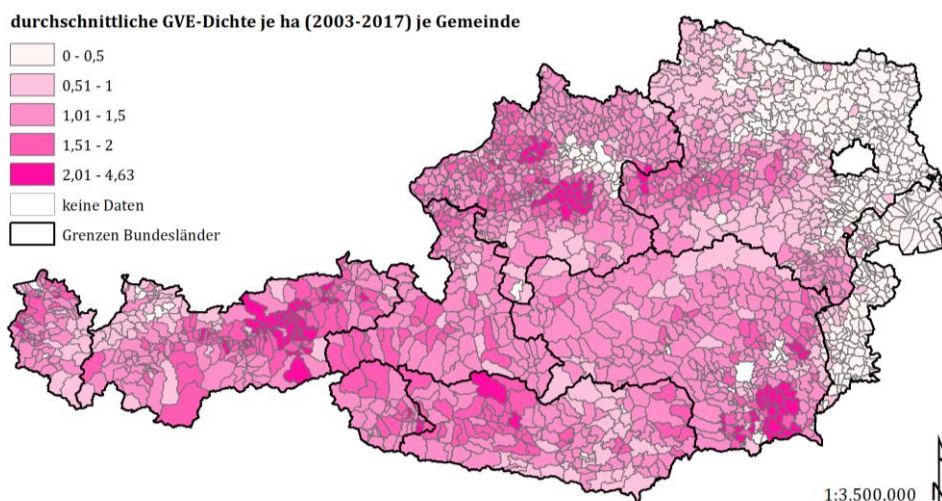


Abbildung 7: durchschnittliche GVE-Dichte je ha (2003-2017) je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

Ergebnisse

Von allen im Rahmen dieser Arbeit herangezogenen standortabhängigen Faktoren (Bruttoregionalprodukt pro Person, Seehöhe über NN, Bevölkerungsdichte sowie Übernachtungsintensität) weist insbesondere der Median der Seehöhe über NN eine räumliche Verteilung auf, die Rückschlüsse auf mögliche Korrelationen dieser mit den abhängigen Variablen erlaubt (siehe Abbildung 8). Der Vergleich mit den Abbildungen 3 und 4 legt nahe, dass eine positive Korrelation zwischen dem Median der Seehöhe und der Anzahl an Betrieben sowie eine negative Korrelation zwischen der durchschnittlichen Betriebsgröße und dem Median der Seehöhe besteht.

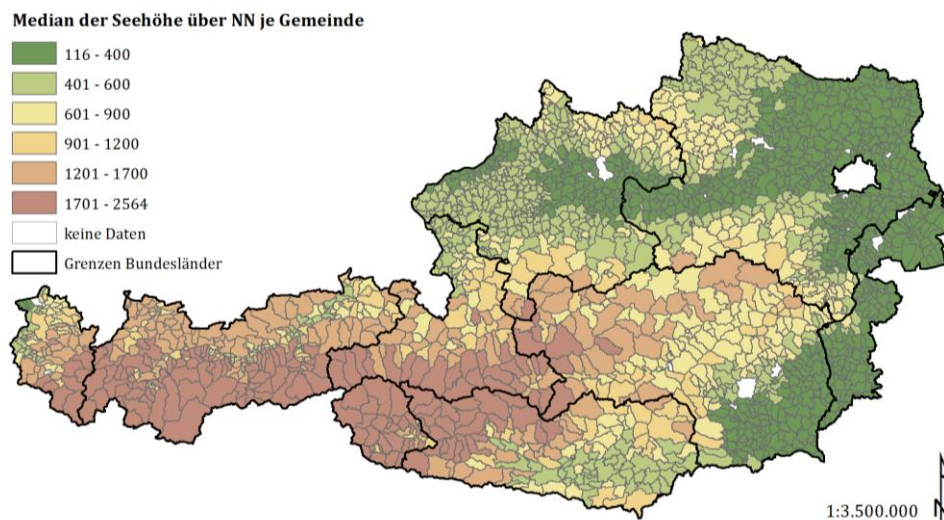


Abbildung 8: Median der Seehöhe über NN je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, GEOLAND.AT 2020, BEV 2019.

Von den vier die Agrarförderungen im Rahmen der GAP repräsentierenden unabhängigen Variablen weisen die Summe der Förderungen der 1. Säule sowie die Summe der Förderungen im Rahmen von ÖPUL und AZ je ha ähnliche Muster der räumlichen Verteilung auf wie die beiden abhängigen Variablen. Abbildung 9 stellt die Verteilung dieser beiden Variablen, gemittelt über die Jahre 2003 bis 2017, kartographisch dar. Der Vergleich mit der Veränderung der Betriebsanzahl in Prozent (Abbildung 3) zeigt, dass die Agrarförderungen der 1. Säule der GAP je ha LF in jenen Regionen niedriger sind, in denen auch die Anzahl an Betrieben weniger stark abnimmt. Dies würde implizieren, dass eine höhere Förderintensität mit einer höheren Ausstiegsrate unter landwirtschaftlichen Betrieben verbunden ist. Über die Jahre 2003-2017 gemittelt beträgt die Förderintensität der 1. Säule rund 263€ je ha, wobei das Maximum bei 1.040€ und das Minimum bei 8€ liegt.

Die räumliche Verteilung der Förderintensität von ÖPUL und AZ zeigt ein ähnliches Muster wie jene der 1. Säule der GAP auf. Jedoch ist sie in jenen Regionen höher bzw. am höchsten, in welchen die Förderintensität im Bezug auf die 1. Säule der GAP am niedrigsten ist. Das bedeutet, bezüglich der Korrelation mit den abhängigen Variablen sind umgekehrte Vorzeichen zu erwarten: die Anzahl an Betrieben ist dort größer, wo die Förderintensität (von ÖPUL und AZ) höher ist während die durchschnittliche Betriebsgröße geringer ist, je höher die Förderintensität. Die über die Jahre 2003-2017 gemittelte Förderintensität im Rahmen von ÖPUL und AZ ist höher als jene der 1. Säule der GAP. Sie beträgt rund 420€ je ha und liegt insgesamt im Bereich von 9€ und 1.965€ je ha.

Ergebnisse

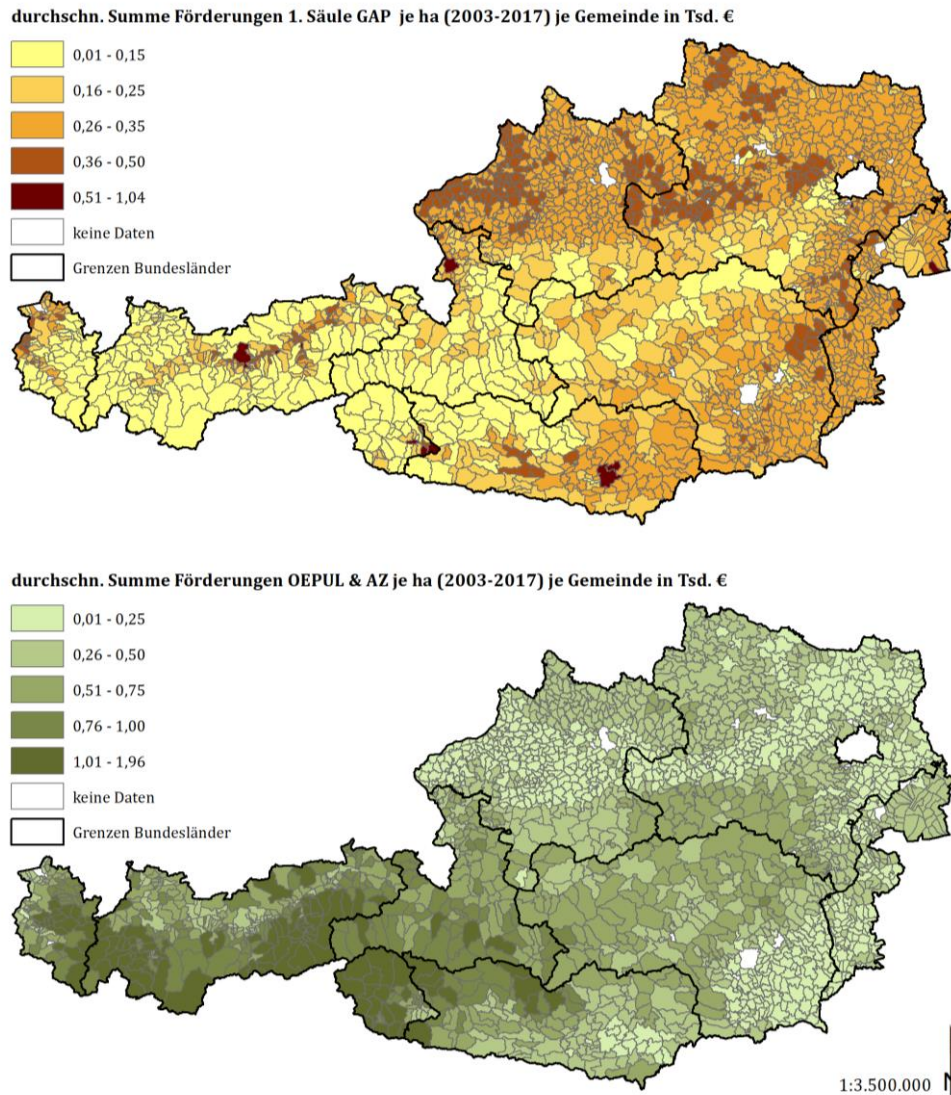


Abbildung 9: durchschnittliche Summen (2003-2017) der Agrarförderungen 1. Säule GAP sowie OEPU & AZ je ha je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

Ein Schwerpunkt dieser Arbeit liegt auf der Untersuchung von räumlichen Abhängigkeiten bzw. räumlicher Autokorrelation. Ob räumliche Autokorrelation vorliegt, kann anhand des Moran's I überprüft werden. Dieses ist im Rahmen dieser Arbeit als Ergänzung der räumlich-deskriptiven Statistik zu sehen und stellt keine Entscheidungsgrundlage zur Modellwahl dar, da ohne das Vorliegen von räumlicher Autokorrelation die Schätzer der Regressionskoeffizienten der spatial lag Variablen ohnehin nicht signifikant wären.

Das Moran's I wurde auf Basis der Residuen einer gepoolten OLS-Regression ermittelt. Diese basiert auf den über den Beobachtungszeitraum gemittelten Werten der abhängigen und unabhängigen Variablen. Um das Moran's I zu berechnen, muss zuvor definiert werden, welche Gemeinden im Umkreis einer Gemeinde als Nachbarn definiert werden. Zur Berechnung des Moran's I beziehungsweise des local Moran's I wurde hierzu ein Radius von rund 16,3 km herangezogen, bei dem jede Gemeinde mindestens eine Gemeinde als Nachbargemeinde aufweist. Das Moran's I beträgt für das Modell mit der Anzahl an Betrieben je Gemeinde 0,45 bei einem erwarteten Wert von -0,003. Ist die durchschnittliche Betriebsgröße die abhängige Variable,

Ergebnisse

beträgt das beobachtete Moran's I 0,43 bei einem erwarteten Wert von -0,003. Beide Ergebnisse sind auf dem 0,01%-Niveau signifikant, das bedeutet, es liegt räumliche Autokorrelation vor.

Anhand des local Moran's I, welches auf Basis der Residuen der zuvor beschriebenen OLS-Regressionen berechnet wurde, kann kartographisch dargestellt werden, in welchen Regionen Österreichs diese räumliche Autokorrelation besonders stark ausgeprägt ist. Dies ist in Abbildung 10 dargestellt. Je höher der Wert des local Moran's I, desto stärker ausgeprägt ist die räumliche Autokorrelation. Es zeigt sich, dass es insbesondere im Südosten, Osten aber auch im Westen des Landes Regionen gibt, in denen starke räumliche Abhängigkeiten zu bestehen scheinen. Ein Zusammenhang mit geographischen Faktoren, insbesondere dem Median der Seehöhe, auf welcher die LF der beobachteten Gemeinden liegt, ist anhand dieser Abbildungen nicht erkennbar.

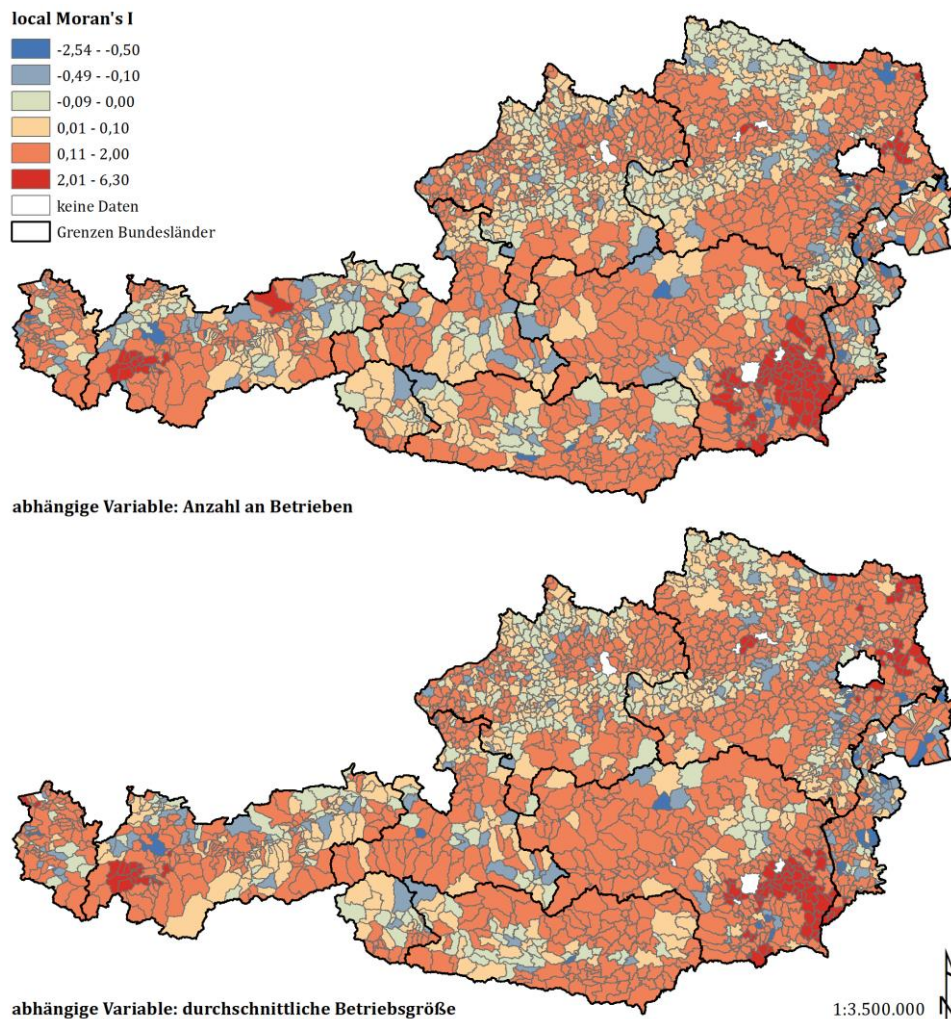


Abbildung 10: local Moran's I. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

5.2. Modellauswahl

Welche Variablen zur Erklärung der beiden abhängigen Variablen (Betriebsanzahl sowie durchschnittliche Betriebsgröße je Gemeinde) herangezogen werden, basiert einerseits auf einer Literaturanalyse (siehe Kapitel 2.3). Andererseits musste auch die Datenverfügbarkeit berücksichtigt werden. Die Datenverfügbarkeit war ebenso maßgeblich für die Festlegung des Beobachtungszeitraums. Nach der Auswahl der Variablen erfolgte eine explorative Datenanalyse, deren Ergebnisse teilweise in Kapitel 5.1 vorgestellt wurden. Hierdurch lassen sich bereits erste mögliche Zusammenhänge erkennen und Einblicke in räumliche Muster der Agrarstruktur bzw. des Agrarstrukturwandels in Österreich sind möglich. Durch die im weiteren Verlauf geschätzten Modelle können diese beobachteten Zusammenhänge geschätzt und *ceteris paribus* Aussagen getroffen werden.

Nach dieser explorativen räumlichen Datenanalyse wurden im nächsten Schritt OLS-Regressionen mit den ausgewählten abhängigen und unabhängigen Variablen für alle Jahre des Beobachtungszeitraums einzeln durchgeführt. Diese erfolgten jeweils mit unterschiedlichen Modellspezifikationen (log-Transformation einzelner Variablen). Dieses Vorgehen hat mehrere Zwecke.

Zum einen kann anhand der Diagnostikplots überprüft werden, wie gut die geschätzten Modelle für die Datengrundlage geeignet sind. Anhand der Diagnostikplots ist es auch möglich, einflussreiche Beobachtungen bzw. Ausreißer zu identifizieren. Eine Beobachtung ist dann einflussreich, wenn sich durch Entfernen derselben die OLS-Schätzer deutlich verändern (vgl. WOOLDRIDGE 2012, 326f.). Einflussreiche Ausreißer, deren Ursache vor allem in sehr hohen Summen an Agrarförderungen der 1. Säule oder sehr hohen Investitionsförderungen in einzelnen Jahren liegt, wurden entfernt. Zum anderen kann beobachtet werden, wie sich die Transformation oder das Weglassen einzelner Variablen auf die Modellergebnisse auswirkt. Dies hilft dabei, die finale Modellspezifikation festzulegen. Gleichzeitig lässt sich die Konsistenz der Daten über den Beobachtungszeitraum hinweg beobachten. Einzig der Einfluss der förderabhängigen Variablen unterscheidet sich zwischen den einzelnen Jahren. Dies ist dadurch zu erklären, dass der Beobachtungszeitraum in mehrere Förderperioden der GAP im Rahmen des mehrjährigen Finanzrahmens der EU fällt.

Nachdem im Zuge dieser OLS-Regressionen für alle einzelnen Jahre des Beobachtungszeitraums einflussreiche Ausreißer entfernt und das Verhalten einzelner Variablen bei log-Transformation beobachtet wurde, erfolgte im nächsten Schritt die Schätzung von gepoolten OLS-Modellen. Auch hierbei wurden die Ergebnisse unterschiedlicher Modellspezifikationen (log-Transformation oder Weglassen einzelner Variablen) analysiert und verglichen. Es hat sich gezeigt, dass die nach diesem Schritt festgelegte Modellspezifikation robust gegenüber der Transformation einzelner Variablen ist. Zwar erhöhen nicht alle berücksichtigten unabhängigen Variablen das R^2 , jedoch verändern sich die Ergebnisse durch das Weglassen betreffender Variablen nicht maßgeblich. Da deren Schätzer jedoch trotzdem weitere Hinweise über mögliche Korrelationen liefern können, wurden diese Variablen ebenfalls in das Modell mitaufgenommen. Die Schätzer fast aller abhängigen Variablen erwiesen sich als signifikant. Wird als abhängige Variable die Anzahl an Betrieben je Gemeinde herangezogen, ist insbesondere die LF in ha (nach Betriebsitz) als unabhängige Variable entscheidend. Wird sie aus dem Modell entfernt, verringert sich das R^2 um rund 0,25.

Neben der gepoolten OLS-Regression kommen auch das fixed- oder random-effects-Modell in Frage. Der nächste Schritt ist es, auf Basis von Tests zu entscheiden, welches dieser, in Kapitel 4.2.2 vorgestellten, panelökonometrischen Modelle angewendet werden soll. Mittels eines LM-Tests nach Breusch und Pagan, basierend auf den Residuen der gepoolten OLS-Regressionen, wurde überprüft, ob unbeobachtete Heterogenität zwischen den beobachteten Gemeinden vorliegt. Das Ergebnis dieses Tests ist für die gepoolten OLS-Regressionen beider abhängiger Variablen auf dem 0,1%-Niveau signifikant, die Nullhypothese (keine unbeobachtete Heterogenität) muss deshalb verworfen werden. Eine gepoolte OLS-Regression ist also keine für die Datengrundlage geeignete Methode und ein fixed- oder random-effects-Modell sollten zur Anwendung kommen.

Auf Basis des in Kapitel 4.2.2 vorgestellten Hausman-Tests kann entschieden werden, ob ein fixed-effects- oder ein random-effects-Modell geschätzt werden sollte. Auch dieser Test ist für beide abhängigen Variablen auf dem 0,1%-Niveau signifikant und die Nullhypothese (beide Modelle sind konsistent) muss abgelehnt werden. Im Rahmen dieser Arbeit wird also ein fixed-effects-Modell geschätzt. Vor allem aufgrund der unterschiedlichen Förderperioden im Laufe des Beobachtungszeitraums ist mit unbeobachteten, zeitspezifischen Effekten zu rechnen, die alle Gemeinden gleichermaßen beeinflussen. Deshalb wird ein two-ways fixed-effects-Modell geschätzt. Auf Basis der erfolgten Literaturrecherche sowie den in Kapitel 4.3.2 ausgeführten Überlegungen wird das two-ways fixed-effects-Modell im nächsten Schritt zu einem SLX-Modell erweitert und dieses unter der Berücksichtigung unterschiedlicher Nachbarschaftsmatrizen und spatial lag Variablen geschätzt. Zur Berechnung einer lokalen Nachbarschaftsmatrix wurde ein Radius von rund 16,3 km herangezogen. Dies entspricht jener Distanz, bei der alle Gemeinde mindestens eine Nachbargemeinde aufweisen. Im weiteren Verlauf der Arbeit werden unterschiedliche Radien zur Definition der Nachbarschaft und Schätzung der Modelle herangezogen. Die weiteren Radien betragen 25, 35, 45, 55, 65 sowie 75 km. Einerseits kann hierdurch die Robustheit der Modelle überprüft werden, andererseits sind weitere Rückschlüsse über mögliche räumliche Zusammenhänge möglich.

5.3. Modellergebnisse

Fixed-effects- und SLX-Modelle

Die Ergebnisse der auf Basis der in Kapitel 5.1 und 5.2 beschriebenen Annahmen und Erkenntnisse geschätzten Regressionsmodelle sind in Tabelle 6 zusammengefasst. In der ersten Spalte sind alle unabhängigen Variablen der Modelle aufgelistet. Ihnen gegenüber stehen in den folgenden Spalten deren geschätzte Regressionskoeffizienten für alle geschätzten Modelle. Die als semi-elastizitäten vorliegenden Regressionskoeffizienten wurden in den Tabellen noch nicht mit 100 multipliziert, wie es zur korrekten Interpretation notwendig ist. Das Vorzeichen der Schätzer gibt Auskunft über das Vorzeichen der geschätzten Korrelation mit der abhängigen Variable. Anhand der an den geschätzten Regressionskoeffizienten angehängten Zeichen kann die Signifikanz der jeweiligen Schätzer abgelesen werden. Als Signifikanzniveau wird das in der Ökonometrie übliche Signifikanzniveau von 5% herangezogen (vgl. WOOLDRIDGE 2012, 123f.). Die Aufschlüsselung der Signifikanzniveaus befindet sich in der letzten Zeile der Tabelle. In den beiden Zeilen darüber ist einerseits das R^2 und andererseits die Anzahl an Beobachtungen angegeben. Die Anzahl an 30.990 Beobachtungen in allen Modellen ergibt sich aus der Multiplikation aus beobachteten Gemeinden (2.066 Gemeinden) mit der Anzahl an

Ergebnisse

Beobachtungszeitpunkten (Beobachtung aus 15 Jahren). Diese hohe Anzahl an Beobachtungen bedingt auch das hohe Signifikanzniveau fast aller unabhängigen Variablen.

Alle förderungsbezogenen Variablen kommen in den SLX-Modellen in zwei Varianten vor: einmal als einfache, nicht gewichtete Variable und einmal mit einer SWM gewichtet. Für die in Tabelle 6 vorgestellten Regressionsmodelle handelt es sich bei der SWM um die lokale Nachbarschaftsmatrix, bei der der Radius zur Definition der Nachbarschaft so festgelegt wurde, dass jede Gemeinde mindestens eine Nachbargemeinde aufweist. Dieser Radius beträgt ca. 16,3 km.

| | <i>abhängige Variable:</i> | | | |
|--|---|------------|--------------------------------------|------------|
| | Anzahl Betriebe (ln) | | durchschnittliche Betriebsgröße (ln) | |
| | <i>FE</i> | <i>SLX</i> | <i>FE</i> | <i>SLX</i> |
| % Biobetriebe | -0,003*** | -0,003*** | 0,004*** | 0,004*** |
| % Ackerfläche | -0,006*** | -0,006*** | 0,008*** | 0,008*** |
| ln (BRP pro Kopf) | 0,108*** | 0,044** | -0,127*** | -0,062*** |
| (EW je km ²) / 100 | 0,091*** | 0,077*** | -0,098*** | -0,086*** |
| ln (LF) | 0,516*** | 0,508*** | | |
| GVE/ha | 0,059*** | 0,049*** | -0,085*** | -0,076*** |
| (ÜN je EW) / 10 | 0,003*** | 0,002*** | -0,003*** | -0,002*** |
| ln (Säule 1 je ha) | 0,339*** | 0,071*** | -0,410*** | -0,169*** |
| W_lokal*ln (Säule 1 je ha) | | 1,145*** | | -1,060*** |
| ln(ÖPUL+AZ je ha) | 0,449*** | 0,437*** | -0,660*** | -0,729*** |
| W_lokal*ln(ÖPUL+AZ je ha) | | -0,015 | | 0,287*** |
| ln(Investitionsförderungen je Betrieb) | 0,003* | -0,001 | -0,003* | 0,001 |
| W_lokal* | | 0,053*** | | -0,052*** |
| ln(Investitionsförderungen je Betrieb) | | | | |
| ln(LE Säule 2 je EW) | 0,029** | 0,028** | -0,028* | -0,027* |
| W_lokal*ln(LE Säule 2 je EW) | | 0,251*** | | -0,236*** |
| Beobachtungen | 30.990 | 30.990 | 30.990 | 30.990 |
| R ² | 0,202 | 0,233 | 0,180 | 0,205 |
| Signifikanzniveaus: | . p<0,1; * p<0,05; ** p<0,01; *** p<0,001 | | | |

Tabelle 6: Ergebnisse der FE- und SLX-Modelle. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Das R² der geschätzten Modelle ist mit 0,18 bis 0,23 zwar gering, dies ist jedoch auf den Umstand zurückzuführen, dass fixed-effects-Modelle geschätzt wurden. Das R² spiegelt deshalb nur wider, welcher Anteil der Änderungen der abhängigen Variablen im Laufe der Zeit durch die Änderungen der unabhängigen Variablen im Laufe der Zeit erklärt werden. Würde man dem Modell Dummy-Variablen für jede Gemeinde hinzufügen, wäre das R² wesentlich höher (vgl. WOOLDRIDGE 2012, 487f.). Wird das Modell als gepoolte OLS-Regression geschätzt, liegt das R² bei 0,81 (Anzahl an Betrieben als abhängige Variable) beziehungsweise 0,56 (durchschnittliche Betriebsgröße als abhängige Variable). Das R² der SLX-Modelle ist gegenüber den fixed-effects-Modellen um 0,031 bzw. 0,025 höher.

Für einen Großteil der unabhängigen Variablen sind die Regressionskoeffizienten in allen Modellen auf dem 0,1%-Niveau signifikant. Die Schätzer der Investitionsförderungen je Betrieb sind in den fixed-effects-Modellen auf dem 5%-Niveau signifikant. In den SLX-Modellen sind die Schätzer der nicht räumlich gewichteten Investitionsförderungen nicht signifikant, werden sie

jedoch mit der lokalen SWM gewichtet, sind die geschätzten Regressionskoeffizienten auf dem 0,1%-Niveau signifikant. Die gleiche Tendenz zeigt sich bei Förderungen zur ländlichen Entwicklung der 2. Säule – auch hier sind die Schätzer der nicht räumlich gewichteten Variablen auf einem niedrigeren Niveau signifikant. In jenem SLX-Modell, in dem die Anzahl an Betrieben in einer Gemeinde die abhängige Variable ist, ist die spatial lag Variable der Zahlungen im Rahmen von ÖPUL+AZ je ha nicht signifikant.

Im Zuge der explorativen Datenanalyse hat sich gezeigt, dass eine negative Korrelation zwischen der Anzahl an Betrieben in einer Gemeinde und der durchschnittlichen Betriebsgröße besteht. Dieser Zusammenhang erklärt die Tatsache, dass die geschätzten Regressionskoeffizienten aller Variablen, deren Vorzeichen positiv ist wenn die Anzahl der Betriebe die abhängige Variable ist, ein negatives Vorzeichen aufweisen, wenn die durchschnittliche Betriebsgröße die abhängige Variable ist und umgekehrt. Interessant ist, dass sich das Vorzeichen der geschätzten Regressionskoeffizienten im Falle der Zahlungen im Rahmen von ÖPUL+AZ je ha umdreht, wenn diese Variable als spatial lag Variable betrachtet wird, der Effekt ist jedoch nicht signifikant.

Betriebsstruktur

Mit einem steigenden Anteil an Biobetrieben (**% Biobetriebe**) in einer Gemeinde geht eine geringere Anzahl an Betrieben in dieser Gemeinde einher, jedoch eine größere durchschnittliche Betriebsgröße. Steigt der Anteil an Biobetrieben um ein Prozent, sinkt die Anzahl an Betrieben um 0,3%, während die durchschnittliche Betriebsgröße um 0,4% steigt. Ein ähnliches Bild zeigt sich für den Anteil der Ackerflächen (**% Ackerfläche**) an der gesamten LF (jeweils nach Betriebssitz). Steigt der Anteil an Ackerflächen um ein Prozent, sinkt die Anzahl an Betrieben um 0,6%, die durchschnittliche Betriebsgröße steigt um 0,8%. Je höher der Viehbesatz je ha (**GVE/ha**) ist, desto höher ist die Anzahl an Betrieben und geringer die durchschnittliche Betriebsgröße in einer Gemeinde. Erhöht sich der Viehbesatz um ein GVE je ha, erhöht sich die Anzahl an Betrieben um 5,9% (fixed-effects-Modell) bzw. 4,9% (SLX-Modell). Die durchschnittliche Betriebsgröße sinkt um 8,5% (fixed-effects-Modell) bzw. 7,5% (SLX-Modell). Dass die Schätzer der Regressionskoeffizienten einiger Variablen zwischen fixed-effects- und SLX-Modell variieren, ist möglicherweise darauf zurückzuführen, dass durch unbeobachtete Effekte der Effekt dieser Variablen im fixed-effects-Modell überschätzt wird. Ein Teil dieser unbeobachteten Effekte spiegelt sich in den Regressionskoeffizienten der spatial lag Variablen in den SLX-Modellen wider.

Standortabhängige Variablen

Zwischen der Anzahl an Betrieben und dem Umfang der LF in ha (nach Betriebssitz) in einer Gemeinde (**ln(LF)**) besteht eine erwartungsgemäß hohe und signifikante Korrelation. Steigt der Umfang der LF in ha in einer Gemeinde um ein Prozent, erhöht sich die Anzahl an Betrieben um 0,52% (fixed-effects-Modell) bzw. 0,51% (SLX-Modell). Je höher das Bruttoregionalprodukt pro Person in einer Region (**ln(BRP pro Kopf)**) ist, desto mehr Betriebe gibt es. Steigt dieses um ein Prozent, erhöht sich die Anzahl an Betrieben um 0,11% (fixed-effects-Modell) bzw. 0,04% (SLX-Modell). Die Betriebsgröße sinkt jedoch um 0,13% (fixed-effects-Modell) bzw. 0,06% (SLX-Modell). Die im Falle dieser Variable sehr hohe Differenz zwischen den Schätzern der fixed-effects- und SLX-Modelle wird möglicherweise dadurch erklärt, dass es sich beim BRP pro Kopf um eine Variable handelt, die auf der NUTS3-Ebene aggregiert wurde. Dies könnte dazu führen, dass diese Variable deshalb in den FE-Modellen einen Teil der unbeobachteten Effekte widerspiegelt, die auf regionaler Ebene wirken und in den SLX-Modellen von den spatial lag Variablen aufgefangen werden.

Ergebnisse

Je höher die Einwohnerdichte in einer Gemeinde ist ($(EW \text{ je km}^2)/100$), desto höher ist die Anzahl an Betrieben. Mit einer um 100 Personen je km^2 erhöhten Einwohnerdichte geht eine um 9,1% (fixed-effects-Modell) bzw. 7,7% (SLX-Modell) erhöhte Anzahl an Betrieben einher. Gleichzeitig sinkt die durchschnittliche Betriebsgröße um 9,8% (fixed-effects-Modell) bzw. 8,9% (SLX-Modell). Auch zwischen der Tourismusintensität in einer Gemeinde ($(\ddot{U}N \text{ je EW})/10$) und den beiden abhängigen Variablen besteht ein signifikanter Zusammenhang. In Gemeinden mit 10 $\ddot{U}N$ pro Jahr und EW mehr, ist die Anzahl an landwirtschaftlichen Betrieben um 0,3% (fixed-effects-Modell) bzw. 0,2% (SLX-Modell) erhöht. Die durchschnittliche Betriebsgröße ist jedoch um 0,3% (fixed-effects-Modell) bzw. 0,2% (SLX-Modell) geringer.

Agrarförderungen

Ein Hauptaugenmerk dieser Arbeit liegt auf dem Einfluss der Agrarförderungen auf den Agrarstrukturwandel in Österreich. Dieser wurde im Rahmen dieser Arbeit anhand vier unabhängiger Variablen untersucht. Die Vorzeichen aller dieser Variablen lassen erkennen, dass die untersuchten Agrarförderungen den Agrarstrukturwandel in Österreich bremsen.

Ist die Summe der Agrarförderungen je ha ($\ln(\text{Säule 1 je ha})$) um ein Prozent, erhöht, geht damit eine um 0,34% höhere Anzahl an Betrieben in einer Gemeinde einher. Gleichzeitig sinkt die durchschnittliche Betriebsgröße um 0,41%. In den SLX-Modellen ist diese Korrelation auf Ebene der Gemeinden deutlich weniger stark, aber dennoch signifikant. Eine Prozent mehr geht dann mit einer um 0,07% erhöhten Anzahl an Betrieben und einer um 0,17% geringeren durchschnittlichen Betriebsgröße einher. Werden die Zahlungen in benachbarten Gemeinden berücksichtigt und die Agrarförderungen der 1. Säule je ha im SLX-Modell räumlich gewichtet ($W_{\text{lokal}} \cdot \ln(\ddot{O}PUL + AZ \text{ je ha})$), führt ein Prozent an Zahlungen mehr zu einer um 1,15% erhöhten Anzahl an Betrieben bzw. einer um 1,06% geringeren Betriebsgröße.

In den fixed-effects-Modellen zeigt sich, dass die Höhe der Förderungen im Rahmen von $\ddot{O}PUL$ und AZ je ha ($\ln(\ddot{O}PUL + AZ \text{ je ha})$) einen ähnlich hohen Effekt auf die abhängigen Variablen hat. Steigt die Summe dieser Förderungen je ha um ein Prozent, so erhöht sich damit die Anzahl an Betrieben in einer Gemeinde um 0,45%, gleichzeitig sinkt aber deren durchschnittliche Betriebsgröße um 0,66%. Die Ergebnisse der SLX-Modelle weisen bezüglich dieser Variable ein anderes Muster auf als bezüglich der Agrarförderungen der 1. Säule. Wenn als abhängige Variable die Anzahl an Betrieben je Gemeinde herangezogen wird, ist die spatial lag Variable ($W_{\text{lokal}} \cdot \ln(\ddot{O}PUL + AZ \text{ je ha})$) nicht signifikant. Wird die durchschnittliche Betriebsgröße herangezogen ist die räumlich gewichtete Variable auf dem 0,1%-Niveau signifikant und weist gegenüber der nicht räumlich gewichteten Variablen ein positives Vorzeichen auf. Demnach würde auf Ebene der lokalen Nachbarschaft mit einer um ein Prozent erhöhten Summe der Förderung im Rahmen von $\ddot{O}PUL$ und AZ je ha eine um 0,29% gestiegene durchschnittliche Betriebsgröße einhergehen.

In den fixed-effects-Modellen ist der Schätzer der Regressionskoeffizienten für die Investitionsförderungen je Betrieb ($\ln(\text{Investitionsförderungen je Betrieb})$) auf dem 5%-Niveau signifikant. Den Ergebnissen dieser Modelle zufolge haben Investitionsförderungen nur einen geringen Einfluss auf den Agrarstrukturwandel. Steigt deren Summe je Betrieb um ein Prozent, erhöht sich die Anzahl an Betrieben um 0,003%, die durchschnittliche Betriebsgröße sinkt um 0,003%. In den SLX-Modellen ist die Variable in ihrer nicht räumlich gewichteten Form nicht signifikant. Auf der Ebene der lokalen Nachbarschaft, wenn die Investitionsförderungen mit einer SWM gewichtet werden ($W_{\text{lokal}} \cdot (\text{Investitionsförderungen je Betrieb})$) ist der Schätzer

Ergebnisse

der Regressionskoeffizienten hingegen signifikant. Werden die Investitionsförderungen um ein Prozent erhöht, steigt die Anzahl an Betrieben um 0,05% und die durchschnittliche Betriebsgröße sinkt um 0,5%.

In der unabhängigen Variable **ln(LE Säule 2 je EW)** werden jene Förderungen zusammengefasst, die nicht (nur) direkt an landwirtschaftliche Betriebe ausbezahlt werden, sondern zur Förderung der ländlichen Entwicklung beitragen sollen. Die Ergebnisse der Schätzer dieser Variablen deuten darauf hin, dass auch diese Förderungen dazu beitragen, den Agrarstrukturwandel zu bremsen. Werden die Förderungen um ein Prozent erhöht, ist, den Schätzern der fixed-effects-Modelle zufolge, die Anzahl an Betrieben in einer Gemeinde um 0,03% höher, die durchschnittliche Betriebsgröße jedoch um 0,03% geringer. In den SLX-Modellen wird dieser Effekt nahezu gleich hoch geschätzt bei gleichem Signifikanzniveau. Die spatial lag Variable (**W_lokal*ln(LE Säule 2 je EW)**) ist auf dem 0,1%-Niveau signifikant und zeigt einen stärkeren Effekt: um ein Prozent höhere Förderungen zur ländlichen Entwicklung haben auf Ebene der lokalen Nachbarschaft eine um 0,25% erhöhte Anzahl an Betrieben und eine um 0,24% verringerte durchschnittliche Betriebsgröße zur Folge.

Erweiterte SLX-Modelle

In den in Tabelle 6 beschriebenen Ergebnissen wurden lediglich agrarförderungsbezogene Variablen in den SLX-Modellen mit einer SWM gewichtet. Einerseits da das Hauptaugenmerk dieser Arbeit auf diesen Variablen liegt, andererseits weil, wie in Kapitel 4.1 erläutert, angenommen wird, dass, über den Mechanismus des Bodenmarktes, diese Variablen besonders geeignet sind, um räumliche Abhängigkeiten abzubilden. In Tabelle 7 und 8 sind die Ergebnisse der SLX-Modelle vorgestellt, wenn auch weitere Variablen als spatial lag Variablen berücksichtigt werden. Gleichzeitig wurden diese Modelle auch unter der Verwendung verschiedener Radien zur Definition der Nachbarschaft gewählt. Zweck ist zum einen, zu untersuchen ob sich auf lokaler bzw. regionaler Ebene wirkende Effekte auch in den Schätzern weiterer unabhängiger Variablen niederschlagen. Andererseits soll untersucht werden, wie sich die Definition der Nachbarschaft auf die Modellergebnisse auswirkt. Gegenüber Tabelle 6 ist in der vierten Zeile der Tabellen 7 und 8 der jeweilige Radius der Nachbarschaftsmatrix für jedes der geschätzten SLX-Modelle ergänzt. Räumlich gewichteten Variablen ist das Kürzel „W_“ vorangestellt.

Betriebsstruktur

Die Schätzer für den Anteil an Biobetrieben (**% Biobetriebe**) ändern sich gegenüber den in Tabelle 6 gezeigten Modellen nur geringfügig. Die Schätzer der räumlich gewichteten Variablen (**W_ *% Biobetriebe**) sind in den SLX-Modellen bei einem Nachbarschaftsradius von 16,3 bis 45 km nahezu gleich, wenn als abhängige Variable die Anzahl an Betrieben herangezogen wird. Ab einem Radius von 45 km nehmen Bedeutung und Signifikanz dieser spatial lag Variablen deutlich ab und sind bei einem Nachbarschaftsradius von 75 km ist die Variable nicht mehr signifikant. Der Anteil an Biobetrieben in der näheren Umgebung hat also einen Einfluss auf die Anzahl an Betrieben in einer Gemeinde, je größer die Nachbarschaft jedoch gefasst wird, desto geringer ist der Einfluss. Anders verhält sich diese Variable wenn die durchschnittliche Betriebsgröße als abhängige Variable herangezogen wird, hier bleiben Einfluss und Signifikanz des Anteils an Biobetrieben ähnlich.

Auch den Anteil an Ackerflächen (**% Ackerfläche**) betreffend sind die nicht räumlich gewichteten Variablen in allen erweiterten SLX-Modellen nahezu gleich mit jenen der fixed-effects-Modelle. Interessant ist das Verhalten der spatial lag Variablen (**W_*% Ackerfläche**): ihr Vorzeichen kehrt sich gegenüber der nicht gewichteten Variablen um, gleichzeitig nimmt die Bedeutung der Variablen zu, je größer die Nachbarschaft definiert wird. Während sich also auf Gemeindeebene ein höherer Anteil an Ackerflächen negativ auf die Betriebsanzahl auswirkt, wirkt sich ein hoher Anteil an Ackerflächen in der Nachbarschaft bzw. Region positiv auf diese aus. Andersherum wirkt sich ein höherer Anteil auf Gemeindeebene negativ auf die durchschnittliche Betriebsgröße aus, während sich ein höherer Anteil in der Nachbarschaft bzw. in der Region positiv auf diese auswirkt.

Im erweiterten SLX-Modell wird der Einfluss der Viehbesatzdichte (**GVE/ha**) in der nicht räumlich gewichteten Form deutlich geringer geschätzt als in den fixed-effects-Modellen. Deutlich stärker ist der Effekt der spatial lag Variablen (**W_*GVE/ha**). Die Beträge der Schätzer der Regressionskoeffizienten nehmen für beide abhängigen Variablen mit zunehmender Größe der definierten Nachbarschaft deutlich zu.

Standortabhängige Variablen

Wie jene der Viehbesatzdichte je ha sind auch die geschätzten Regressionskoeffizienten der nicht räumlich gewichteten Einwohnerdichte (**(EW je km²)/100**) in den erweiterten SLX-Modellen deutlich geringer als in den Ausgangsmodellen. Die meisten der spatial lag Variablen (**W_*(EW je km²)/100**) sind auf dem 0,1%-Niveau signifikant. Zwischen der spatial lag Variable und der Anzahl an Betrieben besteht bis zu einem Nachbarschaftsradius von 45 km ein zunehmender, aber negativer Zusammenhang. Der Schätzer der Variable bei einem Radius von 55 km ist nicht signifikant, weist jedoch ein negatives Vorzeichen auf. Die Schätzer für die Variable in den Modellen mit einem Radius von 65 und 75 km weisen ebenfalls einen negativen Zusammenhang auf und sind auf dem 0,1%-Niveau signifikant. Das gleiche Muster ist erkennbar in den Modellen mit der durchschnittlichen Betriebsgröße als abhängiger Variable. Hier wechselt das Vorzeichen von negativ auf positiv bei einem Radius der Nachbarschaftsmatrix von 45 km.

Das BRP pro Person auf NUTS3-Ebene (**ln(BRP pro Kopf)**) wurde nicht mit einer SWM gewichtet, da dieses bereits auf einer höheren räumlichen Ebene aggregiert ist. Der Schätzer des Regressionskoeffizienten ist in den meisten Modellen nicht signifikant und schwankt zudem stark. Die Instabilität dieser Variable ist möglicherweise darauf zurückzuführen, dass es sich um eine auf NUTS3-Ebene aggregierte Variable handelt, wobei jede NUTS3-Ebene bis zu fünf Bezirke umfasst, deren Gemeinden sehr unterschiedliche Charakteristika aufweisen könnten.

In der nicht räumlich gewichteten Form schwankt der Schätzer des Regressionskoeffizienten der Übernachtungsintensität (**(ÜN je EW)/10**) und ist meist nicht signifikant. Zwischen der spatial lag Variable der Übernachtungsintensität (**W_*(ÜN je EW)/10**) und der Anzahl an Betrieben besteht ein auf dem 5%-Niveau oder niedrigerer signifikanter Zusammenhang, der mit zunehmendem Radius der Nachbarschaftsmatrix zunimmt. Ist die durchschnittliche Betriebsgröße die abhängige Variable, schwanken Signifikanz und Höhe des Schätzers.

Agrarförderungen

Die Schätzer der Regressionskoeffizienten der nicht räumlich gewichteten Agrarförderungen der 1. Säule der GAP (**ln(Säule 1 je ha)**) liegen nahe an denen der zuvor geschätzten SLX-Modelle, wenn die lokale Nachbarschaftsmatrix herangezogen wird. Für beide abhängigen Variablen

Ergebnisse

nehmen sie in ihrem Betrag jedoch mit zunehmendem Nachbarschaftsradius zu. In spatial lag Form ($W_* \ln(\text{Säule 1 je ha})$) sind die Beträge der Schätzer geringer als in den Ausgangsmodellen und bleiben über alle geschätzten Modelle hinweg relativ konstant.

Die Summe an Agrarförderungen im Rahmen von ÖPUL und AZ je ha ($\ln(\text{ÖPUL+AZ je ha})$) weisen in den Modellen für beide abhängigen Variablen in ihrer nicht räumlich gewichteten Form ähnliche Werte auf wie in den zuvor geschätzten SLX-Modellen. Anders als in denselben ist die spatial lag Variable ($W_* \ln(\text{ÖPUL+AZ je ha})$) dieser Variable nun in allen Modellen für beide abhängigen Variablen auf dem 0,1%-Niveau signifikant und weist, wie bereits beobachtet, ein umgekehrtes Vorzeichen auf. Dies bedeutet, auf Ebene der Gemeinde scheinen diese Zahlungen den Agrarstrukturwandel zu bremsen, da höhere Zahlungen mit einer höheren Anzahl an Betrieben und einer geringeren durchschnittlichen Betriebsgröße einhergehen. Steigen die Zahlungen jedoch in der lokalen oder regionalen Nachbarschaft einer Gemeinde, wirkt sich dies negativ auf die Anzahl an Betrieben in dieser Gemeinde aus und die durchschnittliche Betriebsgröße steigt.

Auch die Effekte der nicht räumlich gewichteten Investitionsförderungen je Betrieb ($\ln(\text{Investitionsförderungen je Betrieb})$) sind in den in Tabelle 7 und 8 vorgestellten Modellen jenen der Ausgangsmodelle sehr ähnlich. Wie auch in den ursprünglichen SLX-Modellen sind die Schätzer der räumlich gewichteten Investitionszahlungen signifikant und weisen auch ähnliche Werte auf. Je größer die Nachbarschaft definiert wird, desto größer ist der Effekt.

Das gleiche Muster zeigt sich in den Förderungen zur ländlichen Entwicklung je EW im Rahmen der 2. Säule. Die Werte der nicht räumlich gewichteten Förderungen ($\ln(\text{LE Säule 2 je EW})$) kommen jenen der Ausgangsmodelle nahe. Die Schätzer der spatial lag Variable ($W_*(\text{LE Säule 2 je EW})$) sind durchwegs auf dem 0,1%-Niveau signifikant. Der Betrag der Schätzer ist aber gegenüber jenem Modell mit einer lokalen Nachbarschaft zehnmal so hoch, wenn als Radius zur Definition der Nachbarschaft 75 km gewählt wird.

Ergebnisse

| | <i>abhängige Variable:</i> | | | | | | |
|--|---|-------------|-------------|-------------|-------------|-------------|-------------|
| | Anzahl Betriebe (ln) | | | | | | |
| | <i>SLX</i> | | | | | | |
| Radius Nachbarschaftsmatrix | <i>lokal</i> | <i>25km</i> | <i>35km</i> | <i>45km</i> | <i>55km</i> | <i>65km</i> | <i>75km</i> |
| % Biobetriebe | -0,002*** | -0,002*** | -0,002*** | -0,002*** | -0,002*** | -0,002*** | -0,002*** |
| W_ *% Biobetriebe | -0,005*** | -0,006*** | -0,005*** | -0,005*** | -0,003*** | -0,001* | 0,0002 |
| % Ackerfläche | -0,005*** | -0,005*** | -0,006*** | -0,006*** | -0,006*** | -0,006*** | -0,006*** |
| W_ *% Ackerfläche | 0,003*** | 0,004*** | 0,005*** | 0,007*** | 0,009*** | 0,011*** | 0,012*** |
| ln (BRP pro Kopf) | 0,025 | 0,004 | -0,013 | -0,027 | -0,036* | -0,038* | -0,038* |
| (EW je km ²) / 100 | 0,047*** | 0,043*** | 0,051*** | 0,057*** | 0,064*** | 0,071*** | 0,071*** |
| W_ *(EW je km ²) / 100 | 0,179*** | 0,213*** | 0,175*** | 0,101*** | -0,026 | -0,188*** | -0,334*** |
| ln (LF) | 0,511*** | 0,510*** | 0,508*** | 0,511*** | 0,511*** | 0,511*** | 0,510*** |
| GVE/ha | 0,024*** | 0,019*** | 0,021*** | 0,023*** | 0,024*** | 0,026*** | 0,028*** |
| W_ *GVE/ha | 0,319*** | 0,486*** | 0,610*** | 0,700*** | 0,784*** | 0,848*** | 0,931*** |
| (ÜN je EW) / 10 | 0,0003 | 0,0003 | 0,0001 | 0,0001 | 0,0002 | 0,0003 | 0,001 |
| W_ *(ÜN je EW) / 10 | 0,003*** | 0,003* | 0,004* | 0,005* | 0,007* | 0,013*** | 0,013*** |
| ln (Säule 1 je ha) | 0,063*** | 0,060*** | 0,085*** | 0,111*** | 0,133*** | 0,151*** | 0,155*** |
| W_ *ln (Säule 1 je ha) | 0,706*** | 0,725*** | 0,701*** | 0,683*** | 0,690*** | 0,711*** | 0,828*** |
| ln(ÖPUL+AZ je ha) | 0,427*** | 0,396*** | 0,363*** | 0,360*** | 0,351*** | 0,347*** | 0,349*** |
| W_ *ln(ÖPUL+AZ je ha) | -0,253*** | -0,396*** | -0,439*** | -0,510*** | -0,463*** | -0,351*** | -0,340*** |
| ln(Investitionsförderungen je Betrieb) | -0,001 | -0,001 | -0,001 | -0,002 | -0,001 | -0,001 | -0,001 |
| W_ *ln(Investitionsförderungen je Betrieb) | 0,048*** | 0,062*** | 0,077*** | 0,087*** | 0,094*** | 0,098*** | 0,097** |
| ln(LE Säule 2 je EW) | 0,028** | 0,027** | 0,027** | 0,028** | 0,027** | 0,026* | 0,025* |
| W_ *ln(LE Säule 2 je EW) | 0,233*** | 0,458*** | 0,765*** | 1,163*** | 1,604*** | 2,020*** | 2,366*** |
| Beobachtungen | 30.990 | 30.990 | 30.990 | 30.990 | 30.990 | 30.990 | 30.990 |
| R ² | 0,269 | 0,284 | 0,288 | 0,290 | 0,289 | 0,289 | 0,291 |
| Signifikanzniveaus: | . p<0,1; * p<0,05; ** p<0,01; *** p<0,001 | | | | | | |

Tabelle 7: Ergebnisse der SLX-Modelle mit weiteren, räumlich verzögerten Variablen. Abhängige Variable: Anzahl an Betrieben je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Ergebnisse

| | <i>abhängige Variable:</i> | | | | | | |
|---|---|-------------|-------------|-------------|-------------|-------------|-------------|
| | durchschnittliche Betriebsgröße (ln) | | | | | | |
| | <i>SLX</i> | | | | | | |
| Radius Nachbarschaftsmatrix | <i>lokal</i> | <i>25km</i> | <i>35km</i> | <i>45km</i> | <i>55km</i> | <i>65km</i> | <i>75km</i> |
| % Biobetriebe | 0,002*** | 0,002*** | 0,002*** | 0,002*** | 0,003*** | 0,003*** | 0,003*** |
| W_ *% Biobetriebe | 0,006*** | 0,007*** | 0,007*** | 0,007*** | 0,007*** | 0,005*** | 0,004*** |
| % Ackerfläche | 0,008*** | 0,008*** | 0,008*** | 0,008*** | 0,009*** | 0,009*** | 0,009*** |
| W_ *% Ackerfläche | -0,005*** | -0,006*** | -0,007*** | -0,010*** | -0,012*** | -0,013*** | -0,014*** |
| ln (BRP pro Kopf) (EW je km ²) / 100 | -0,013 | 0,011 | 0,027 | 0,041* | 0,049** | 0,051** | 0,048** |
| W_ *(EW je km ²) / 100 | -0,129*** | -0,152*** | -0,101*** | -0,029 | 0,116*** | 0,325*** | 0,488*** |
| GVE/ha | -0,053*** | -0,049*** | -0,052*** | -0,053*** | -0,055*** | -0,056*** | -0,057*** |
| W_ *GVE/ha | -0,310*** | -0,458*** | -0,555*** | -0,631*** | -0,707*** | -0,766*** | -0,840*** |
| (ÜN je EW) / 10 | -0,001 | -0,001 | -0,0003 | -0,0004 | -0,0005 | -0,001 | -0,001* |
| W_ *(ÜN je EW) / 10 | -0,003** | -0,003* | -0,003 | -0,005* | -0,006* | -0,010** | -0,007 |
| ln (Säule 1 je ha) | -0,163*** | -0,166*** | -0,191*** | -0,213*** | -0,231*** | 0,245*** | -0,245*** |
| W_ *ln (Säule 1 je ha) | -0,665*** | -0,658*** | -0,630*** | -0,587*** | -0,568*** | -0,587*** | -0,720*** |
| ln(ÖPUL+AZ je ha) | -0,709*** | -0,655*** | -0,615*** | -0,608*** | -0,599*** | -0,591*** | -0,587*** |
| W_ *ln(ÖPUL+AZ je ha) | 0,510*** | 0,604*** | 0,619*** | 0,705*** | 0,690*** | 0,623*** | 0,636*** |
| ln(Investitionsförderungen je Betrieb) | 0,001 | 0,002 | 0,002 | 0,002* | 0,002 | 0,002 | 0,002 |
| W_ *ln(Investitionsförderungen je Betrieb) | -0,046*** | -0,061*** | -0,075*** | -0,084*** | -0,089*** | -0,091*** | -0,091*** |
| ln(LE Säule 2 je EW) | -0,028** | -0,028* | -0,028* | -0,029** | -0,028** | -0,027* | -0,026* |
| W_ *ln(LE Säule 2 je EW) | -0,224*** | -0,405*** | -0,669*** | -1,015*** | -1,348*** | -1,709*** | -2,049*** |
| Beobachtungen | 30.990 | 30.990 | 30.990 | 30.990 | 30.990 | 30.990 | 30.990 |
| R ² | 0,241 | 0,252 | 0,254 | 0,256 | 0,256 | 0,256 | 0,259 |
| Signifikanzniveaus: | . p<0,1; * p<0,05; ** p<0,01; *** p<0,001 | | | | | | |

Tabelle 8: Ergebnisse der SLX-Modelle mit weiteren, räumlich verzögerten Variablen. Abhängige Variable: durchschnittliche Betriebsgröße in ha je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Vergleich der räumlichen Effekte in verschiedenen Hauptproduktionsgebieten

Die kartographische Darstellung des local Moran's I in Abbildung 10 hat bereits gezeigt, dass es in Österreich Regionen gibt, in welchen räumliche Abhängigkeiten stärker ausgeprägt zu sein scheinen als in anderen Regionen. In manchen Regionen könnten räumliche Abhängigkeiten darüber hinaus durch geographische Bedingungen gedämpft werden, beispielsweise wenn zwei eigentlich direkt aneinandergrenzende Gemeinden faktisch durch einen Gebirgsstock voneinander getrennt werden. Um diese Annahme und die anhand des local Moran's I beobachteten Zusammenhänge zu überprüfen, wurden die in Tabelle 6 vorgestellten SLX-Modelle auf Basis zwei kleinerer Datensätze berechnet, die jeweils Gemeinden in unterschiedlichen Hauptproduktionsgebieten Österreichs umfassen. Ausgewählt wurden hierfür einerseits die Hauptproduktionsgebiete 7 und 8 (nordöstliches bzw. südöstliches Flach- und Hügelland). Beide liegen im Osten Österreichs, weisen einen eher geringen Median der Seehöhe über NN auf und zeigen bereits in Abbildung 10 starke räumliche Abhängigkeiten. Andererseits handelt es sich um Gemeinden des Hauptproduktionsgebietes 1, welches die Hochalpen umfasst. Die Ergebnisse dieser Modelle sind in Tabelle 9 zusammengefasst.

Ergebnisse

| | <i>abhängige Variable:</i> | | | |
|---|---|-------------|--------------------------------------|-------------|
| | Anzahl Betriebe (ln) | | durchschnittliche Betriebsgröße (ln) | |
| | <i>SLX</i> | | | |
| Hauptproduktionsgebiet | <i>1</i> | <i>7, 8</i> | <i>1</i> | <i>7, 8</i> |
| % Biobetriebe | -0,001*** | -0,001* | 0,002*** | 0,002*** |
| % Ackerfläche | -0,000 | -0,010*** | 0,001 | 0,013*** |
| ln (BRP pro Kopf) | 0,041 | -0,453*** | -0,024 | 0,366*** |
| (EW je km ²) / 100 | 0,065*** | 0,213*** | -0,088*** | -0,223*** |
| ln (LF) | 0,470*** | 0,577*** | | |
| GVE/ha | 0,048*** | 0,016 | -0,099*** | -0,037** |
| (ÜN je EW) / 10 | 0,0002 | -0,003 | -0,0004 | 0,003 |
| ln (Säule 1 je ha) | 0,001 | 0,116*** | 0,063 | -0,237*** |
| W_lokal*ln (Säule 1 je ha) | -0,081 | 1,393*** | 0,013 | -1,195*** |
| ln(ÖPUL+AZ je ha) | 0,487*** | -0,004 | -0,876*** | -0,135* |
| W_lokal*ln(ÖPUL+AZ je ha) | 0,087 | -0,851*** | 0,359*** | 0,937*** |
| ln(Investitionsförderungen je Betrieb) | -0,005** | 0,002 | 0,005** | -0,001 |
| W_lokal* | | | | |
| ln(Invesititionsförderungen je Betrieb) | -0,002 | -0,006 | -0,003 | -0,001 |
| ln(LE Säule 2 je EW) | 0,024* | 0,023 | -0,024 | -0,036 |
| W_lokal*ln(LE Säule 2 je EW) | 0,094 | 0,880*** | -0,055 | -0,948*** |
| Beobachtungen | 7.155 | 8.070 | 7.155 | 8.070 |
| R ² | 0,234 | 0,305 | 0,252 | 0,210 |
| Signifikanzniveaus: | . p<0,1; * p<0,05; ** p<0,01; *** p<0,001 | | | |

Tabelle 9: SLX-Modelle für verschiedene Hauptproduktionsgebiete Österreichs. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Um die SWM zu berechnen wurde ein Radius von 25 km für die Nachbarschaftsmatrix ausgewählt. Bei dem in den Ausgangsmodellen üblichen Radius der lokalen Nachbarschaftsmatrix von 16,3 km hätten einige Gemeinden in diesen Modellen keine Nachbarn, weshalb die nächstgrößere Nachbarschaftsmatrix gewählt wurde. Abgesehen von den Investitionsförderungen weisen in den Modellen für die Hauptproduktionsgebiete 7 und 8 alle spatial lag Variablen einen Schätzer auf, der auf dem 0,1%-Niveau signifikant ist. Hingegen ist in den Modellen für das Hauptproduktionsgebiet 1 nur ein Schätzer eines Regressionskoeffizienten auf dem 0,1%-Niveau signifikant, nämlich jener der Summe an Agrarförderungen im Rahmen von ÖPUL und AZ je ha, wenn die durchschnittliche Betriebsgröße als abhängige Variable herangezogen wird. Alle weiteren spatial lag Variablen sind nicht signifikant.

Die Schätzer der Regressionenkoeffizienten des Anteils an Biobetrieben, der Tourismusintensität sowie der nicht räumlich verzögerten Förderungen für ländliche Entwicklung unterscheiden sich zwischen den Hauptproduktionsgebieten kaum. Während der Anteil an Ackerflächen in den Hauptalpen keinen signifikanten Effekt aufweist, hat die Viehbesatzdichte in den Hauptproduktionsgebieten 7 und 8 keinen signifikanten Einfluss auf die Anzahl an Betrieben. Das Bruttoregionalprodukt pro Person weist in den Hochalpen keinen signifikanten Einfluss auf die abhängigen Variablen auf, der Effekt der Bevölkerungsdichte ist in den nord- bzw. südöstlichen Flach- und Hügelländern stärker. Die (nicht räumlich verzögerten) Förderungen im Rahmen der 1. Säule weisen in den Hochalpen keinen signifikanten Effekt auf, in den Hauptproduktionsgebieten 7 und 8 hingegen schon. Andersherum ist der Effekt der nicht räumlich verzögerten Förderungen im Rahmen von ÖPUL und AZ nur in den Hochalpen signifikant. Die Schätzer der (nicht räumlich verzögerten) Investitionsförderungen weisen in den Hochalpen ein anderes Vorzeichen auf als in den Hauptproduktionsgebieten 7 und 8.

6. Diskussion

Im Rahmen der vorliegenden Arbeit wurde der Einfluss verschiedener Faktoren auf den Agrarstrukturwandel in Österreich, gemessen als Veränderung (i) der Anzahl der Betriebe und (ii) der durchschnittlichen Betriebsgröße, untersucht. Dabei wurde besonderes Augenmerk auf Agrarförderungen sowie im Zusammenhang damit stehender räumlicher Effekte gelegt. Hierfür wurden (Agrar-)Strukturdaten zu 2.066 österreichischen Gemeinden aus je 15 Jahren (2003-2017) herangezogen, was in Summe 30.990 Beobachtungen entspricht. In Kapitel 6.1 wird diskutiert, wie damit umgegangen wurde und welche Konsequenzen daraus für die vorliegenden Ergebnisse folgen könnten. In Kapitel 6.2 werden diese Ergebnisse insbesondere im Hinblick auf zuvor getroffene Annahmen diskutiert und interpretiert.

6.1. Diskussion der Datengrundlage und Methode

Im Rahmen einer Literaturanalyse wurde zu Beginn ermittelt, welche Faktoren im später entwickelten Modell berücksichtigt werden müssen, um den Agrarstrukturwandel in Österreich anhand ökonomischer Methoden erklären zu können. Dabei ist es wichtig, all jene Faktoren zu ermitteln, welche einen signifikanten Einfluss auf die abhängigen Variablen haben und zugleich mit den Agrarförderungen korrelieren, da sich das Hauptaugenmerk der Arbeit auf den Einfluss dieser richtet. Dadurch wird vermieden, dass es durch das Vorliegen von Endogenität aufgrund unbeobachteter Variablen zu verzerrten Ergebnissen kommt (vgl. GREENE 2012, 259).

Einige der Faktoren, die sich im Rahmen dieser Literaturanalyse als relevant erwiesen, konnten jedoch in weiterer Folge nicht berücksichtigt werden, da Daten zu diesen im Rahmen dieser Arbeit nicht verfügbar sind. Dies betrifft insbesondere alle Faktoren des Humankapitals der Betriebe, wie beispielsweise das Alter der Betriebsleiterinnen und Betriebsleitern. Weitere nicht berücksichtigte Faktoren, die sich in vorherigen Studien jedoch als signifikant erweisen haben, sind unter anderem der Anteil an Haupt- oder Nebenerwerbsbetrieben oder die Managementstruktur der Betriebe. Für einige Faktoren konnten stellvertretende Variablen herangezogen werden. So soll beispielsweise die wirtschaftliche Situation in einer Gemeinde bzw. Region anhand des BRP berücksichtigt werden, da im Rahmen der Arbeit keine geeigneten Daten zur Arbeitslosenquote verfügbar waren. Das Weglassen einiger Variablen könnte ein Grund für eine möglicherweise vorliegende Endogenität sein.

Ein weiterer Punkt, der die Aussagekraft der vorliegenden Ergebnisse einschränken könnte, ist die Tatsache, dass im Rahmen dieser Arbeit keine Daten auf Betriebsebene herangezogen werden konnten. Bei allen Daten handelt es sich um auf Gemeindeebene aggregierte Daten, die lediglich Durchschnittswerte für alle Betriebe einer Gemeinde widerspiegeln. Wie in Kapitel 3 erläutert, sind deshalb Aussagen nur bezogen auf alle Betriebe einer Gemeinde als Gruppe möglich. Regressionen auf Basis räumlich aggregierter Daten weisen möglicherweise zwar ein ähnlich hohes Bestimmtheitsmaß auf wie Regressionen mit Daten auf einzelbetrieblicher Ebene, dennoch dürfen die Ergebnisse nicht auf die einzelbetriebliche Ebene übertragen werden, da sonst ökologische Fehlschlüsse die Folge sein können (vgl. OPENSHAW 1984, 26). Dennoch kann davon ausgegangen werden, dass in den Ergebnissen dieser Arbeit erkennbare Zusammenhänge nicht nur durch das Verwenden von räumlich aggregierten Daten künstlich erzeugt werden. So zeigen SCHMIDTNER et al. (2015, 175ff.) in ihrer Arbeit, dass räumliche Abhängigkeiten in Bezug auf den biologischen Landbau in Deutschland sowohl auf Basis von auf Gemeinde- als auch auf Kreisebene aggregierten Daten erkennbar sind. Informationen über räumliche Abhängigkeiten gehen jedoch

insofern verloren, als dass die auf Gemeindeebene vorliegenden Ergebnisse bereits Effekte durch bestehende Nachbarschaften zwischen den Betrieben innerhalb einer Gemeinde beinhalten. STORM und HECKELEI (2018) beispielsweise können im Rahmen ihrer Arbeit auf einzelbetriebliche Daten zurückgreifen und so zwischen der einzelbetrieblichen Ebene, der lokalen Nachbarschaft und der regionalen Nachbarschaft differenzieren. In der vorliegenden Arbeit gehen Informationen verloren, weil die Datengrundlage bereits auf einer Ebene der lokalen Nachbarschaft bzw. Gemeindeebene aggregiert ist.

Die die Agrarförderungen im Rahmen der GAP beschreibenden Variablen sind zudem nicht nur räumlich aggregiert, sondern fassen, abgesehen von der Variable der Förderungen für materielle Investitionen, verschiedene Förderungen zusammen. Grund hierfür ist, dass ein Kompromiss zwischen Aussagekraft und Komplexität des Modells gefunden werden sollte. Die vorliegenden Ergebnisse erlauben deshalb zwar Rückschlüsse darüber, welchen Effekt beispielsweise die Förderungen im Rahmen der 1. Säule der GAP in Summe haben. Jedoch ist nicht erkennbar, welche Förderungen im Detail maßgeblich für diesen Effekt sind.

Des Weiteren führt das Verwenden des fixed-effects- bzw. SLX-Modells zu einem weiteren Informationsverlust. Geschätzt wird nur der Effekt der Änderungen der abhängigen Variablen im Laufe der Zeit durch die Änderungen der unabhängigen Variablen im Laufe der Zeit (vgl. WOOLDRIDGE 2012, 487f.). Der Effekt im Laufe der Zeit konstanter Variablen, wie in der vorliegenden Arbeit der Median der Seehöhe je Gemeinde, kann mit diesem Modell nicht näher untersucht werden, was allerdings auch nicht Ziel der Analyse war.

Wie bereits erläutert, basiert die Auswahl der berücksichtigten unabhängigen Variablen auf einer Literaturanalyse sowie einer explorativen Datenanalyse. Bei dieser explorativen Datenanalyse wurde, wie in Kapitel 5.2 erläutert, das Verhalten der Schätzer der Regressionskoeffizienten sowie des R^2 in verschiedenen Modellspezifikationen beobachtet. Da das R^2 nicht fallen kann, wenn dem Modell zusätzliche erklärende Variablen hinzugefügt werden, besteht jedoch die Gefahr des von Overfittings. Da das Ziel im Rahmen dieser Arbeit jedoch nicht ein möglichst exaktes Modell sondern die Beobachtung der Effekte und räumlichen Abhängigkeiten im Bezug auf Agrarförderungen im Rahmen der GAP ist, scheint die angewendete Vorgangsweise dennoch ausreichend. Darüber hinaus erwies sich das geschätzte Modell als robust gegenüber der Transformation und/oder dem Weglassen einzelner Variablen, was als Indiz gegen das Vorliegen grober Missspezifikationen gedeutet werden kann.

Neben dem Vorliegen einer Missspezifikation des Modells kann auch das Vorliegen von Endogenität im Modell nicht ausgeschlossen werden. Einerseits kann es durch vergessene bzw. unbeobachtete Variablen zu einem sogenannten *omitted variable bias* kommen, wenn die nicht berücksichtigte Variable mit anderen unabhängigen Variablen korreliert (vgl. GREENE 2012, 259). Aufgrund der Datenverfügbarkeit konnten nicht alle möglicherweise relevanten Variablen berücksichtigt oder für diese stellvertretende Variablen identifiziert werden. Verzerrte Ergebnisse durch unbeobachtete Variablen können deshalb nicht ausgeschlossen werden.

Im Rahmen dieser Arbeit wurden panelökonometrische Methoden verwendet. Das Ziel der Arbeit ist dabei nicht eine möglichst genaue Schätzung der Regressionskoeffizienten einzelner Variablen, sondern einen beschreibenden Überblick über den Agrarstrukturwandel zu geben. Deshalb ist eine gewisse Verzerrung der Schätzer der Regressionskoeffizienten durch unbeobachtete Variablen vertretbar. Eine Identifikationsstrategie, die einen möglichen *omitted variable bias* stärker in den Vordergrund rückt und, beispielsweise in weiterführenden Forschungsarbeiten,

besser geeignet ist, um nicht nur Korrelationen, sondern Kausalitäten zu erfassen, ist die Instrumentvariablenschätzung. Bei dieser wird statt der unabhängigen Variable, welche mit der unbeobachteten Variable bzw. dem Fehler korreliert ist, eine sogenannte Instrumentvariable in das Modell aufgenommen. Diese muss mit der interessierenden unabhängigen Variablen korreliert sein, darf aber nicht mit dem Fehlerterm bzw. der unbeobachteten Variable korrelieren (vgl. WOOLDRIDGE 2012, 513f.).

Eine weitere Ursache für Endogenitätsprobleme kann unbeobachtete Heterogenität (bzw. sogenannte Individualeffekte) zwischen den beobachteten Gemeinden sein (vgl. GREENE 2012, 260f.). Handelt es sich bei den Individualeffekten um zeitlich konstante Effekte, kann dieser Ursache von Endogenität durch das Verwenden eines fixed-effects-Modells beigegeben werden (vgl. WOOLDRIDGE 2012, 512). Bei diesem Modell wird von jeder Beobachtung der Variablen das arithmetische Mittel dieser Variable über alle Jahre des Beobachtungszeitraums abgezogen sodass nur der Effekt einer Veränderung einer unabhängigen Variablen auf die Veränderung der abhängigen Variablen geschätzt wird, die Individualeffekte jedoch eliminiert werden (vgl. WOOLDRIDGE 2012, 484f.). Darauf, dass Endogenität vorliegt, deutet das Ergebnis des Hausman-Tests hin. Da das Ergebnis signifikant ist, muss die Annahme $Cov(x_{itj}, c_j) = 0$, wobei die c_i die individuellen, über die Zeit konstanten Effekte darstellt, abgelehnt werden (vgl. WOOLDRIDGE 2012, 328f.)

Ein weiterer Teil der möglichen Effekte von unbeobachteten bzw. vergessenen Variablen soll durch das Erweitern des fixed-effects-Modells zu einem SLX-Modell abgefangen werden. LESAGE und PACE (2009) argumentieren, dass unbeobachtete bzw. vergessene Variablen häufig in einem räumlichen Zusammenhang stehen. So haben beispielsweise die Nähe zu Hauptverkehrsadern oder das Image einer Region einen Effekt auf die abhängige Variable, ohne dass dieser direkt beobachtet werden kann. Werden diese Effekte nicht im Modell berücksichtigt, befinden sie sich im Fehlerterm. Aufgrund der Prävalenz räumlicher Effekte kann davon ausgegangen werden, dass diese nicht nur mit der abhängigen, sondern auch mit den unabhängigen Variablen korrelieren. Ein Teil der Effekte kann deshalb abgefangen werden, wenn unabhängige Variablen auch als räumlich verzögerte Variablen in das Modell aufgenommen werden (vgl. LESAGE und PACE 2009, 27f.). Das two-ways fixed-effects-Modell berücksichtigt jedoch nur über die Zeit konstante individuelle sowie für alle Gemeinden gleichermaßen wirksame unbeobachtete Zeiteffekte. Es kann deshalb nicht ausgeschlossen werden, dass weitere, zeitlich nicht konstante und nicht alle Gemeinden gleichermaßen beeinflussende Faktoren darüber hinaus Endogenität verursachen.

Das Ergebnis des Breusch-Pagan-Tests auf das Vorliegen von Heteroskedastizität ist ebenfalls signifikant, was auf das Vorliegen von Heteroskedastizität schließen lässt. Damit wird die fünfte, in Kapitel 4.2.1 getroffene Annahme ($Var(u|x_1, x_2, \dots, x_k) = \sigma^2$) verletzt. Heteroskedastizität verursacht weder eine Verzerrung noch Inkonsistenz der Schätzer, jedoch ist die geschätzte Varianz der Schätzer $Var(\hat{\beta}_j)$ verzerrt. Da die Standardfehler auf der geschätzten Varianz basieren, sind diese ebenfalls verzerrt, mit der Konsequenz, dass die angegebenen Signifikanzen der Schätzer ungültig sind (vgl. WOOLDRIDGE 2012, 268f.). Die Berechnung der fixed-effects-Modelle mit heteroskedastierobusten Standardfehlern nach HEISS (2020, 210) zeigte, dass sich die Signifikanz der Schätzer um eine Niveaustufe nach oben bewegte. Da Schätzer der Regressionskoeffizienten der meisten unabhängigen Variablen höchst signifikant sind, bleiben sie auch unter der Berücksichtigung heteroskedastierobusten Standardfehlern signifikant.

6.2. Diskussion der Ergebnisse

Im Folgenden sollen die Ergebnisse der fixed-effects- sowie SLX-Modelle insbesondere unter der Berücksichtigung der in Kapitel 2.3 verwendeten Literatur diskutiert und interpretiert werden. Ein großer Teil der Ergebnisse deckt sich mit getroffenen Annahmen, während insbesondere ein Teil der Ergebnisse der SLX-Modellen weiteren Forschungsbedarf aufdeckt. Nach einem kurzen Vergleich der Ergebnisse der fixed-effects-Modelle mit Ergebnissen bisheriger Studien folgt eine Interpretation und Diskussion der in den SLX-Modellen beobachtbaren räumlichen Abhängigkeiten, auf welchen das Hauptaugenmerk dieser Arbeit liegt.

Fixed-effects-Modelle

Aus den Ergebnissen geht hervor, dass ein steigender Anteil an Biobetrieben in einer Gemeinde mit einer sinkenden Anzahl an Betrieben sowie einer größeren durchschnittlichen Betriebsgröße einhergeht. FERJANI et al. (2015, 67) erkennen, dass die Wahrscheinlichkeit der Betriebsaufgabe unter Biobetrieben geringer ist. Dieser scheinbare Widerspruch könnte dadurch erklärt werden, dass der Anteil an Biobetrieben vor allem in von einem starken Betriebsrückgang betroffenen Regionen steigt. Da, wie FERJANI et al. feststellen, eher konventionell bewirtschaftete Betriebe aufgegeben werden, nimmt damit der Anteil an Biobetrieben zu. Gleichzeitig nimmt mit steigendem Anteil an Biobetrieben die durchschnittliche Betriebsgröße zu. Einen ähnlichen Effekt erkennen auch BARTOLINI und VIAGGI (2013, 133): konventionell geführte Betriebe schrumpfen eher als Biobetriebe.

Die Ergebnisse zeigen, dass ein steigender Anteil an Ackerflächen an der gesamten LF einer Gemeinde mit einer sinkenden Anzahl an Betrieben und im Umkehrschluss mit einer steigenden durchschnittlichen Betriebsgröße einhergeht. Dies deckt sich mit den Ergebnissen anderer Autorinnen und Autoren: nach NIEDERMAYR et al. (2015, 281) wirkt sich ein hoher Anteil an Ackerflächen im Alpenraum negativ auf die Betriebsanzahl aus, während laut STORM und HECKELEI (2018, 7) erkennen, dass in norwegischen Regionen mit einem hohen Anteil an Ackerflächen Betriebswachstum stärker ausgeprägt ist. Ein Grund hierfür könnte in den höheren Preisen für Ackerland gegenüber Grünland liegen. Dieser könnte vor allem kleine, weniger rentable Betriebe dazu bewegen, aus der Landwirtschaft auszusteigen.

Eine steigende Anzahl an gehaltenen GVE je ha LF geht mit einer steigenden Anzahl Betrieben sowie einer sinkenden durchschnittlichen Betriebsgröße in einer Gemeinde einher. Da eine (wenn auch schwach ausgeprägte) negative Korrelation zwischen dem Anteil an Ackerflächen sowie der Viehbesatzdichte besteht, entspricht dieses Ergebnis den Erwartungen. Ein möglicher Grund ist, dass mit einer höheren Viehbesatzdichte auch eine größere Produktivität einhergeht, die die Wettbewerbsfähigkeit der Betriebe in einer Gemeinde steigert. BREUSTEDT und GLAUBEN (07, 121f.) erkennen in ihrer Studie, dass die Ausstiegsrate unter viehhaltenden Betrieben geringer ist als unter reinen Ackerbaubetrieben. Sie vermuten, dass ein Grund hierfür sein könnte, dass die Aufgabe eines viehhaltenden Betriebes zu wesentlich höheren versunkenen Kosten führt als die Aufgabe eines Ackerbaubetriebes (vgl. BREUSTEDT und GLAUBEN 2007, 122).

Da Daten zum BRP pro Kopf nur auf NUTS3-Ebene zur Verfügung stehen, ist die Aussagekraft dieser Variable beschränkt. Entgegen der Annahmen zeigen die Ergebnisse der FE-Modelle, dass in Regionen mit hohem BRP pro Kopf eine größere Anzahl an Betrieben je Gemeinde zu erwarten ist, während die durchschnittliche Betriebsgröße in diesen Gemeinden geringer ist. GLAUBEN et al. (2006, 112) hingegen erkennen, dass in Regionen mit hohem Bruttoinlandsprodukt die Ausstiegsrate landwirtschaftlicher Betriebe erhöht ist. Das BRP liegt im Rahmen dieser Arbeit jedoch auf NUTS3-Ebene vor. Jede NUTS3-Ebene umfasst dabei bis zu fünf Bezirke und damit teilweise eine große Anzahl an mitunter sehr unterschiedlichen Gemeinden, was die Ergebnisse

verzerrern könnte. So könnte es zum Beispiel der Fall sein, dass ein Großteil des BRP in einigen wenigen Gemeinden der NUTS3-Region mit sehr wenigen landwirtschaftlichen Betrieben generiert wird und tatsächlich ein hohes BRP mit einer geringeren Anzahl an Betrieben einhergeht.

Auf Basis der Literaturanalyse lässt sich keine eindeutige Annahme darüber treffen, wie sich die Bevölkerungsdichte auf den Agrarstrukturwandel auswirken könnte. Die Ergebnisse im Rahmen der vorliegenden Arbeit zeigen, dass mit steigender Bevölkerungsdichte je km² eine größere Anzahl an Betrieben sowie eine geringere durchschnittliche Betriebsgröße einhergeht. GLAUBEN et al. (2006, 112) erkennen einen ähnlichen Effekt und vermuten, dass in Regionen mit höherer Bevölkerungsdichte, also urbanen Regionen, der Agrarstrukturwandel bereits früher eingesetzt hat und damit heute weniger dynamisch verläuft als in ländlichen Regionen. Ein weiterer Grund könnte sein, dass sich in bevölkerungsreichen Gemeinden bessere Absatzmöglichkeiten für Landwirtinnen und Landwirte beispielsweise durch Direktvermarktung ergeben. Gleichzeitig ist der Wettbewerb um Boden durch einen erhöhten Nutzungsdruck stärker was die Landwirtinnen und Landwirte in ihren Wachstumsmöglichkeiten beschränkt und damit einen negativen Effekt auf die durchschnittliche Betriebsgröße hat.

Je höher die Übernachtungsintensität (Anzahl an ÜN pro EW und Jahr) ist, desto höher ist die Anzahl an Betrieben und desto geringer ist die durchschnittliche Betriebsgröße in einer Gemeinde. Dies deckt sich mit der zuvor getroffene Annahme bezüglich dieser Variablen. Ähnliche Beobachtungen machten auch GLAUBEN et al. (2006, 111) in ihrer Studie. Sie zogen als erklärende Variable den Anteil an Betrieben mit Ferienunterkünften in einer Region heran. Möglich ist, dass in Gemeinden mit starkem Tourismus auch landwirtschaftliche Betriebe von diesem profitieren. So können sie Mehreinnahmen durch das Vermieten von Gästezimmern generieren und haben bessere Absatzmöglichkeiten beispielsweise in der Direktvermarktung oder durch das Beliefern von Hotellerie- und Gastronomiebetrieben. Gleichzeitig verstärkt sich jedoch der Wettbewerb um Boden, was Landwirtinnen und Landwirte in ihren Wachstumsmöglichkeiten beschränkt.

In den fixed-effects-Modellen haben alle vier die Agrarförderungen repräsentierenden Variablen einen positiven Effekt auf die Anzahl an Betrieben in einer Gemeinde sowie einen negativen Effekt auf die durchschnittliche Betriebsgröße dieser Betriebe. Die Zahlungen im Rahmen der Säule 1 der GAP sowie jener im Rahmen von ÖPUL und AZ (jeweils je ha LF) auf haben jedoch einen deutlich stärkeren Effekt und sind auf dem 0,1%-Niveau signifikant, während die Förderungen für materielle Investitionen je Betrieb sowie jene für ländliche Entwicklung im Rahmen der 2. Säule je Einwohnerin maximal auf dem 1%-Niveau signifikant sind und einen deutlich schwächeren Effekt auf die abhängigen Variablen haben.

Die Ergebnisse der fixed-effects-Modelle weisen damit darauf hin, dass die Agrarförderungen im Rahmen der GAP den Agrarstrukturwandel tatsächlich bremsen, wenn auch in unterschiedlichem Ausmaß. Die Summe der Förderungen der 1. Säule sowie jene im Rahmen von ÖPUL und AZ zu erhöhen hätte einen deutlich stärker den Agrarstrukturwandel bremsenden Effekt als höhere Förderungen für materielle Investitionen oder Förderungen für die Entwicklung im ländlichen Raum im Rahmen der 2. Säule.

Die Förderungen für materielle Investitionen zu erhöhen hat nur einen geringen Effekt auf die abhängigen Variablen: 1.000€ mehr an Investitionsförderungen pro Betrieb führen lediglich zu 0,003% mehr Betrieben bzw. einer um 0,003% geringeren durchschnittlichen Betriebsgröße. Die Schätzer der Regressionskoeffizienten dieser Variablen sind zudem lediglich auf dem 5%-Niveau signifikant. KIRCHWEGER und KANTELHARDT (2015) untersuchten in ihrer Studie ebenfalls den Effekt von Investitionsförderungen auf den Agrarstrukturwandel in Österreich. Sie erkennen, dass diese Förderungen den Agrarstrukturwandel sogar eher verstärken, da jene Betriebe, die

Investitionsförderungen erhalten stärker wachsen (vgl. KIRCHWEGER und KANTELHARDT 2015, 86). Diese Beobachtung spiegelt sich in dieser Arbeit nicht direkt wider, da die Ergebnisse zeigen, dass höhere Förderungen für materielle Investitionen je Betrieb in einer Gemeinde mit einer geringeren durchschnittlichen Betriebsgröße einhergehen.

Mehrere AutorInnen und Autoren erkennen, dass Agrarförderungen mit geringeren Ausstiegsraten aus der Landwirtschaft einhergehen (z.B. KEY und ROBERTS 2007b, STORM et al. 2014). Diese Beobachtungen stimmen mit den Ergebnissen der vorliegenden Arbeit überein: je höher die Agrarförderungen, desto mehr Betriebe gibt es in einer Gemeinde. Gleichzeitig zeigen die Ergebnisse der fixed-effects-Modelle jedoch, dass mit höheren Agrarförderungen eine niedrigere durchschnittliche Betriebsgröße einhergeht. Dies erscheint deshalb folgerichtig, da eine negative Korrelation zwischen der Anzahl an Betrieben und der durchschnittlichen Betriebsgröße besteht. Je mehr landwirtschaftliche Betriebe es innerhalb einer Gemeinde gibt, desto geringer ist der Anteil an der gesamten LF in einer Gemeinde, den jeder einzelne Betriebe bewirtschaften kann und die durchschnittliche Betriebsgröße sinkt. Mehrere AutorInnen erkennen in ihren Arbeiten jedoch, dass Agrarförderungen in einem positiven Zusammenhang mit dem Betriebswachstum stehen (z.B. KEY und ROBERTS 2007b, STORM und HECKELEI 2018). Dieser Effekt könnte durch die räumliche Aggregation der Daten verdeckt werden. Es ist möglich, dass Betriebe, die etwas mehr Agrarförderungen je ha erhalten wachsen, während jene Betriebe, die geringere Fördersummen je ha erhalten, eher schrumpfen oder in ihrer Größe stabil bleiben. Es könnte also innerhalb der Gemeinde zu einer Umschichtung der Flächen zwischen den Betrieben kommen, die auch von der Höhe der Agrarförderungen abhängt, jedoch aufgrund der räumlichen Aggregation der Daten nicht sichtbar ist.

Die Förderungen für ländliche Entwicklung im Rahmen der 2. Säule der GAP – darunter fallen die Fördermaßnahmen für Wissenstransfer und Information, Beratungsdienste, Basisdienstleistung und Dorferneuerung, Zusammenarbeit sowie LEADER – werden nicht (nur) direkt an landwirtschaftliche Betriebe ausbezahlt, sondern richten sich an fast alle Akteurinnen und Akteure im ländlichen Raum. Auch bei diesen Förderungen ist ein bremsender Effekt auf den Agrarstrukturwandel erkennbar. Landwirtschaftliche Betriebe profitieren wahrscheinlich direkt und indirekt von diesen Förderungen. Einerseits richten sich manche Fördermaßnahmen, wie Beratungsdienste, mitunter direkt an landwirtschaftliche Betriebe. Andererseits könnten beispielsweise LEADER- oder Dorferneuerungs-Projekte zu attraktiveren Lebensbedingungen aber auch einer verbesserten wirtschaftlichen Situation in der Gemeinde führen, wovon auch Landwirtinnen und Landwirte profitieren.

Bei der Interpretation der Schätzer der die Agrarförderungen widerspiegelnden Variablen muss jedoch die unterschiedliche Skalierung der Variablen im Hinterkopf behalten werden. Um den geschätzten Effekt zu erzielen, müssen sehr unterschiedliche Summen aufgewendet werden. Dies wird anhand eines Beispiels deutlich. Angenommen, es befinden sich in einer Gemeinde 50 Betriebe, die jeweils 20 ha LF (also in Summe 1.000 ha LF) bewirtschaften. 1.000€ mehr an Förderungen je ha LF in dieser Gemeinde im Rahmen der 1. Säule der GAP erhöhen die Anzahl an Betrieben in einer Gemeinde um 0,34%. Um diesen Effekt zu erzielen, müssten $(1.000 \cdot 1.000\text{€}) = 1.000.000\text{€}$ aufgewendet werden. 1.000€ mehr an Förderungen für materielle Investitionen je Betrieb in dieser Gemeinde führen zwar nur zu einer Erhöhung der Betriebsanzahl um 0,003%, um diesen Effekt zu erreichen müssten jedoch nur $(50 \cdot 1.000\text{€}) = 50.000\text{€}$ aufgewendet werden. Die Kosten sind also um den Faktor 20 geringer. Angenommen, es steht eine Million Euro für diese Gemeinde zur Verfügung, kann mit diesen die Anzahl an Betrieben um 0,34% erhöht werden, wenn diese gänzlich über Förderungen im Rahmen der 1. Säule ausbezahlt werden. Wenn diese gänzlich über Investitionsförderung ausbezahlt werden sollen, stehen je Betrieb 20.000€ zur Verfügung, wodurch sich die Anzahl an Betrieben um 0,06% steigern ließe.

SLX-Modelle

Um den Effekt räumlicher Abhängigkeiten beobachten zu können, wurden im Rahmen von SLX-Modellen unabhängige Variablen mit einer räumlichen Gewichtungsmatrix gewichtet. In einem ersten Modell wurden lediglich die Agrarförderungen widerspiegelnde Variablen als spatial lag Variablen hinzugefügt. Gewichtet wurden diese mit einer lokalen Nachbarschaftsmatrix, bei der alle Gemeinden, deren Mittelpunkt sich maximal 16,3 km vom Mittelpunkt der beobachteten Gemeinde entfernt befinden, als Nachbarn definiert werden.

Die Schätzer der Regressionskoeffizienten der übrigen unabhängigen Variablen ändern sich dadurch nur geringfügig. Lediglich jene des BRP pro Kopf auf NUTS3-Ebene reduzieren sich deutlich, was jedoch auch durch die Tatsache, dass dieses auf NUTS3-Ebene aggregiert vorliegt, erklärt werden kann. Es ist möglich, dass die Schätzer des auf regionaler Ebene aggregierten Bruttoregionalprodukts damit bereits einen Teil der auf regionaler Ebene wirkenden unbeobachteten Faktoren auffangen, die sich nun verstärkt in den Schätzern der räumlich verzögerten Variablen der Agrarförderungen widerspiegeln.

Der Effekt der Förderungen im Rahmen der 1. Säule der GAP wird in den fixed-effects-Modellen deutlich überschätzt. In deren nicht räumlich verzögerten Form der SLX-Modelle ist die Korrelation zwischen diesen Förderungen und den abhängigen Variablen um den Faktor 4,8 bzw. 2,4 geringer als in den fixed-effects-Modellen. STORM und HECKELEI (2018, 5ff.) argumentieren, dass die Ursache für diese Unterschiede in unbeobachteten auf lokaler bzw. regionaler Ebene wirkenden Faktoren liegen könnte. Nachbarschaftseffekte zwischen Landwirtinnen und Landwirte entstehen vor allem durch zwei bereits in Kapitel 2.2 erwähnte Ursachen: den Wettbewerb um Boden sowie durch Informationsnetzwerke. Mit zunehmender Entfernung von der beobachteten Gemeinde nehmen diese Effekte ab. Dann gewinnen andere auf regionaler Ebene wirkende unbeobachtete Effekte, beispielsweise gute Produktionsbedingungen in der gesamten Region, an Bedeutung (vgl. STORM und HECKELEI 2018, 5ff.). Diese Zusammenhänge könnten in den SLX-Modellen sichtbar sein: auf Gemeindeebene bremst möglicherweise der Wettkampf um landwirtschaftlich nutzbaren Boden den Effekt der Agrarförderungen.

Ein anderes Bild zeigt sich bezüglich der Summe der Agrarförderungen welche im Rahmen von ÖPUL und AZ je ha. Die Schätzer der nicht räumlich verzögerten Variablen liegen in den SLX-Modellen sehr nahe an jenen der fixed-effects-Modelle. Die spatial lag Variablen ändern gegenüber diesen ihr Vorzeichen. Ist die Anzahl an Betrieben die abhängige Variable, ist der Schätzer des Regressionskoeffizienten zudem nicht signifikant. Ein Grund hierfür könnte in der Struktur dieser Förderungen liegen. Die ausbezahlte Summe dieser Förderung unterscheidet sich regional stark, wie auch in Abbildung 9 (unten) ersichtlich. AZ werden zudem nicht in allen Regionen Österreichs ausbezahlt. Der Effekt der sich dadurch ergibt ist möglicherweise in den Schätzern der räumlich gewichteten Variablen sichtbar. In Grenzregionen, wo sich die ausbezahlten Summen unter den Gemeinden besonders stark unterscheiden, beschleunigen diese Förderungen den Agrarstrukturwandel möglicherweise. Wenn die Betriebe einiger Gemeinden stärker von den Förderungen profitieren ist ihre WTP für Boden möglicherweise höher, und sie schränken somit die Betriebe anderer Gemeinden in ihren Entwicklungsmöglichkeiten ein.

In den SLX-Modellen sind nur die Schätzer der räumlich verzögerten Investitionsförderungen signifikant. Die Korrelation dieser Variablen mit den abhängigen Variablen ist zudem deutlich stärker als die der nicht räumlich verzögerten Investitionsförderungen. Investitionsförderungen werden nicht in jedem Jahr an alle Betriebe ausbezahlt sondern sind abhängig von der Investitionstätigkeit seitens der Betriebe. Die Summe der Investitionsförderungen je Betrieb in einer Gemeinde schwankt dadurch teilweise deutlich zwischen einzelnen Jahren, weshalb sich der Effekt auf Gemeindeebene nur schwer schätzen lässt. In der spatial lag Variable werden die

Investitionszahlungen an Betriebe in mehreren Gemeinden berücksichtigt. Hierdurch liegt der Wert der spatial lag Variable näher am Durchschnittswert, es treten weniger Ausreißer auf, der Regressionskoeffizient kann besser geschätzt werden und ist zugleich signifikanter.

Die Schätzer der spatial lag Variablen der Zahlungen für ländliche Entwicklung zeigen eine starke Korrelation mit den abhängigen Variablen und sind höchst signifikant. Die nicht räumlich gewichtete Variable dieser Zahlungen zeigt einen schwächeren Effekt und eine geringere Signifikanz. Eine Ursache hierfür könnte sein, dass diese Zahlungen ihre Wirkung vor allem auf regionaler Ebene entfalten. Denn fließen beispielsweise Förderungen für Beratungsdienste in eine Gemeinde, könnten davon auch Landwirtinnen und Landwirte umliegender Gemeinden profitieren.

Im nächsten Schritt wurden dem SLX-Modell weitere spatial lag Variablen hinzugefügt. Gleichzeitig wurde das Modell unter der Verwendung unterschiedlicher Nachbarschaftsmatrizen geschätzt. Da das Bruttoregionalprodukt pro Kopf bereits auf NUTS3-Ebene aggregiert ist, wurde diese unabhängige Variable nicht mit einer räumlichen Gewichtungsmatrix gewichtet. Ihr Effekt erweist sich zudem in den meisten Modellen als nicht mehr signifikant. Dies könnte daran liegen, dass die Variable in den zuvor geschätzten Modellen als auf regionaler Ebene aggregierte Ebene vor allem auf regionaler Ebene wirkende Effekte abgebildet hat, und somit überschätzt wurde. Diese regionalen, unbeobachteten Effekte werden in den weiteren Modellen wahrscheinlich von den anderen, räumlich verzögerten Variablen abgebildet. Ebenso wurde die LF je Gemeinde nicht als räumlich verzögerte Variable in die Modelle mitaufgenommen, da diese vor allem die durch administrative Grenzziehungen verursachten Gemeindegrößen, aber keine tatsächlich herrschenden Standortbedingungen in der Nachbarschaft widerspiegeln würde.

Die Schätzer der Regressionskoeffizienten des Anteils an Ackerflächen in einer Gemeinde erweisen sich als robust, wenn dem Modell weitere räumlich verzögerte Variablen hinzugefügt werden. Die Schätzer der spatial lag Variablen des Ackeranteils weisen jedoch umgekehrte Vorzeichen auf. Auf regionaler Ebene betrachtet, führt ein größerer Anteil an Ackerflächen zu einer größeren Anzahl an Betrieben mit einer geringeren durchschnittlichen Betriebsgröße, auf Ebene der Gemeinden ist das Gegenteil der Fall. Der Effekt könnte auch hier, ähnlich wie STORM und HECKELEI (2018, 7) vermuten, in auf regionaler Ebene wirkenden Standortbedingungen liegen. In Regionen mit einem hohen Anteil an Ackerflächen ist der Wettbewerb unter den Landwirten innerhalb einer Gemeinde möglicherweise aufgrund der hohen Bodenpreise hoch, was mit einer geringen Anzahl an Betrieben und einer größeren durchschnittlichen Betriebsgröße einhergeht. Auf regionaler Ebene betrachtet sind Regionen mit einem hohen Anteil an Ackerflächen Regionen mit allgemein sehr guten Standortbedingungen, was zu einer größeren Anzahl an Betrieben führt. Ähnlich wie bei den Agrarförderungen im Rahmen der 1. Säule der GAP zeigt sich bei der Viehbesatzdichte, dass diese in den fixed-effects-Modellen auf lokaler Ebene deutlich überschätzt wird.

Bis zu einem Nachbarschaftsradius von 55 km hat die Bevölkerungsdichte je km² als spatial lag Variable den gleichen Effekt, wie in ihrer nicht räumlich verzögerten Form. Dann kehrt sich das Vorzeichen jedoch um und mit einer größeren Bevölkerungsdichte auf regionaler Ebene geht dann eine geringere Anzahl an Betrieben und eine größere durchschnittliche Betriebsgröße einher. Auf kleinräumlicher Ebene ermöglicht eine große Bevölkerungsdichte den LandwirtInnen und Landwirte möglicherweise bessere Absatzmöglichkeiten. Ist die Bevölkerungsdichte aber in der gesamten Region hoch und es handelt sich damit um eine urbane Region, kommen andere Faktoren zum Tragen, die sich eher beschleunigend auf den Agrarstrukturwandel auswirken.

Ebenso wie die Förderungen für ländliche Entwicklung im Rahmen der 2. Säule der GAP ist die Wirkung der Übernachtungsintensität (ÜN je EW und Jahr) auf der regionalen Ebene auf den

Agrarstrukturwandel deutlich stärker als auf Gemeindeebene. Der Grund hierfür besteht möglicherweise in ähnlichen räumlichen Abhängigkeiten: von einer starken Tourismusintensität in einer Gemeinde profitieren möglicherweise auch Nachbargemeinden, sodass sich der Effekt dieser Variable verstärkt, wenn die gesamte Region von einer hohen Nächtigungsintensität profitiert.

Die Schätzer der nicht räumlich verzögerten Variablen der verschiedenen Agrarförderungen zeigen sich robust gegenüber dem Einfügen von weiteren spatial lag Variablen. Die räumlich verzögerten Variablen der Zahlungen der 1. Säule im Rahmen der GAP wurden in den vorherigen SLX-Modellen überschätzt. Möglicherweise wird ein Teil der regionalen Effekte, der sich in den Schätzern dieser Variablen widerspiegelt, in den erweiterten SLX-Modellen von anderen spatial lag Variablen aufgefangen.

Die spatial lag Variablen der Zahlungen im Rahmen von ÖPUL und AZ sind nun für beide abhängigen Variablen signifikant und die Korrelation wird deutlich stärker geschätzt. Möglich ist, dass räumlich Effekte, die sich nun in den Schätzern der weiteren spatial lag Variablen widerspiegeln, die zuvor den räumlichen Effekt dieser Zahlungen zuvor unterdrückt haben. Je größer die Nachbarschaft definiert wird, desto stärker wird zudem die Korrelation, jedoch nur bis zu einer Distanz von 45 km. Ein Grund für diesen Effekt könnte sein, dass mit zunehmender Größe der definierten Nachbarschaft mehr und mehr Grenzregionen erfasst werden. In diesen kommt es, wie bereits erwähnt, möglicherweise aufgrund der Ausgestaltung dieser Zahlungen zu erhöhter Konkurrenz zwischen landwirtschaftlichen Betrieben, was den Agrarstrukturwandel möglicherweise beschleunigt.

Wird die lokale Nachbarschaftsmatrix herangezogen, ändert sich der Schätzer der räumlich verzögerten Investitionsförderungen kaum. Je größer die Nachbarschaft definiert wird, desto größer werden die räumlichen Abhängigkeiten im Bezug auf diese Variable. Ein Grund hierfür könnte sein, dass sich der bereits diskutierte räumliche Effekt der Investitionszahlungen mit zunehmender Größe der definierten Nachbarschaft verstärkt.

Die Korrelation der räumlich verzögerten Förderungen für ländliche Entwicklung im Rahmen der 2. Säule der GAP bleibt auf der Ebene der lokalen Nachbarschaft gleich, nimmt aber deutlich zu, je großzügiger die Nachbarschaftsmatrix definiert wird. Es ist möglich, dass, wie bereits diskutiert, diese Zahlungen ihre Wirkung vor allem auf regionaler Ebene entfalten und ihr Effekt nicht auf einzelne Betriebe bzw. Gemeinden und ihre direkten Nachbarn beschränkt ist. Der Effekt dieser Zahlungen verstärkt sich deshalb wahrscheinlich, je mehr Gemeinden als Nachbargemeinden definiert werden.

Vergleich der räumlichen Effekte in verschiedenen Hauptproduktionsgebieten

Die Ergebnisse zeigen, dass es in Österreich räumliche Abhängigkeiten gibt, die die Wirkung verschiedener Faktoren und insbesondere auch die Wirkung von Agrarsubventionen im Rahmen der GAP beeinflussen. Wie jedoch bereits im Rahmen der räumlich-deskriptiven und insbesondere der Analyse des local Moran's I deutlich wurde, ist anzunehmen, dass diese räumlichen Abhängigkeiten nicht in ganz Österreich gleichermaßen wirken. Um diese Vermutung zu überprüfen, wurden SLX-Modelle für verschiedene Hauptproduktionsgebiete getrennt berechnet und die Ergebnisse verglichen.

Es zeigt sich, dass es deutliche Unterschiede im Ausmaß und in der Signifikanz räumlicher Abhängigkeiten in Bezug auf Agrarförderungen innerhalb Österreichs gibt. Drei der vier räumlich verzögerten Variablen, die sich auf Agrarförderungen beziehen, zeigen in den Hauptproduktionsgebieten 7 und 8 (nordöstliches sowie südöstliches Flach- und Hügelland) eine Signifikanz der Schätzer auf dem 0,1%-Niveau. Die Schätzer dieser Variablen sind nicht

signifikant, wenn die Modelle nur für Gemeinden des Hauptproduktionsgebietes 10 (Hochalpen) geschätzt werden. Es ist also einerseits anzunehmen, dass es Faktoren gibt, die räumliche Abhängigkeiten zwischen Gemeinden in einigen Regionen fördern oder ermöglichen. Andererseits gibt es möglicherweise Faktoren, die räumliche Abhängigkeiten in anderen Regionen bremsen oder unmöglich machen.

Ein Vergleich der kartographischen Darstellungen im Rahmen der räumlich-deskriptiven Statistik mit der räumlichen Verortung der Hauptproduktionsgebiete in Österreich (vgl. Abbildung 16 im Anhang) macht einige mögliche Zusammenhänge deutlich.

Anhand der Abbildungen 3 und 4 zeigt sich, dass sich der Agrarstrukturwandel in den Hauptproduktionsgebieten 7 und 8 besonders dynamisch entwickelt, während dieser in den Hochalpen deutlich weniger ausgeprägt ist. Hier ist die durchschnittliche Betriebsgröße einerseits deutlich geringer, andererseits hat die Anzahl an landwirtschaftlichen Betrieben in den Jahren 2003 bis 2017 deutlich weniger stark abgenommen. Dass der Agrarstrukturwandel im österreichischen Alpenraum deutlich langsamer voranschreitet, erkannte auch STREIFENEDER (2009, 43). Dies lässt annehmen, dass ein Zusammenhang zwischen dem Ausmaß an räumlichen Abhängigkeiten und der Dynamik des Agrarstrukturwandels vorliegt.

Ein Blick auf die Abbildungen 5, 6 und 7 zeigt, dass sich die Produktionsbedingungen sowie die Betriebsstrukturen im nord- bzw. südöstlichen Flach- und Hügelland deutlich von jenen in den Hochalpen unterscheiden. Möglicherweise hängt das Ausmaß der räumlichen Abhängigkeiten auch davon ab, welche Betriebstypen in den jeweiligen Regionen dominieren. Dass sich landwirtschaftliche Betriebe unterschiedlichen Typen im Bezug auf ihr Verhalten gegenüber benachbarten Betrieben zuordnen lassen erkannten auch SAINT-CYR et al. (2019, 256ff.). Möglicherweise liegt diese Heterogenität auch zwischen verschiedenen Betriebstypen (bzw. spezifische Produktionsausrichtungen) vor.

Abbildung 8 zeigt den Median der Seehöhe über NN je Gemeinde. Anhand dieser Karte wird deutlich, dass die Gemeinden in Hauptproduktionsgebiet 10 deutlich höher als jene der Hauptproduktionsgebiete 7 und 8 liegen. Die daraus resultierenden geographischen Unterschiede zwischen den Hauptproduktionsgebieten könnten ein weiterer Hinweis auf mögliche Gründe für deutlich geringere räumliche Abhängigkeiten in den Hochalpen sein. Im alpinen Raum werden benachbarte Gemeinden möglicherweise durch Gebirgsstöcke getrennt. Nachbarschaftliche Beziehungen wie der Informationsaustausch werden dadurch möglicherweise behindert oder unterbunden.

Auch die Schätzer der nicht räumlich verzögerten Variablen weisen teilweise Unterschiede zwischen den untersuchten Teilregionen Österreichs auf. Der Anteil an Ackerflächen weist in den Hochalpen keinen signifikanten Effekt auf, in den nord- und südöstlichen Flach- und Hügelländern hingegen schon. Ein ähnlicher Effekt zeigt sich bezüglich der Viehbesatzdichte, der Schätzer dieser Variable ist in den Hochalpen signifikanter. Dies hängt wahrscheinlich damit zusammen, dass Ackerbau in den Alpen und Viehhaltung in den nord- und südöstlichen Flach- und Hügelländern eine untergeordnete Rolle spielt, was sich auch in den Abbildung 6 und 7 erkennen lässt.

Der Einfluss des Bruttoregionaleproduktes pro Kopf ist in den Hochalpen nicht signifikant, in den Hauptproduktionsgebieten 7 und 8 hingegen schon. Da diese Variable auf NUT3-Ebene aggregiert ist, könnte dieser Zusammenhang auf geringere räumliche Abhängigkeiten in den Hochalpen zurückzuführen sein. Die Schätzer der Förderungen im Rahmen der 1. Säule der GAP sind in den Hauptproduktionsgebieten 7 und 8 höchst signifikant, in den Hochalpen nicht. Umgekehrt sind Förderungen im Rahmen von ÖPUL und AZ in den Hochalpen höchst signifikant, in den Hauptproduktionsgebieten maximal auf dem 5%-Niveau. Der Grund hierfür könnte sein, dass die

Förderintensität bezüglich ÖPUL und AZ in den Alpen deutlich höher ist als in den nord- und südöstlichen Flach- und Hügelländern, wo AZ teilweise gar nicht ausbezahlt werden und deshalb keine Auswirkung auf den Agrarstrukturwandel haben. Hingegen ist die Förderintensität bezüglich der 1. Säule in den nord- und südöstlichen Flach- und Hügelländern größer. Im Gegensatz zu den Hauptproduktionsgebieten 7 und 8 sind die Schätzer der Investitionsförderungen in den Hochalpen signifikant und weisen umgekehrtes Vorzeichen auf. Der Grund hierfür ist unklar, liegt aber möglicherweise auch darin, dass sich der Einfluss der Investitionsförderungen im Rahmen dieser Arbeit aufgrund der räumlich aggregierten Ebene nur schwer schätzen lässt. Wie bereits erwähnt, werden Investitionsförderungen jedes Jahr nur an einen Teil der Betriebe ausbezahlt, was zu großen Unterschieden in den ausbezahlten Summen pro Betrieb je Gemeinde zwischen einzelnen Jahren führt. Um realistischere Ergebnisse erzielen zu können, müsste dieser Zusammenhang auf Basis einzelbetrieblicher Daten untersucht werden.

6.3. Schlussfolgerungen und Ausblick

Es ist das Ziel dieser Arbeit, einen Überblick über Einflussfaktoren auf den Agrarstrukturwandel zu geben und Zusammenhänge in Österreich, unter der Berücksichtigung räumlicher Abhängigkeiten, anhand ökonometrischer Methoden zu schätzen. Insbesondere sollte untersucht werden, ob räumliche Abhängigkeiten in den Effekten von Agrarförderungen auf den Agrarstrukturwandel erkennbar sind und ob sich diese Abhängigkeiten in ganz Österreich gleichermaßen erkennen lassen.

Anhand einer Literaturrecherche konnten mögliche Einflussfaktoren ermittelt werden, die sich den Kategorien Humankapital, Betriebsstruktur, Standortfaktoren sowie Agrarförderungen zuordnen lassen. Die Ergebnisse der geschätzten Modelle liefern Hinweise zu vorliegenden Korrelationen zwischen den berücksichtigten, unabhängigen Variablen und der Anzahl an Betrieben je Gemeinde bzw. deren durchschnittliche Betriebsgröße als wesentliche Indikatoren des Agrarstrukturwandels. Die Schätzung von räumlich-ökonometrischen SLX-Modellen unter der Berücksichtigung räumlich verzögerter Variablen zeigt, dass es eine Reihe von räumlichen Abhängigkeiten gibt, die einen signifikanten Einfluss auf die abhängigen Variablen haben. Diese nicht zu berücksichtigen führt, wie der Vergleich mit den geschätzten fixed-effects-Modellen zeigt, dazu, dass der Einfluss mancher unabhängiger Variablen überschätzt wird. So weisen die Schätzer der Korrelationskoeffizienten der räumlich verzögerten Zahlungen im Rahmen von ÖPUL und AZ ein anderes Vorzeichen auf als die entsprechende nicht räumlich verzögerte Variable. Dasselbe gilt auch für den Anteil an Ackerflächen an der gesamten LF einer Gemeinde. Die Schätzer der Investitionszahlungen sind in den SLX-Modellen nur als räumlich verzögerte Variablen signifikant, aber nicht auf Ebene der Gemeinden. Außerdem hat sich gezeigt, dass besonders der Effekt der Förderungen im Rahmen der 1. Säule der GAP in den fixed-effects-Modellen auf Gemeindeebene deutlich überschätzt wird. Innerhalb Österreichs gibt es jedoch deutliche Unterschiede in der Ausprägung und Signifikanz dieser räumlichen Abhängigkeiten. Während diese im süd- bzw. nordöstlichen Flach- und Hügelland einen signifikanten Einfluss auf den Agrarstrukturwandel zeigen, haben sie auf den Agrarstrukturwandel in den Hochalpen keinen signifikanten Einfluss.

Welche Gründe es für diese Unterschiede in den räumlichen Abhängigkeiten innerhalb Österreichs gibt, kann im Rahmen dieser Arbeit zwar diskutiert, aber nicht beantwortet werden und könnte Gegenstand weiterer Forschungsarbeiten sein. Mit Hilfe von GIS-Software könnte beispielsweise das Vorhandensein von verschiedenen Infrastrukturen (beispielsweise

Diskussion

hochrangiger Verkehrsverbindungen) berücksichtigt werden, um so mögliche Ursachen zu untersuchen. Darüber hinaus wurden im Rahmen dieser Arbeit alle Ergebnisse auf Basis von auf Gemeindeebene aggregierten Daten ermittelt, mit den bereits geschilderten Auswirkungen. Um detaillierte und realistischere Einschätzungen zu den Auswirkungen räumlicher Abhängigkeiten auf den Agrarstrukturwandel zu erhalten, sollten diese auch anhand einzelbetrieblicher Daten untersucht werden. Daneben erlauben die in dieser Arbeit geschätzten fixed-effects- sowie SLX-Modelle keine Rückschlüsse auf den Effekt zeitlich konstanter Variablen, wie beispielsweise der durchschnittlichen Seehöhe oder der Lage der Gemeinde in einer bestimmten Region. Auch zeitliche Effekte, die alle Gemeinden gleichermaßen beeinflussen (wie beispielsweise der Beginn einer neuen Förderperiode) wurden nicht geschätzt. Diese Effekte zu untersuchen war nicht Ziel dieser Arbeit, sie im Detail zu untersuchen könnte jedoch Gegenstand weiterer Forschungsarbeiten sein.

Es ist wichtig zu erwähnen, dass im Rahmen der vorliegenden Arbeit zwar Korrelationen aufgezeigt werden, zugrunde liegende Kausalitäten jedoch lediglich diskutiert werden können. Es soll nicht der kausale Zusammenhang einzelner unabhängiger Variablen mit den abhängigen Variablen möglichst genau geschätzt werden. Das mögliche Vorliegen von Endogenität in den geschätzten Modellen macht dies zudem nicht möglich. Das Ziel ist eher, einen Überblick über mögliche Einflussfaktoren und Zusammenhänge zu geben, sowie insbesondere auch erste Erkenntnisse über mögliche räumliche Abhängigkeiten in Bezug auf den Agrarstrukturwandel in Österreich zu gewinnen. Kausale Zusammenhänge, beispielsweise anhand von Instrumentvariablenschätzungen, zu ermitteln kann Gegenstand weiterer Forschungsarbeiten sein. Die vorliegende Arbeit gibt einen Überblick über den Agrarstrukturwandel und dessen Einflussfaktoren in Österreich, zeigt erstmals räumliche Abhängigkeiten auf und öffnet damit das Feld für eine Reihe weiterer Forschungsarbeiten.

Literaturverzeichnis

AKIMOWICZ, M.; MAGRINI, M.-B.; RIDIER, A.; BERGEZ, J.-E.; REQUIER-DESJARDINS, D. (2013): What Influences Farm Size Growth? An Illustration in Southwestern France. *Applied Economic Perspectives and Policy* 35 Nr. 2, 242–269.

AMA - AGRARMARKT AUSTRIA (2018): INVEKOS Schlage sterreich 2018. Unter: https://www.data.gv.at/katalog/dataset/ama_invekosschlgesterreich2018/resource/1df4c9ed-a8c8-46cf-b472-d9bb630a13a6 (06.08.2020).

ANSELIN (2001): Spatial Econometrics. In: BALTAGI, BADI H. (Hrsg.): *A Companion to Theoretical Econometrics*. Malden: Blackwell Publishing, 310–330.

AUBERT, MAGALI; PERRIER-CORNET, PHILIPPE (2009): Is there a future for small farms in developed countries? Evidence from the French case. *Agricultural Economics* 40 Nr. 34, 797–806.

BAB - BUNDESANSTALT FUR AGRARWIRTSCHAFT UND BERGBAUERNFRAGEN (2020): *Gemeindedatenbank 2019*. Wien: nicht veroffentlicht.

BALMANN, ALFONS (1997): Farm-based modelling of regional structural change: A cellular automata approach. *European Review of Agricultural Economics* 24, 85–108.

BALTAGI, BADI H. (2005): *Econometric Analysis of Panel Data*. Chichester: John Wiley & Sons, Ltd.

BARTOLINI, FABIO; VIAGGI, DAVIDE (2013): The common agricultural policy and the determinants of changes in EU farm size. *Land Use Policy* 31, 126–135.

BEN ARFA, NEJLA; DANIEL, KARINE; JACQUET, FLORENCE; KARANTININIS, KOSTAS (2015): Agricultural Policies and Structural Change in French Dairy Farms: A Nonstationary Markov Model. *Canadian Journal of Agricultural Economics/Revue canadienne d'agroeconomie* 63 Nr. 1, 19–42.

BERGER, THOMAS (2001): Agent-based spatial models applied to agriculture: a simulation tool for technology diffusion, resource use changes and policy analysis. *Agricultural Economics* 25, 245–260.

BEV - BUNDESAMT FUR EICH- UND VERMESSUNGSWESEN (2019): *Verwaltungsgrenzen (VGD) - Stichtagsdaten grundstucksgenau*. Unter: <https://www.data.gv.at/katalog/dataset/51bdc6dc-25ae-41de-b8f3-938f9056af62> (31.05.2020).

BIVAND, ROGER S. (2019): *Spatial Dependence: Weighting Schemes, Statistics*. Unter: <https://CRAN.R-project.org/package=spdep> (12.11.2020).

BIVAND, ROGER S. (2020): *Creating Neighbours*. Unter: <https://cran.r-project.org/web/packages/spdep/vignettes/nb.pdf> (11.11.2020).

BIVAND, ROGER S.; KEITT, TIM; ROWLINGSON, BARRY (2019): *Bindings for the "Geospatial" Data Abstraction Library*. Unter: <https://CRAN.R-project.org/package=rgdal> (12.11.2020).

BIVAND, ROGER S.; PEBESMA, EDZER; GOMEZ-RUBIO, VIRGILIO (2013): *Applied Spatial Data Analysis with R*. New York: Springer.

BMNT - BUNDESMINISTERIUM FUR NACHHALTIGKEIT UND TOURISMUS (2018): *Gruner Bericht 2018*. Wien: Selbstverlag.

BMNT - BUNDESMINISTERIUM FUR NACHHALTIGKEIT UND TOURISMUS (2019): *Gruner Bericht 2019*. Wien: Selbstverlag.

Literaturverzeichnis

- BREUSTEDT, GUNNAR; GLAUBEN, THOMAS (2007): Driving Forces behind Exiting from Farming in Western Europe. *Journal of Agricultural Economics* 58 Nr. 1, 115–127.
- CROISSANT, YVES; MILLO, GIOVANNI; TAPPE, KEVIN (2019): Linear Models for Panel Data. Unter: <https://cran.r-project.org/package=plm> (12.11.2020).
- ECKEY, HANS-FRIEDRICH; KOSFELD, REINHOLD; DREGER, CHRISTIAN (2011): *Ökonometrie*. Wiesbaden: Gabler Verlag.
- ELHORST, J. PAUL (2014): *Spatial Econometrics*. Heidelberg u.a.: Springer.
- FERJANI, ALI; ZIMMERMANN, ALBERT; ROESCH, ANDREAS (2015): Determining Factors of Farm Exit in Agriculture in Switzerland. *Agricultural Economics Review* 16 Nr. 1, 59–72.
- GELLRICH, MARIO; ZIMMERMANN, NIKLAUS E. (2007): Investigating the regional-scale pattern of agricultural land abandonment in the Swiss mountains: A spatial statistical modelling approach. *Landscape and Urban Planning* 79 Nr. 1, 65–76.
- GEOLAND.AT (2020): Digitales Geländemodell (DGM) Österreich. Unter: <https://www.data.gv.at/katalog/dataset/d88a1246-9684-480b-a480-ff63286b35b7> (31.05.2020).
- GETIS, ARTHUR (2009): Spatial Weights Matrices. *Geographical Analysis* 41, 404–410.
- GIBBONS, STEPHEN; OVERMAN, HENRY G. (2012): Mostly Pointless Spatial Econometrics? *Journal of Regional Science* 52 Nr. 2, 172–191.
- GLAUBEN, THOMAS; TIETJE, HENDRIK; WEISS, CHRISTOPH R. (2006): Agriculture on the move: Exploring regional differences in farm exit rates in Western Germany. *Jahrbuch für Regionalwissenschaft* 26, 103–118.
- GOCHT, ALEXANDER; RÖDER, NORBERT; NEUENFELDT, SEBASTIAN; STORM, HUGO; HECKELEI, THOMAS (2012): *Modelling farm structural change*. Sevilla: European Commission.
- GREENE, WILLIAM H. (2012): *Econometric analysis*. Boston: Prentice Hall.
- GROIER, MICHAEL (2004): Wachsen und Weichen. *Ländlicher Raum* Nr. 6, 1–23.
- GROSJEAN, PHILIPPE; IBANEZ, FREDERIC (2018): Package for Analysis of Space-Time Ecological Series. Unter: <https://CRAN.R-project.org/package=pastecs> (12.11.2020).
- HAPPE, KATHRIN; BALMANN, ALFONS; KELLERMANN, KONRAD; SAHRBACHER, CHRISTOPH (2008): Does structure matter? The impact of switching the agricultural policy regime on farm structures. *Journal of Economic Behavior & Organization* 67 Nr. 2, 431–444.
- HAPPE, KATHRIN; KELLERMANN, KONRAD; BALMANN, ALFONS (2006): Agent-based Analysis of Agricultural Policies: an Illustration of the Agricultural Policy Simulator AgriPoliS, its Adaptation and Behavior. *Ecology and Society* 11 Nr. 1, s.p.
- HEISS, FLORIAN (2020): Using R for Introductory Econometrics. Düsseldorf. Unter: <http://urfie.net/read/index.html> (03.12.2020).
- HLAVAC, MAREK (2018): Well-Formatted Regression and Summary Statistics Tables. Unter: <https://cran.r-project.org/package=stargazer> (12.11.2020).
- HOTHORN, TORSTEN; ZEILEIS, ACHIM; FAREBROTTER, RICHARD W.; CUMMINS, CLINT (2019): *Testing Linear Regression Models*. Unter: <https://cran.r-project.org/package=lmtest> (12.11.2020).

Literaturverzeichnis

- KEY, NIGEL; ROBERTS, MICHAEL J. (2007a): Cropland Concentrating Faster Where Payments Are Higher. *Amber Waves* 5 Nr. 5, 30–35.
- KEY, NIGEL; ROBERTS, MICHAEL J. (2007b): Do Government Payments Influence Farm Size and Survival? *Journal of Agricultural and Resource Economics* 32 Nr. 2, 330–349.
- KEY, NIGEL; ROBERTS, MICHAEL J. (2006): Government Payments and Farm Business Survival. *American Journal of Agricultural Economics* 88 Nr. 2, 382–392.
- KIRCHWEGER, STEFAN; KANTELHARDT, JOCHEN (2015): The dynamic effects of government-supported farm-investment activities on structural change in Austrian agriculture. *Land Use Policy* 48, 73–93.
- KIRNER, LEOPOLD (2004): Entwicklungstendenzen in der österreichischen Milchproduktion auf Ebene der Einzelbetriebe - Befragung von Bauern und Bäuerinnen. *Die Bodenkultur* 55 Nr. 2, 53–62.
- KIRNER, LEOPOLD (2019): Relevanz und Perspektiven der land- und forstwirtschaftlichen Diversifizierung in Österreich. *Berichte über Landwirtschaft* 97 Nr. 1, 1–22.
- LÄPPLE, DORIS.; KELLEY, HUGH (2015): Spatial dependence in the adoption of organic drystock farming in Ireland. *European Review of Agricultural Economics* 42 Nr. 2, 315–337.
- LESAGE, JAMES (2014): What regional scientists need to know about spatial econometrics. SSRN, s.p.
- LESAGE, JAMES; PACE, R. KELLEY (2009): *Introduction to Spatial Econometrics*. Boca Raton: CRC Press.
- MANN, STEFAN (2003): Bestimmungsgründe des landwirtschaftlichen Strukturwandels. *Agrarforschung Schweiz* 10 Nr. 1, 32–36.
- MILLO, GIOVANNI; PIRAS, GIANFRANCO (2018): *Econometric Models for Spatial Panel Data*. Unter: <https://cran.r-project.org/package=splm> (12.11.2020).
- NAHRSTEDT, HARALD (2015): *Die Monte-Carlo-Methode*. Wiesbaden: Springer Fachmedien Wiesbaden.
- NEUENFELDT, SEBASTIAN; GOCHT, ALEXANDER; HECKELEI, THOMAS; CIAIAN, PAVEL (2019): Explaining farm structural change in the European agriculture: a novel analytical framework. *European Review of Agricultural Economics* 46 Nr. 5, 713–768.
- NIEDERMAYR, ANDREAS; KAPFER, MARTIN; KANTELHARDT, JOCHEN (2016): Regional heterogeneity and spatial interdependence as determinants of the cultivation of an emerging alternative crop: The case of the Styrian Oil Pumpkin. *Land Use Policy* 58, 276–288.
- NIEDERMAYR, JULIA; HOFFMANN, CHRISTIAN; STAWINOJA, AGNIESKA; STREIFENEDER, THOMAS (2015): Agro-structural patterns in the Alps 2000-2010. *Jahrbuch der Österreichischen Gesellschaft für Agrarökonomie* 24, 275–284.
- OPENSHAW, S. (1984): Ecological fallacies and the analysis of areal census data. *Environment and Planning* 16 Nr. A, 17–31.
- PARKER, DAWN C.; BERGER, THOMAS; MANSON, STEVEN M. (2002): *Agent-Based Models of Land-Use and Land-Cover Change*. Indiana: Selbstverlag.

Literaturverzeichnis

- PENZ, HUGO (2011): Die Entwicklung der Landwirtschaft im österreichischen Alpenraum nach dem Grad der Betriebserschwerung. Mitteilungen der Österreichischen Geographischen Gesellschaft 153, 7–30.
- PLANT, RICHARD E. (2012): Spatial Data Analysis in Ecology and Agriculture using R. Boca Raton: CRC Press.
- QUENDLER (2015): Zum Phänomen bäuerlicher Familienbetriebe - Charakteristika und Entwicklungen. In: EGARTNER, SIGRID; RESL, THOMAS (Hrsg.): Einblicke in Österreichs Landwirtschaft seit dem EU-Beitritt. Wien: AWI - Bundesanstalt für Agrarwirtschaft, 35–66.
- R CORE TEAM (2018): A language and environment for statistical computing. R Foundation for Statistical Computing. Wien, Österreich. Unter: <https://www.R-project.org/> (03.12.2020).
- ROBERTS, MICHAEL J.; KEY, NIGEL (2008): Agricultural Payments and Land Concentration: A Semiparametric Spatial Regression Analysis. American Journal of Agricultural Economics 90 Nr. 3, 627–643.
- ROBINSON, W. S. (2009): Ecological correlations and the behavior of individuals. International journal of epidemiology 38 Nr. 2, 337–341.
- RSTUDIO TEAM (2016): RStudio: Integrated Development for R. RStudio. Boston, MA. Unter: <http://www.rstudio.com/> (03.12.2020).
- SAINT-CYR, LEGRAND D. F.; STORM, HUGO; HECKELEI, THOMAS; PIET, LAURENT (2019): Heterogeneous impacts of neighbouring farm size on the decision to exit: evidence from Brittany. European Review of Agricultural Economics 46 Nr. 2, 237–266.
- SCHMID, ERWIN (2007): Einflussfaktoren der Betriebsentwicklung mit besonderer Berücksichtigung der Einkommensverteilung in der österreichischen Landwirtschaft. Jahrbuch der Österreichischen Gesellschaft für Agrarökonomie 16, 73–84.
- SCHMIDTNER, EVA; LIPPERT, CHRISTIAN; DABBERT, STEPHAN (2015): Does Spatial Dependence Depend on Spatial Resolution? - An Empirical Analysis of Organic Farming in Southern Germany. German Journal of Agricultural Economics 64 Nr. 3, 175–191.
- SCHMIDTNER, EVA; LIPPERT, CHRISTIAN; ENGLER, BARBARA; HÄRING, ANNA MARIA; AURBACHER, JOACHIM; DABBERT, STEPHAN (2012): Spatial distribution of organic farming in Germany: does neighbourhood matter? European Review of Agricultural Economics 39 Nr. 4, 661–683.
- SEHER, WALTER (2004): Welchen Stellenwert hat die Land- und Forstwirtschaft in der Raumplanung? Der Öffentliche Sektor - Forschungsmemoranden 30 Nr. 1-2, 61–68.
- SINABELL, FRANZ (2004): Entwicklungstendenzen der österreichischen Landwirtschaft seit dem EU-Beitritt. Ländlicher Raum Nr. 6, 1–20.
- STATISTIK AUSTRIA (2019): Bruttoregionalprodukt nominell 2000-2017 nach NUTS 3-Regionen: absolut und je Einwohner. Unter: https://www.statistik.at/wcm/idc/idcplg?IdcService=GET_NATIVE_FILE&RevisionSelectionMethod=LatestReleased&dDocName=019126 (31.05.2020).
- STORM, HUGO; HECKELEI, THOMAS (2015): Short Term Prediction of Agricultural Structural Change using Farm Accountancy Data Network and Farm Structure Survey Data. German Journal of Agricultural Economics 64 Nr. 3, 163–174.

Literaturverzeichnis

- STORM, HUGO; HECKELEI, THOMAS (2018): Reducing omitted-variable bias in spatial-interaction models by considering multiple neighbourhoods. *Spatial Economic Analysis* 13 Nr. 4, 457–472.
- STORM, HUGO; MITTENZWEL, KLAUS; HECKELEI, THOMAS (2014): Direct Payments, Spatial Competition, and Farm Survival in Norway. *American Journal of Agricultural Economics* 97 Nr. 4, 1192–1205.
- STREIFENEDER, THOMAS (2009): Die Agrarstrukturen in den Alpen und ihre Entwicklung unter Berücksichtigung ihrer Bestimmungsgründe. München: Dissertation. Ludwig-Maximilians-Universität München.
- UMWELTBUNDESAMT (2013): Zehnter Umweltkontrollbericht - Umweltsituation in Österreich. Wien: Selbstverlag.
- VEGA, SOLMARIA HALLECK; ELHORST, J. PAUL (2015): THE SLX MODEL. *Journal of Regional Science* 55 Nr. 3, 339–363.
- VOGEL, STEFAN; HOFREITHER, MARKUS F.; SCHNEEBERGER, WALTER; WEIß, FRANZ (2004): Bestimmungsgründe von Flächenausweitungsplänen in der Berglandwirtschaft Österreichs. *Die Bodenkultur* 55 Nr. 2, 73–81.
- WAGNER (2015): Regionale Strukturveränderungen in Österreichs Landwirtschaft seit dem EU-Beitritt 2015. In: EGARTNER, SIGRID; RESL, THOMAS (Hrsg.): Einblicke in Österreichs Landwirtschaft seit dem EU-Beitritt. Wien: AWI - Bundesanstalt für Agrarwirtschaft, 67–96.
- WEI, TAIYUN; SIMKO, VILIAM (2017): Visualisation of a Correlation Matrix. Unter: <https://cran.r-project.org/package=corrplot> (12.11.2020).
- WEISS, CHRISTOPH R. (1999): Farm Growth and Survival: Econometric Evidence for Individual Farms in Upper Austria. *American Journal of Agricultural Economics* 81, 103–116.
- WICKHAM, HADLEY; CHANG, WINSTON; HENRY, LIONEL; PEDERSEN, THOMAS LIN; TAKAHASHI, KOSHIKE; WILKE, CLAU; WOO, KARA; YUTANI, HIROAKI; DUNNINGTON, DEWEY (2020): ggplot2: Create Elegant Data Visualisations Using the Grammar of Graphics. Unter: <https://cran.r-project.org/package=ggplot2> (12.11.2020).
- WIESINGER, GEORG (2005): Landwirtschaft zwischen Tradition und Moderne - Über den Struktur und Wertewandel in der bäuerlichen Lebenswelt. *Jahrbuch der Österreichischen Gesellschaft für Agrarökonomie* 10, 165–180.
- WOOLDRIDGE, JEFFREY M. (2010): *Econometric analysis of cross section and panel data*. Cambridge, London: MIT Press.
- WOOLDRIDGE, JEFFREY M. (2012): *Introductory Econometrics*. Mason: South-Western.
- WOOLDRIDGE, JEFFREY M. (2020): *Introductory Econometrics*. Boston: Cengage.
- ZIMMERMANN, ANDREA; HECKELEI, THOMAS (2012): Structural Change of European Dairy Farms - A Cross-Regional Analysis. *Journal of Agricultural Economics* 63 Nr. 3, 576–603.
- ZIMMERMANN, ANDREA; HECKELEI, THOMAS; DOMÍNGUEZ, IGNACIO PÉREZ (2009): Modelling farm structural change for integrated ex-ante assessment: review of methods and determinants. *Environmental Science & Policy* 12 Nr. 5, 601–618.

Anhang

A. Kartographische Darstellungen

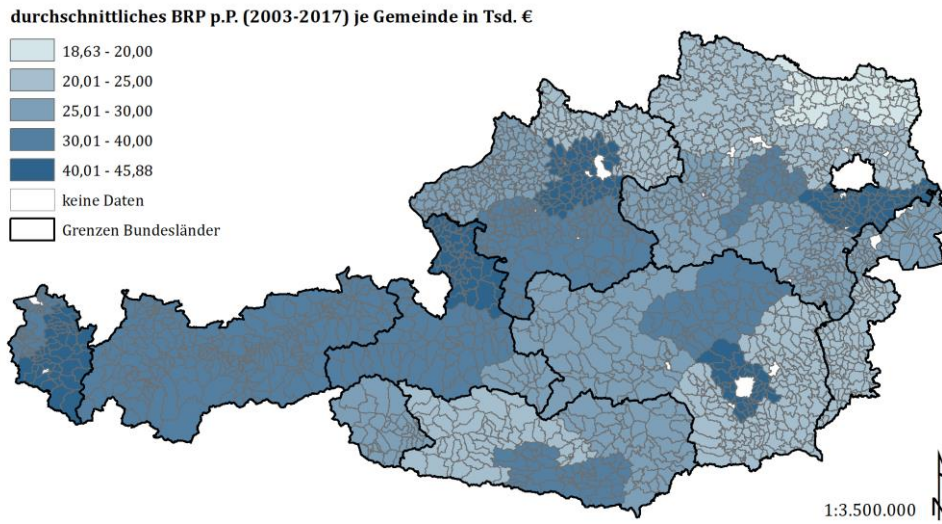


Abbildung 11: Durchschnittliches BIP p.P. (2003-2017) je Gemeinde in Tsd. €. Quelle: eigene Darstellung. Datengrundlage: BEV 2019, Statistik Austria 2019.

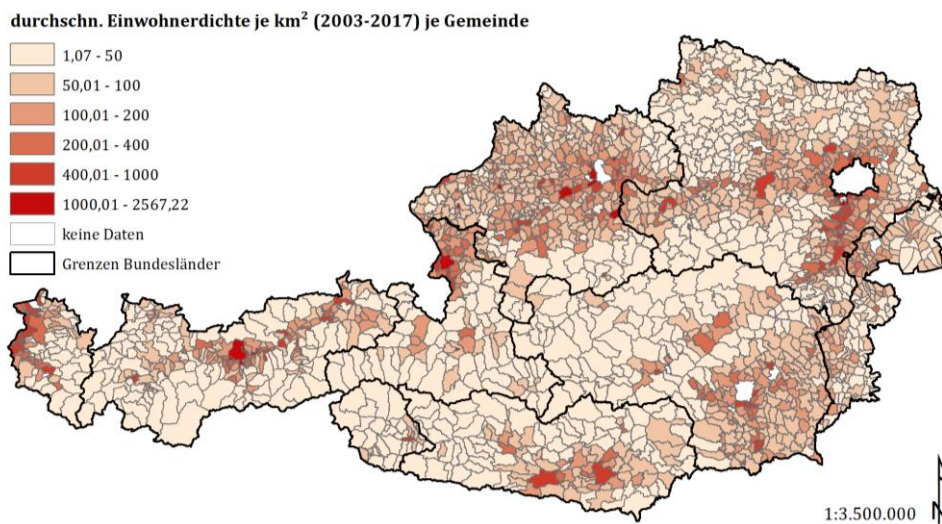


Abbildung 12: Durchschnittliche EinwohnerInnen-dichte je km² (2003-2017) je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: BEV 2019, BAB 2020.

Anhang

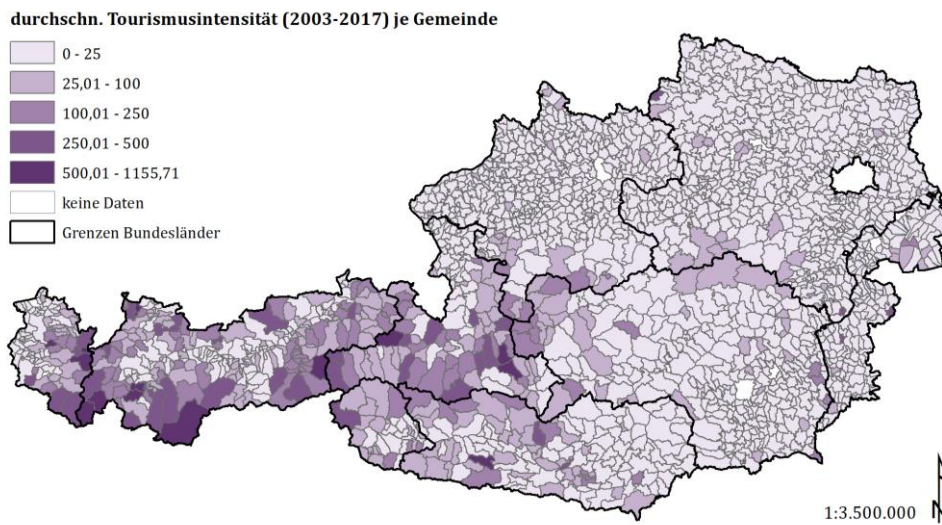


Abbildung 13: Durchschnittliche Tourismusintensität (2003-2017) je Gemeinde. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

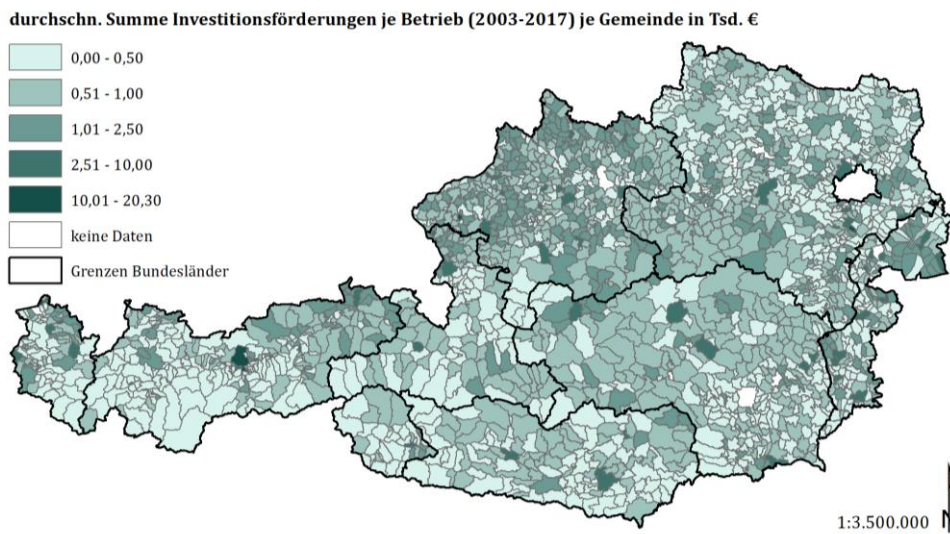


Abbildung 14: Durchschnittliche Summe Investitionsförderungen je Betrieb (2003-2017) je Gemeinde in Tsd. €. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

Anhang

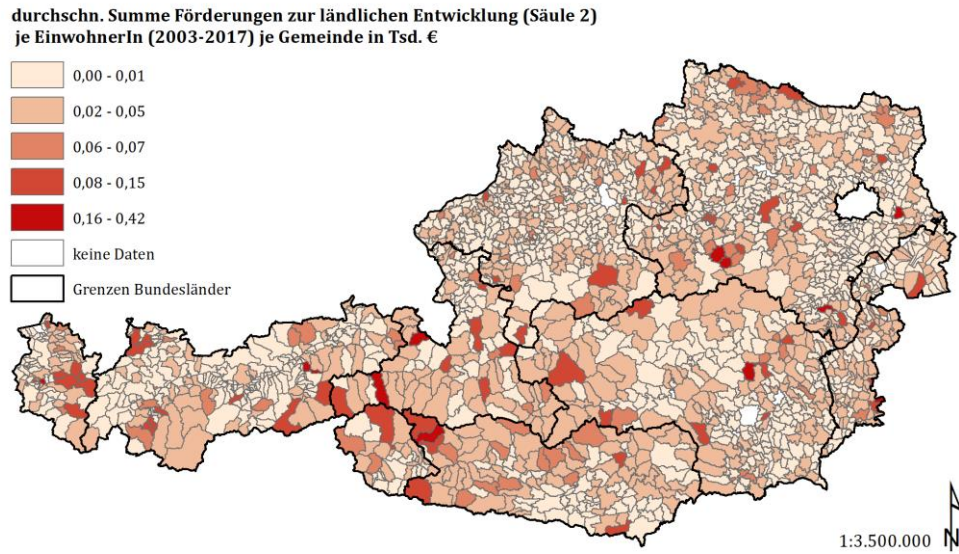


Abbildung 16: Durchschnittliche Summe der Förderungen zur ländlichen Entwicklung (Säule 2) je EinwohnerIn (2003-2017) je Gemeinde in Tsd. €. Quelle: eigene Darstellung. Datengrundlage: BAB 2020, BEV 2019.

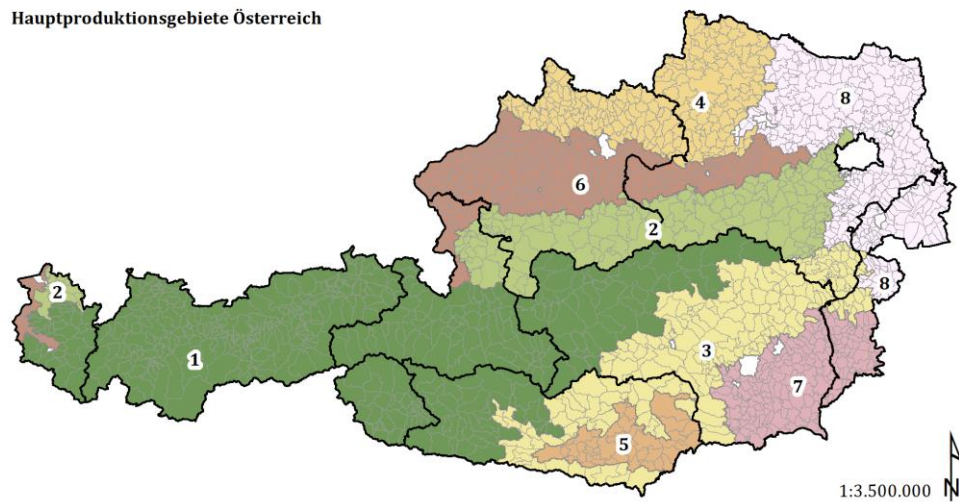


Abbildung 15: Hauptproduktionsgebiete in Österreich. Quelle: eigene Darstellung. Datengrundlage: BEV 2019, STATISTIK AUSTRIA 2020.

B. Weitere Ergebnistabellen

| Dependent variable: Anzahl Betriebe | | | | | | | | | | | | | | | |
|-------------------------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| | 2003 | 2004 | 2005 | 2006 | 2007 | 2008 | 2009 | 2010 | 2011 | 2012 | 2013 | 2014 | 2015 | 2016 | 2017 |
| % Biobetriebe | -0.312*** (0.039) | -0.349*** (0.039) | -0.355*** (0.037) | -0.370*** (0.037) | -0.345*** (0.037) | -0.330*** (0.037) | -0.314*** (0.038) | -0.263*** (0.039) | -0.290*** (0.039) | -0.278*** (0.040) | -0.272*** (0.042) | -0.263*** (0.042) | -0.179*** (0.040) | -0.149*** (0.041) | -0.139*** (0.042) |
| % Ackerfläche | -0.312*** (0.039) | -0.349*** (0.039) | -0.355*** (0.037) | -0.370*** (0.037) | -0.345*** (0.037) | -0.330*** (0.037) | -0.314*** (0.038) | -0.263*** (0.039) | -0.290*** (0.039) | -0.278*** (0.040) | -0.272*** (0.042) | -0.263*** (0.042) | -0.179*** (0.040) | -0.149*** (0.041) | -0.139*** (0.042) |
| GVE/ha | 0.599*** (0.101) | 0.575*** (0.101) | 0.434*** (0.102) | 0.415*** (0.099) | 0.388*** (0.093) | 0.342*** (0.090) | 0.372*** (0.096) | 0.420*** (0.099) | 0.307*** (0.099) | 0.296*** (0.100) | 0.278*** (0.099) | 0.194*** (0.097) | 0.243*** (0.092) | 0.304*** (0.090) | 0.273*** (0.088) |
| LF | 0.512*** (0.032) | 0.582*** (0.035) | 0.600*** (0.035) | 0.677*** (0.035) | 0.685*** (0.033) | 0.710*** (0.033) | 0.654*** (0.032) | 0.600*** (0.033) | 0.598*** (0.032) | 0.550*** (0.032) | 0.545*** (0.032) | 0.627*** (0.033) | 0.550*** (0.031) | 0.535*** (0.031) | 0.506*** (0.031) |
| BRP pro Kopf | -0.020 (0.022) | -0.033 (0.020) | -0.046* (0.018) | -0.048* (0.019) | -0.050* (0.024) | -0.112*** (0.015) | -0.111*** (0.015) | -0.074*** (0.016) | -0.110*** (0.017) | -0.044* (0.018) | -0.028 (0.018) | -0.047* (0.020) | -0.076*** (0.017) | -0.052** (0.016) | -0.014 (0.015) |
| (EW je km ²)/100 | -0.020 (0.022) | -0.033 (0.020) | -0.046* (0.018) | -0.048* (0.019) | -0.050* (0.024) | -0.112*** (0.015) | -0.111*** (0.015) | -0.074*** (0.016) | -0.110*** (0.017) | -0.044* (0.018) | -0.028 (0.018) | -0.047* (0.020) | -0.076*** (0.017) | -0.052** (0.016) | -0.014 (0.015) |
| (ÜN je EW)/10 | -0.162 (0.170) | -0.921*** (0.163) | -1.085*** (0.178) | -1.531*** (0.167) | -1.473*** (0.164) | -1.522*** (0.163) | -1.217*** (0.165) | -0.984*** (0.153) | -1.053*** (0.155) | -0.718*** (0.148) | -0.661*** (0.149) | -1.221*** (0.158) | -0.377* (0.160) | -0.271 (0.166) | -0.164 (0.180) |
| Säule 1 je ha | 0.599*** (0.101) | 0.575*** (0.101) | 0.434*** (0.102) | 0.415*** (0.099) | 0.388*** (0.093) | 0.342*** (0.090) | 0.372*** (0.096) | 0.420*** (0.099) | 0.307*** (0.099) | 0.296*** (0.100) | 0.278*** (0.099) | 0.194*** (0.097) | 0.243*** (0.092) | 0.304*** (0.090) | 0.273*** (0.088) |
| ÖPUL-AZ je ha | 0.789*** (0.011) | 0.795*** (0.010) | 0.795*** (0.010) | 0.800*** (0.010) | 0.798*** (0.010) | 0.815*** (0.010) | 0.811*** (0.010) | 0.805*** (0.010) | 0.810*** (0.010) | 0.795*** (0.010) | 0.791*** (0.010) | 0.796*** (0.010) | 0.794*** (0.010) | 0.797*** (0.010) | 0.790*** (0.010) |
| Investitionsförderungen je Betrieb | 0.789*** (0.011) | 0.795*** (0.010) | 0.795*** (0.010) | 0.800*** (0.010) | 0.798*** (0.010) | 0.815*** (0.010) | 0.811*** (0.010) | 0.805*** (0.010) | 0.810*** (0.010) | 0.795*** (0.010) | 0.791*** (0.010) | 0.796*** (0.010) | 0.794*** (0.010) | 0.797*** (0.010) | 0.790*** (0.010) |
| LE Säule 2 je EW | 0.025* (0.013) | 0.021- (0.013) | 0.019 (0.013) | 0.014 (0.012) | 0.019 (0.012) | 0.020 (0.012) | 0.024* (0.012) | 0.018 (0.012) | 0.021- (0.012) | 0.024* (0.012) | 0.024- (0.012) | 0.016 (0.012) | 0.024* (0.012) | 0.024* (0.012) | 0.024* (0.012) |
| In_oepeul_az_ha | 0.599*** (0.101) | 0.575*** (0.101) | 0.434*** (0.102) | 0.415*** (0.099) | 0.388*** (0.093) | 0.342*** (0.090) | 0.372*** (0.096) | 0.420*** (0.099) | 0.307*** (0.099) | 0.296*** (0.100) | 0.278*** (0.099) | 0.194*** (0.097) | 0.243*** (0.092) | 0.304*** (0.090) | 0.273*** (0.088) |
| In_invest_betrieb | -0.020 (0.022) | -0.033 (0.020) | -0.046* (0.018) | -0.048* (0.019) | -0.050* (0.024) | -0.112*** (0.015) | -0.111*** (0.015) | -0.074*** (0.016) | -0.110*** (0.017) | -0.044* (0.018) | -0.028 (0.018) | -0.047* (0.020) | -0.076*** (0.017) | -0.052** (0.016) | -0.014 (0.015) |
| Observations | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 |
| R ² | 0.802 | 0.805 | 0.806 | 0.814 | 0.820 | 0.825 | 0.821 | 0.816 | 0.818 | 0.813 | 0.814 | 0.820 | 0.827 | 0.826 | 0.825 |
| Adjusted R ² | 0.801 | 0.804 | 0.805 | 0.813 | 0.819 | 0.824 | 0.820 | 0.815 | 0.817 | 0.812 | 0.813 | 0.819 | 0.826 | 0.825 | 0.824 |
| Residual Std. Error (df = 2053) | 0.370 | 0.368 | 0.366 | 0.359 | 0.354 | 0.349 | 0.352 | 0.358 | 0.355 | 0.360 | 0.360 | 0.356 | 0.350 | 0.351 | 0.353 |
| F Statistic (df = 12; 2053) | 694.670 | 706.113 | 712.516 | 748.934 | 777.377 | 808.645 | 785.504 | 758.950 | 769.153 | 742.249 | 747.466 | 778.020 | 819.135 | 812.370 | 804.615 |

Note: * p<0.1; ** p<0.05; *** p<0.01; **** p<0.001

Tabelle 10: Ergebnisse der OLS-Regressionen aller Jahre des Beobachtungszeitraums 2003-2017), abhängige Variable: Anzahl Betriebe. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| <i>Dependent variable:</i> | | | | | | | | | | | | | | | |
|------------------------------------|---------------------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| | durchschnittliche Betriebsgröße | | | | | | | | | | | | | | |
| | 2003 | 2004 | 2005 | 2006 | 2007 | 2008 | 2009 | 2010 | 2011 | 2012 | 2013 | 2014 | 2015 | 2016 | 2017 |
| % Biobetriebe | 0.260*** (0.040) | 0.305*** (0.039) | 0.308*** (0.038) | 0.332*** (0.037) | 0.313*** (0.038) | 0.304*** (0.038) | 0.287*** (0.039) | 0.242*** (0.040) | 0.266*** (0.040) | 0.250*** (0.042) | 0.243*** (0.043) | 0.230*** (0.043) | 0.133** (0.042) | 0.095* (0.043) | 0.090* (0.044) |
| % Ackerfläche | 0.260*** (0.040) | 0.305*** (0.039) | 0.308*** (0.038) | 0.332*** (0.037) | 0.313*** (0.038) | 0.304*** (0.038) | 0.287*** (0.039) | 0.242*** (0.040) | 0.266*** (0.040) | 0.250*** (0.042) | 0.243*** (0.043) | 0.230*** (0.043) | 0.133** (0.042) | 0.095* (0.043) | 0.090* (0.044) |
| GVE/ha | 0.060** (0.023) | 0.066** (0.020) | 0.063*** (0.019) | 0.093*** (0.019) | 0.075** (0.024) | 0.146*** (0.015) | 0.156*** (0.015) | 0.116*** (0.016) | 0.161*** (0.017) | 0.084*** (0.018) | 0.066*** (0.019) | 0.087*** (0.021) | 0.106*** (0.017) | 0.110*** (0.017) | 0.069*** (0.016) |
| BRP pro Kopf | -0.042** (0.013) | -0.037** (0.013) | -0.032* (0.013) | -0.025* (0.013) | -0.031* (0.013) | -0.031* (0.012) | -0.034** (0.012) | -0.027* (0.012) | -0.031* (0.012) | -0.034** (0.013) | -0.036** (0.013) | -0.024 (0.012) | -0.035** (0.012) | -0.032** (0.012) | -0.038** (0.012) |
| (EW je km ²)/100 | 0.140 (0.280) | 0.142 (0.216) | 0.059 (0.176) | 0.017 (0.172) | 0.138 (0.236) | 0.275 (0.226) | 0.151 (0.208) | 0.174 (0.159) | 0.174 (0.152) | 0.282 (0.171) | 0.218 (0.209) | 0.164 (0.164) | 0.109 (0.112) | 0.286 (0.283) | 0.166 (0.163) |
| (ÜN je EW)/10 | 0.140 (0.280) | 0.142 (0.216) | 0.059 (0.176) | 0.017 (0.172) | 0.138 (0.236) | 0.275 (0.226) | 0.151 (0.208) | 0.174 (0.159) | 0.174 (0.152) | 0.282 (0.171) | 0.218 (0.209) | 0.164 (0.164) | 0.109 (0.112) | 0.286 (0.283) | 0.166 (0.163) |
| Säule 1 je ha | -0.569*** (0.103) | -0.544*** (0.103) | -0.393*** (0.104) | -0.388*** (0.102) | -0.374*** (0.096) | -0.337*** (0.092) | -0.350*** (0.098) | -0.401*** (0.101) | -0.265** (0.101) | -0.270** (0.103) | -0.250* (0.103) | -0.159 (0.100) | -0.163 (0.096) | -0.216* (0.094) | -0.195* (0.092) |
| ÖPUL+AZ je ha | 0.060** (0.023) | 0.066** (0.020) | 0.063*** (0.019) | 0.093*** (0.019) | 0.075** (0.024) | 0.146*** (0.015) | 0.156*** (0.015) | 0.116*** (0.016) | 0.161*** (0.017) | 0.084*** (0.018) | 0.066*** (0.019) | 0.087*** (0.021) | 0.106*** (0.017) | 0.110*** (0.017) | 0.069*** (0.016) |
| Investitionsförderungen je Betrieb | -0.432*** (0.033) | -0.512*** (0.035) | -0.533*** (0.036) | -0.623*** (0.035) | -0.624*** (0.034) | -0.666*** (0.033) | -0.608*** (0.033) | -0.548*** (0.033) | -0.552*** (0.033) | -0.492*** (0.033) | -0.479*** (0.033) | -0.575*** (0.035) | -0.482*** (0.032) | -0.473*** (0.033) | -0.428*** (0.032) |
| LE Säule 2 je EW | -0.432*** (0.033) | -0.512*** (0.035) | -0.533*** (0.036) | -0.623*** (0.035) | -0.624*** (0.034) | -0.666*** (0.033) | -0.608*** (0.033) | -0.548*** (0.033) | -0.552*** (0.033) | -0.492*** (0.033) | -0.479*** (0.033) | -0.575*** (0.035) | -0.482*** (0.032) | -0.473*** (0.033) | -0.428*** (0.032) |
| ln_pile1_ha | 0.380* (0.173) | 1.135*** (0.166) | 1.317*** (0.181) | 1.801*** (0.169) | 1.770*** (0.167) | 1.781*** (0.165) | 1.498*** (0.166) | 1.270*** (0.155) | 1.340*** (0.157) | 1.027*** (0.151) | 0.946*** (0.153) | 1.568*** (0.162) | 0.659*** (0.167) | 0.498** (0.173) | 0.324 (0.189) |
| ln_invest_betrieb | 0.060** (0.023) | 0.066** (0.020) | 0.063*** (0.019) | 0.093*** (0.019) | 0.075** (0.024) | 0.146*** (0.015) | 0.156*** (0.015) | 0.116*** (0.016) | 0.161*** (0.017) | 0.084*** (0.018) | 0.066*** (0.019) | 0.087*** (0.021) | 0.106*** (0.017) | 0.110*** (0.017) | 0.069*** (0.016) |
| Observations | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 | 2,066 |
| R ² | 0.487 | 0.504 | 0.511 | 0.545 | 0.566 | 0.593 | 0.593 | 0.585 | 0.606 | 0.592 | 0.592 | 0.608 | 0.625 | 0.650 | 0.631 |
| Adjusted R ² | 0.484 | 0.501 | 0.509 | 0.543 | 0.563 | 0.591 | 0.591 | 0.582 | 0.604 | 0.590 | 0.590 | 0.606 | 0.623 | 0.628 | 0.629 |
| Residual Std. Error (df = 2054) | 0.378 | 0.375 | 0.374 | 0.367 | 0.364 | 0.356 | 0.359 | 0.367 | 0.363 | 0.372 | 0.374 | 0.370 | 0.367 | 0.367 | 0.371 |
| F Statistic (df = 11, 2054) | 177.201*** | 189.447*** | 195.396*** | 223.796*** | 243.168*** | 272.131*** | 271.749*** | 262.903*** | 287.330*** | 271.473*** | 271.125*** | 289.565*** | 310.892*** | 317.428*** | 319.870*** |

Note:

. p<0.1; * p<0.05; ** p<0.01; *** p<0.001

Tabelle 11: Ergebnisse der OLS—Regressionen aller Jahre des Beobachtungszeitraums 2003-2017), abhängige Variable: durchschnittliche Betriebsgröße. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| Abhängige Variable: Anzahl Betriebe | | | | | | | | | | | | | |
|---|--------------------------|--------------------------|--------------------------|--------------------------|-------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|
| | (1) | (2) | (3) | (4) | (5) | (6) | (7) | (8) | (9) | (10) | (11) | (12) | (13) |
| % Bioetriebe | -0.006*** (0.0002) | -0.004*** (0.0002) | -0.004*** (0.0003) | -0.007*** (0.0003) | 0.003 (0.0003) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.003*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) |
| % Ackerfläche | -0.005*** (0.0001) | -0.004*** (0.0001) | -0.005*** (0.0001) | -0.009*** (0.0001) | 0.001*** (0.0002) | -0.005*** (0.0001) | -0.004*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) | -0.006*** (0.0001) | -0.006*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) |
| ln(GY/ha) | 0.387*** (0.008) | 0.634*** (0.008) | 0.765*** (0.008) | 0.921*** (0.016) | 0.921*** (0.016) | 0.594*** (0.008) | 0.565*** (0.008) | 0.593*** (0.008) | 0.384*** (0.008) | 0.523*** (0.008) | 0.552*** (0.008) | 0.584*** (0.008) | 0.387*** (0.008) |
| ln(LF) | 0.796*** (0.003) | 0.784*** (0.003) | 0.774*** (0.003) | 0.821*** (0.003) | 0.796*** (0.003) | 0.796*** (0.003) | 0.803*** (0.003) | 0.786*** (0.003) | 0.795*** (0.003) | 0.790*** (0.003) | 0.797*** (0.003) | 0.791*** (0.003) | 0.796*** (0.003) |
| (Seefläche u. NNY)/100 | 0.002* (0.001) | 0.003*** (0.001) | -0.003*** (0.001) | 0.027*** (0.001) | -0.031*** (0.002) | -0.001 (0.001) | -0.001 (0.001) | -0.00002 (0.001) | 0.003*** (0.001) | 0.008*** (0.001) | 0.010*** (0.001) | 0.002* (0.001) | 0.002* (0.001) |
| BRP pro Kmpf | -0.306*** (0.009) | -0.341*** (0.009) | -0.253*** (0.009) | -0.261*** (0.009) | -0.499*** (0.017) | -0.305*** (0.009) | -0.286*** (0.008) | -0.286*** (0.008) | -0.298*** (0.009) | -0.310*** (0.009) | -0.322*** (0.009) | -0.308*** (0.009) | -0.306*** (0.009) |
| ln(EV ₁ je km ² /100) | 0.050*** (0.005) | 0.038*** (0.006) | 0.039*** (0.006) | 0.082*** (0.006) | -0.654*** (0.010) | 0.047*** (0.005) | -0.001 (0.005) | 0.020*** (0.003) | 0.047*** (0.005) | 0.032*** (0.005) | 0.053*** (0.005) | 0.047*** (0.005) | 0.050*** (0.005) |
| ln(CN ₁ je EV)/10 | 0.022*** (0.003) | 0.024*** (0.003) | 0.025*** (0.003) | 0.019*** (0.003) | -0.032*** (0.006) | 0.024*** (0.003) | 0.007* (0.003) | 0.020*** (0.003) | 0.024*** (0.003) | 0.031*** (0.003) | 0.030*** (0.003) | 0.022*** (0.003) | 0.022*** (0.003) |
| ln(Säule 1 je ha) | -0.798*** (0.039) | -0.812*** (0.040) | -1.295*** (0.039) | 0.261*** (0.039) | 0.542*** (0.078) | -0.823*** (0.037) | -0.826*** (0.040) | -0.741*** (0.039) | -0.854*** (0.039) | -0.826*** (0.039) | -0.780*** (0.039) | -0.834*** (0.039) | -0.798*** (0.039) |
| ln(OPUL-AZ je ha) | 0.415*** (0.024) | 0.263*** (0.024) | 0.936*** (0.022) | 0.010 (0.025) | 0.518*** (0.048) | 0.440*** (0.020) | 0.303*** (0.024) | 0.423*** (0.024) | 0.438*** (0.024) | 0.403*** (0.024) | 0.421*** (0.024) | 0.421*** (0.024) | 0.415*** (0.024) |
| ln(Investitionsförderungen je Betrieb) | -0.055*** (0.004) | -0.062*** (0.004) | -0.039*** (0.004) | -0.045*** (0.005) | 0.151*** (0.009) | -0.055*** (0.004) | -0.057*** (0.004) | -0.033*** (0.004) | -0.054*** (0.004) | -0.061*** (0.004) | -0.056*** (0.004) | -0.054*** (0.004) | -0.055*** (0.004) |
| ln(LE Säule 2 je EV) | -0.048 (0.045) | -0.090 (0.046) | -0.011 (0.046) | -0.094 (0.048) | 0.450*** (0.089) | -0.047 (0.045) | -0.018 (0.046) | -0.073 (0.045) | -0.040 (0.045) | -0.063 (0.045) | -0.037 (0.045) | -0.060 (0.045) | -0.060 (0.045) |
| Constant | -0.466*** (0.037) | -0.381*** (0.038) | -0.903*** (0.037) | -0.492*** (0.040) | 5.134*** (0.064) | -0.462*** (0.037) | -1.521*** (0.023) | -0.446*** (0.037) | -0.478*** (0.037) | -0.535*** (0.037) | -0.286*** (0.036) | -0.440*** (0.037) | -0.466*** (0.037) |
| Observations | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 |
| R ² | 0.816 | 0.808 | 0.803 | 0.786 | 0.266 | 0.816 | 0.808 | 0.815 | 0.816 | 0.814 | 0.814 | 0.815 | 0.816 |
| Adjusted R ² | 0.816 | 0.808 | 0.803 | 0.786 | 0.266 | 0.816 | 0.808 | 0.815 | 0.816 | 0.813 | 0.814 | 0.815 | 0.816 |
| F Statistic | 11,445,610*** (30977) | 11,837,680*** (30978) | 11,513,350*** (30978) | 10,352,160*** (30978) | 1,020,113*** (30978) | 12,484,610*** (30978) | 11,886,430*** (30978) | 12,445,590*** (30978) | 12,461,670*** (30978) | 12,284,170*** (30978) | 12,337,980*** (30978) | 12,409,160*** (30978) | 12,485,950*** (30978) |

Note: * p<0.1; ** p<0.05; *** p<0.01.

Tabelle 12: Gepoolte OLS-Regressionen, abhängige Variable: Anzahl Betriebe. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| | Dependent variable: | | | | | | | | | | | |
|--|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|
| | (1) | (2) | (3) | (4) | (5) | (6) | (7) | (8) | (9) | (10) | (11) | (12) |
| % Biobetriebe | 0.007*** (0.0002) | 0.005*** (0.0002) | 0.005*** (0.0002) | 0.008*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.006*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) |
| % Ackerfläche | 0.006*** (0.0001) | 0.005*** (0.0001) | 0.006*** (0.0001) | 0.009*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.007*** (0.0001) | 0.007*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) |
| ln(GVE/ha) | -0.519*** (0.008) | -0.569*** (0.009) | -0.737*** (0.008) | -0.549*** (0.008) | -0.503*** (0.009) | -0.528*** (0.009) | -0.513*** (0.008) | -0.452*** (0.008) | -0.432*** (0.008) | -0.468*** (0.008) | -0.509*** (0.009) | -0.519*** (0.008) |
| (Seehöhe u. NN)/100 | -0.008*** (0.001) | -0.010*** (0.001) | -0.003** (0.001) | -0.030*** (0.001) | -0.006*** (0.001) | -0.002* (0.001) | -0.010*** (0.001) | -0.016*** (0.001) | -0.015*** (0.001) | -0.008*** (0.001) | -0.008*** (0.001) | -0.008*** (0.001) |
| BRP pro Kopf | 0.256*** (0.009) | 0.294*** (0.009) | 0.180*** (0.009) | 0.221*** (0.009) | 0.249*** (0.009) | 0.155*** (0.009) | 0.155*** (0.009) | 0.245*** (0.009) | 0.259*** (0.009) | 0.270*** (0.009) | 0.257*** (0.009) | 0.255*** (0.009) |
| ln(EW je km ² /100) | -0.180*** (0.005) | -0.203*** (0.005) | -0.190*** (0.005) | -0.189*** (0.005) | -0.171*** (0.005) | -0.132*** (0.005) | -0.132*** (0.005) | -0.177*** (0.005) | -0.164*** (0.005) | -0.182*** (0.005) | -0.182*** (0.005) | -0.181*** (0.005) |
| ln(CUN je EW)/10 | -0.034*** (0.003) | -0.037*** (0.003) | -0.040*** (0.003) | -0.021*** (0.003) | -0.041*** (0.003) | -0.021*** (0.003) | -0.029*** (0.003) | -0.045*** (0.003) | -0.045*** (0.003) | -0.041*** (0.003) | -0.033*** (0.003) | -0.034*** (0.003) |
| ln(Säule 1 je ha) | 1.019*** (0.040) | 1.062*** (0.041) | 1.709*** (0.040) | 0.029 (0.039) | 1.145*** (0.038) | 1.035*** (0.041) | 0.845*** (0.041) | 1.077*** (0.040) | 0.845*** (0.040) | 1.005*** (0.040) | 1.097*** (0.040) | 1.022*** (0.040) |
| ln(OPUL+AZ je ha) | -0.367*** (0.025) | -0.181*** (0.025) | -1.038*** (0.023) | -0.005 (0.025) | -0.482*** (0.021) | -0.441*** (0.025) | -0.395*** (0.025) | -0.401*** (0.024) | -0.350*** (0.025) | -0.375*** (0.025) | -0.375*** (0.025) | -0.366*** (0.025) |
| ln(Investitionsförderungen je Betrieb) | 0.092*** (0.004) | 0.104*** (0.005) | 0.079*** (0.005) | 0.077*** (0.005) | 0.093*** (0.004) | 0.093*** (0.005) | 0.095*** (0.005) | 0.092*** (0.004) | 0.103*** (0.004) | 0.093*** (0.004) | 0.092*** (0.004) | 0.092*** (0.004) |
| ln(LE Säule 2 je EW) | 0.154*** (0.046) | 0.213*** (0.048) | 0.123* (0.049) | 0.181*** (0.049) | 0.149** (0.046) | 0.125** (0.047) | 0.290*** (0.047) | 0.143** (0.046) | 0.177*** (0.047) | 0.144** (0.046) | 0.179*** (0.046) | 0.179*** (0.046) |
| Constant | 2.011*** (0.033) | 2.014*** (0.034) | 2.778*** (0.032) | 1.879*** (0.035) | 2.012*** (0.033) | 2.857*** (0.016) | 2.234*** (0.033) | 2.041*** (0.033) | 2.178*** (0.033) | 1.849*** (0.031) | 2.029*** (0.033) | 2.015*** (0.033) |
| Observations | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 |
| R ² | 0.579 | 0.554 | 0.536 | 0.528 | 0.578 | 0.568 | 0.563 | 0.578 | 0.571 | 0.576 | 0.573 | 0.579 |
| Adjusted R ² | 0.579 | 0.554 | 0.536 | 0.528 | 0.578 | 0.568 | 0.562 | 0.578 | 0.570 | 0.576 | 0.573 | 0.579 |
| F Statistic | 3.878.080*** (11; 30978) | 3.853.002*** (10; 30979) | 3.575.839*** (10; 30979) | 3.469.911*** (10; 30979) | 4.247.851*** (10; 30979) | 4.072.935*** (10; 30979) | 3.983.795*** (10; 30979) | 4.239.778*** (10; 30979) | 4.115.781*** (10; 30979) | 4.213.362*** (10; 30979) | 4.165.385*** (10; 30979) | 4.263.397*** (10; 30979) |

Note: *p<0.1; **p<0.05; ***p<0.001

Tabelle 13: Gepoolte OLS-Regressionen, abhängige Variable: durchschnittliche Betriebsgröße. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| | <i>Dependent variable:</i> | | | | | | | | | |
|--|----------------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|
| | Anzahl Betriebe | | | | | | | | | |
| | (1) | (2) | (3) | (4) | (5) | (6) | (7) | (8) | (9) | (10) |
| % Biobetriebe | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.002*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) | -0.006*** (0.0002) |
| % Ackerfläche | -0.005*** (0.0001) | -0.006*** (0.0001) | -0.003*** (0.0002) | -0.005*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) | -0.005*** (0.0001) |
| ln(GVE/ha) | 0.587*** (0.008) | | 0.859*** (0.012) | 0.582*** (0.008) | 0.593*** (0.008) | 0.581*** (0.008) | 0.579*** (0.008) | 0.579*** (0.008) | 0.583*** (0.008) | 0.587*** (0.008) |
| GVE/ha | | 0.264*** (0.004) | | | | | | | | |
| ln(LF) | 0.796*** (0.003) | 0.801*** (0.003) | | 0.798*** (0.003) | 0.791*** (0.003) | 0.794*** (0.003) | 0.795*** (0.003) | 0.797*** (0.003) | 0.793*** (0.003) | 0.796*** (0.003) |
| LF | | | 0.001*** (0.00000) | | | | | | | |
| (Seehöhe ü. NN)/100 | 0.002* (0.001) | 0.006*** (0.001) | -0.014*** (0.001) | 0.001 (0.001) | 0.0004 (0.001) | 0.004*** (0.001) | 0.003** (0.001) | 0.002 (0.001) | 0.002* (0.001) | 0.002* (0.001) |
| ln(BRP pro Kopf) | -0.306*** (0.009) | -0.310*** (0.009) | -0.347*** (0.012) | | -0.294*** (0.008) | -0.291*** (0.009) | -0.307*** (0.009) | -0.313*** (0.009) | -0.308*** (0.009) | -0.306*** (0.009) |
| BRP pro Kopf | | | | -0.009*** (0.0003) | | | | | | |
| ln(EW je km ²)/100 | 0.050*** (0.005) | 0.049*** (0.006) | -0.303*** (0.007) | 0.047*** (0.005) | | 0.045*** (0.005) | 0.049*** (0.005) | 0.050*** (0.005) | 0.052*** (0.005) | 0.050*** (0.005) |
| (EW je km ²)/100 | | | | | 0.006*** (0.001) | | | | | |
| ln((ÜN je EW)/10) | 0.022*** (0.003) | 0.017*** (0.003) | -0.004 (0.005) | 0.021*** (0.003) | 0.021*** (0.003) | | 0.024*** (0.003) | 0.021*** (0.003) | 0.022*** (0.003) | 0.022*** (0.003) |
| (ÜN je EW)/10 | | | | | | -0.002*** (0.0003) | | | | |
| ln(Säule 1 je ha) | -0.798*** (0.039) | -0.685*** (0.040) | -0.144* (0.056) | -0.806*** (0.039) | -0.773*** (0.039) | -0.871*** (0.039) | | -0.780*** (0.039) | -0.808*** (0.039) | -0.798*** (0.039) |
| Säule 1 je ha | | | | | | | -0.564*** (0.029) | | | |
| ln(ÖPUL+AZ je ha) | 0.415*** (0.024) | 0.294*** (0.024) | 0.411*** (0.034) | 0.438*** (0.024) | 0.421*** (0.024) | 0.451*** (0.024) | 0.415*** (0.024) | | 0.419*** (0.024) | 0.416*** (0.024) |
| ÖPUL+AZ je ha | | | | | | | | 0.253*** (0.014) | | |
| ln(Investitionsförderungen je Betrieb) | -0.055*** (0.004) | -0.055*** (0.004) | 0.037*** (0.006) | -0.056*** (0.004) | -0.054*** (0.004) | -0.054*** (0.004) | -0.055*** (0.004) | -0.055*** (0.004) | | -0.055*** (0.004) |
| Investitionsförderungen je Betrieb | | | | | | | | | -0.011*** (0.001) | |
| ln(LE Säule 2 je EW) | -0.048 (0.045) | -0.046 (0.045) | 0.046 (0.065) | -0.046 (0.045) | -0.066 (0.045) | -0.038 (0.045) | -0.049 (0.045) | -0.052 (0.045) | -0.053 (0.045) | |
| LE Säule 2 je EW | | | | | | | | | | -0.058 (0.034) |
| Constant | -0.466*** (0.037) | -0.335*** (0.038) | 4.164*** (0.047) | -1.254*** (0.024) | -0.453*** (0.037) | -0.490*** (0.037) | -0.491*** (0.037) | -0.405*** (0.036) | -0.451*** (0.037) | -0.466*** (0.037) |
| Observations | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 |
| R ² | 0.816 | 0.811 | 0.615 | 0.815 | 0.816 | 0.816 | 0.816 | 0.816 | 0.816 | 0.816 |
| Adjusted R ² | 0.816 | 0.811 | 0.615 | 0.815 | 0.816 | 0.816 | 0.816 | 0.816 | 0.816 | 0.816 |
| F Statistic (df = 12; 30977) | 11,445.610*** | 11,051.140*** | 4,117.772*** | 11,348.250*** | 11,419.500*** | 11,450.570*** | 11,425.410*** | 11,453.500*** | 11,433.560*** | 11,446.370*** |

Note:

. p<0.1; * p<0.05; ** p<0.01; *** p<0.001

Tabelle 14: Gepoolte OLS-Regressionen, abhängige Variable: Anzahl Betriebe. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| | <i>Dependent variable:</i> | | | | | | | | |
|--|---------------------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| | durchschnittliche Betriebsgröße | | | | | | | | |
| | (1) | (2) | (3) | (4) | (5) | (6) | (7) | (8) | (9) |
| % Biobetriebe | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) | 0.007*** (0.0002) |
| % Ackerfläche | 0.006*** (0.0001) | 0.007*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) | 0.006*** (0.0001) |
| ln(GVE/ha) | -0.519*** (0.008) | | -0.516*** (0.008) | -0.538*** (0.009) | -0.511*** (0.008) | -0.507*** (0.008) | -0.512*** (0.008) | -0.509*** (0.008) | -0.519*** (0.008) |
| GVE/ha | | -0.234*** (0.004) | | | | | | | |
| (Seehöhe ü. NN)/100 | -0.008*** (0.001) | -0.012*** (0.001) | -0.007*** (0.001) | -0.004*** (0.001) | -0.010*** (0.001) | -0.009*** (0.001) | -0.007*** (0.001) | -0.008*** (0.001) | -0.008*** (0.001) |
| ln(BRP pro Kopf) | 0.256*** (0.009) | 0.260*** (0.009) | | 0.214*** (0.009) | 0.239*** (0.009) | 0.256*** (0.009) | 0.261*** (0.009) | 0.257*** (0.009) | 0.256*** (0.009) |
| BRP pro Kopf | | | 0.007*** (0.0003) | | | | | | |
| ln((EW je km ²)/100) | -0.180*** (0.005) | -0.175*** (0.005) | -0.176*** (0.005) | | -0.176*** (0.005) | -0.180*** (0.005) | -0.179*** (0.005) | -0.187*** (0.005) | -0.180*** (0.005) |
| (EW je km ²)/100 | | | | -0.032*** (0.001) | | | | | |
| ln((ÜN je EW)/10) | -0.034*** (0.003) | -0.029*** (0.003) | -0.033*** (0.003) | -0.032*** (0.003) | | -0.037*** (0.003) | -0.033*** (0.003) | -0.034*** (0.003) | -0.034*** (0.003) |
| (ÜN je EW)/10 | | | | | 0.001*** (0.0003) | | | | |
| ln(Säule 1 je ha) | 1.019*** (0.040) | 0.911*** (0.040) | 1.024*** (0.040) | 0.990*** (0.040) | 1.097*** (0.040) | | 1.002*** (0.040) | 1.062*** (0.040) | 1.020*** (0.040) |
| Säule 1 je ha | | | | | | 0.705*** (0.030) | | | |
| ln(ÖPUL+AZ je ha) | -0.367*** (0.025) | -0.259*** (0.025) | -0.386*** (0.025) | -0.384*** (0.025) | -0.408*** (0.024) | -0.366*** (0.025) | | -0.374*** (0.025) | -0.367*** (0.025) |
| ÖPUL+AZ je ha | | | | | | | -0.231*** (0.015) | | |
| ln(Investitionsförderungen je Betrieb) | 0.092*** (0.004) | 0.091*** (0.004) | 0.093*** (0.004) | 0.096*** (0.004) | 0.091*** (0.004) | 0.093*** (0.004) | 0.092*** (0.004) | | 0.092*** (0.004) |
| Investitionsförderungen je Betrieb | | | | | | | | 0.014*** (0.001) | |
| ln(LE Säule 2 je EW) | 0.154*** (0.046) | 0.149*** (0.047) | 0.151*** (0.046) | 0.220*** (0.046) | 0.142*** (0.046) | 0.156*** (0.046) | 0.157*** (0.046) | 0.170*** (0.046) | |
| LE Säule 2 je EW | | | | | | | | | 0.114** (0.035) |
| Constant | 2.011*** (0.033) | 1.867*** (0.033) | 2.660*** (0.017) | 2.068*** (0.033) | 2.051*** (0.033) | 2.056*** (0.033) | 1.956*** (0.032) | 2.029*** (0.033) | 2.012*** (0.033) |
| Observations | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 | 30,990 |
| R ² | 0.579 | 0.570 | 0.578 | 0.573 | 0.578 | 0.578 | 0.580 | 0.576 | 0.579 |
| Adjusted R ² | 0.579 | 0.570 | 0.577 | 0.573 | 0.578 | 0.578 | 0.580 | 0.576 | 0.579 |
| F Statistic (df = 11; 30978) | 3,878.080*** | 3,736.060*** | 3,849.473*** | 3,776.888*** | 3,857.296*** | 3,857.494*** | 3,883.996*** | 3,824.555*** | 3,877.929*** |

Note:

. p<0.1; * p<0.05; ** p<0.01; *** p<0.001

Tabelle 15: Gepoolte OLS-Regressionen, abhängige Variable: durchschnittliche Betriebsgröße. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| | <i>Dependent variable:</i> | |
|--|--|---------------------------------|
| | Anzahl Betriebe | durchschnittliche Betriebsgröße |
| % Biobetriebe | -0.006*** (0.0002) | 0.007*** (0.0002) |
| % Ackerfläche | -0.006*** (0.0001) | 0.007*** (0.0001) |
| GVE/ha | 0.265*** (0.004) | -0.240*** (0.004) |
| ln(LF) | 0.793*** (0.003) | |
| (Seehöhe ü. NN)/100 | 0.007*** (0.001) | -0.010*** (0.001) |
| ln(BRP pro Kopf) | -0.283*** (0.009) | 0.203*** (0.009) |
| (EW je km ²)/100 | 0.004*** (0.001) | -0.030*** (0.001) |
| (ÜN je EW)/10 | -0.002*** (0.0003) | 0.002*** (0.0003) |
| ln(Säule 1 je ha) | -0.727*** (0.040) | 0.955*** (0.041) |
| ln(ÖPUL+AZ je ha) | 0.331*** (0.024) | -0.311*** (0.025) |
| ln(Investitionsförderungen je Betrieb) | -0.054*** (0.004) | 0.094*** (0.005) |
| LE Säule 2 je EW | -0.055 (0.045) | 0.205*** (0.047) |
| Constant | -0.344*** (0.038) | 1.960*** (0.034) |
| Observations | 30,990 | 30,990 |
| R ² | 0.811 | 0.563 |
| Adjusted R ² | 0.811 | 0.563 |
| F Statistic | 11,046.500*** (df = 12; 30977) 3,627.008*** (df = 11; 30978) | |
| <i>Note:</i> | . p<0.1; * p<0.05; ** p<0.01; *** p<0.001 | |

Tabelle 16: Gepoolte OLS Regressionen mit ausgewählter Modellspezifikation. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

Anhang

| | <i>Dependent variable:</i> | |
|--|---|---------------------------------|
| | Anzahl Betriebe | durchschnittliche Betriebsgröße |
| % Biobetriebe | -0.004*** (0.0001) | 0.004*** (0.0001) |
| % Ackerfläche | -0.006*** (0.0002) | 0.007*** (0.0002) |
| GVE/ha | 0.083*** (0.004) | -0.097*** (0.004) |
| ln(LF) | 0.647*** (0.006) | |
| (Seehöhe ü. NN)/100 | 0.007*** (0.002) | -0.014*** (0.002) |
| ln(BRP pro Kopf) | -0.406*** (0.007) | 0.211*** (0.010) |
| (EW je km ²)/100 | 0.009* (0.003) | -0.043*** (0.003) |
| (ÜN je EW)/10 | 0.002*** (0.0004) | -0.002*** (0.0004) |
| ln(Säule 1 je ha) | 0.301*** (0.018) | -0.355*** (0.018) |
| ln(ÖPUL+AZ je ha) | 0.604*** (0.018) | -0.695*** (0.019) |
| ln(Investitionsförderungen je Betrieb) | 0.004*** (0.001) | -0.003* (0.001) |
| LE Säule 2 je EW | 0.024* (0.011) | -0.024* (0.012) |
| Constant | 0.836*** (0.054) | 2.330*** (0.039) |
| Observations | 30,990 | 30,990 |
| R ² | 0.445 | 0.237 |
| Adjusted R ² | 0.445 | 0.237 |
| F Statistic | 24,860.880*** | 9,625.309*** |
| <i>Note:</i> | . p<0.1; * p<0.05; ** p<0.01; *** p<0.001 | |

Tabelle 17: Random-effects-Modelle. Quelle: eigene Darstellung. Datengrundlage: AMA 2018, BAB 2020, BEV 2019, GEOLAND.AT 2020, STATISTIK AUSTRIA 2019.

C. R-Code für das Schätzen der fixed-effects- und SLX-Modelle

Einlesen und Aufbereiten der Datengrundlage

```

data <- read.csv2("data.csv", header=TRUE)
data <- data.frame(data)

attach(data)

data <- transform(data, bio_share100 = bio_share*100)
data <- transform(data, acker_share100 = acker_share*100)

data <- transform(data, levelNN_median_100 = levelNN_median/100)
data <- transform(data, pile1 = pile1/1000)
data <- transform(data, pile1_ha = pile1_ha/1000)
data <- transform(data, oepul_az = oepul_az/1000)
data <- transform(data, oepul_az_ha = oepul_az_ha/1000)
data <- transform(data, invest = invest/1000)
data <- transform(data, invest_betrieb = invest_betrieb/1000)
data <- transform(data, pile2_sub = pile2_sub/1000)
data <- transform(data, pile2_sub_EW = pile2_sub_EW/1000)
data <- transform(data, BRP_pp_NUTS3 = BRP_pp_NUTS3/1000)
data <- transform(data, EW_km = EW_km/100)
data <- transform(data, tour_int = tour_int/10)

data <- transform(data, ln_betriebe = log(1 + betriebe))
data <- transform(data, ln_LF_je_betrieb = log(1 + LF_je_betrieb))
data <- transform(data, ln_BRP_pp_NUTS3 = log(1 + BRP_pp_NUTS3))
data <- transform(data, ln_EW_km = log(1 + EW_km))
data <- transform(data, ln_GVE_ha = log(1 + GVE_ha))
data <- transform(data, ln_tour_int = log(1 + tour_int))
data <- transform(data, ln_pile1 = log(1 + pile1))
data <- transform(data, ln_LF_sitz = log(1 + LF_sitz))
data <- transform(data, ln_pile1_ha = log(1 + pile1_ha))
data <- transform(data, ln_oepul_az = log(1 + oepul_az))
data <- transform(data, ln_invest = log(1 + invest))
data <- transform(data, ln_pile2_sub_EW = log(1 + pile2_sub_EW))
data <- transform(data, ln_oepul_az_ha = log(1 + oepul_az_ha))
data <- transform(data, ln_invest_betrieb = log(1 + invest_betrieb))

detach(data)

paneldata <- pdata.frame(data, index = c("GKZ", "year"))

attach(paneldata)

##### Schätzen der nicht-räumlichen Modelle und Tests #####

pooled_n <- plm(ln_betriebe ~ bio_share100 + acker_share100
  + GVE_ha + ln_LF_sitz + levelNN_median_100
  + ln_BRP_pp_NUTS3 + EW_km
  + tour_int + ln_pile1_ha + ln_oepul_az_ha
  + ln_invest_betrieb + ln_pile2_sub_EW,
  data = paneldata, model = "pooling")

pooled_LF <- plm(ln_LF_je_betrieb ~ bio_share100 + acker_share100
  + GVE_ha + levelNN_median_100 + ln_BRP_pp_NUTS3
  + EW_km + tour_int + ln_pile1_ha + ln_oepul_az_ha
  + ln_invest_betrieb + ln_pile2_sub_EW,
  data = paneldata, model = "pooling")

fixed_n <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
  + levelNN_median_100 + EW_km + ln_LF_sitz + GVE_ha
  + tour_int + ln_pile1_ha + ln_oepul_az_ha
  + ln_invest_betrieb + ln_pile2_sub_EW + acker_share100,
  data = paneldata, model = "within", effect = "twoways")

fixed_LF <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
  + levelNN_median_100 + EW_km + GVE_ha + tour_int
  + ln_pile1_ha + ln_oepul_az_ha + ln_invest_betrieb
  + ln_pile2_sub_EW + acker_share100,
  data = paneldata, model = "within", effect = "twoways")

random_n <- plm(ln_betriebe ~ bio_share100 + acker_share100 + GVE_ha
  + ln_LF_sitz + levelNN_median_100 + ln_BRP_pp_NUTS3
  + EW_km + tour_int + ln_pile1_ha + ln_oepul_az_ha
  + ln_invest_betrieb + ln_pile2_sub_EW,
  data = paneldata, model = "random", effect = "twoways")

random_LF <- plm(ln_LF_je_betrieb ~ bio_share100 + acker_share100
  + GVE_ha + levelNN_median_100 + ln_BRP_pp_NUTS3
  + EW_km + tour_int + ln_pile1_ha + ln_oepul_az_ha
  + ln_invest_betrieb + ln_pile2_sub_EW,
  data = paneldata, model = "random", effect = "twoways")

```


Anhang

```
# Breusch-Pagan Lagrange Multiplier Test #
# zur Entscheidung: gepoolte OLS oder random effects --> random effects #

plmtest(pooled_n, type = "bp")
plmtest(pooled_LF, type = "bp")

# Hausman-Test #
# zur Entscheidung: fixed oder random effects --> fixed effects#

phtest(fixed_n, random_n)
phtest(fixed_LF, random_LF)

# Breusch-Pagan Test #
# prueft auf Heteroskedastie #

bptest(fixed_n)
bptest(fixed_LF)

# Berechnung mit heteroskedastierobusten Standardfehlern (nach HEISS 2020) #

coeftest(fixed_n, vcov = vcovHC)
coeftest(fixed_LF, vcov = vcovHC)

##### Nachbarschaftsmatrizen erstellen (nach BIVAND 2020) #####

# shp-Datei einlesen #
GKZ_shape <- readOGR("GKZ_2020_1.shp")

# Koordinaten und IDs festlegen #
coord <- coordinates(GKZ_shape)
ID <- GKZ_shape$GKZ

# Erstellen einer Nachbarschaftsliste, bei der jede Gemeinde mind. 1 Nachbarn hat #

Gem_1nb <- knn2nb(knearneigh(coord, k = 1), row.names = ID)

# Distanzen zwischen benachbarten Gemeinden auslesen #

dists <- unlist(nbdists(Gem_1nb, coord))
summary(dists)

# abspeichern der groessten Distanz #

max_1nb <- max(dists)
max_1nb

# jetzt koennen die Nachbarschaftsmatrizen festgelegt werden #

Gem_nb_lokal <- dnearneigh(coord, d1 = 0, d2 = max_1nb, row.names = ID)
Gem_nb_reg025 <- dnearneigh(coord, d1 = 0, d2 = 25000, row.names = ID)
Gem_nb_reg035 <- dnearneigh(coord, d1 = 0, d2 = 35000, row.names = ID)
Gem_nb_reg045 <- dnearneigh(coord, d1 = 0, d2 = 45000, row.names = ID)
Gem_nb_reg055 <- dnearneigh(coord, d1 = 0, d2 = 55000, row.names = ID)
Gem_nb_reg065 <- dnearneigh(coord, d1 = 0, d2 = 65000, row.names = ID)
Gem_nb_reg075 <- dnearneigh(coord, d1 = 0, d2 = 75000, row.names = ID)

# Erstellen der raeumlichen Gewichtungsmatrizen (reihenstandardisiert) #

lokal_W <- nb2listw(Gem_nb_lokal, glist = NULL, style = "W", zero.policy = TRUE)
reg025_W <- nb2listw(Gem_nb_reg025, glist = NULL, style = "W", zero.policy = TRUE)
reg035_W <- nb2listw(Gem_nb_reg035, glist = NULL, style = "W", zero.policy = TRUE)
reg045_W <- nb2listw(Gem_nb_reg045, glist = NULL, style = "W", zero.policy = TRUE)
reg055_W <- nb2listw(Gem_nb_reg055, glist = NULL, style = "W", zero.policy = TRUE)
reg065_W <- nb2listw(Gem_nb_reg065, glist = NULL, style = "W", zero.policy = TRUE)
reg075_W <- nb2listw(Gem_nb_reg075, glist = NULL, style = "W", zero.policy = TRUE)

##### Test auf raeumliche Autokorrelation #####

data_aggr <- aggregate(cbind(ln_betriebe, ln_LF_je_betrieb,
                             bio_share100, ln_BRP_pp_NUTS3,
                             levelNN_median_100, EW_km, ln_LF_sitz,
                             GVE_ha, tour_int, ln_pile1_ha,
                             ln_oepul_az_ha, ln_invest_betrieb,
                             ln_pile2_sub_EW, acker_share100) ~ GKZ,
                       data=data, FUN=mean)

model_means_n <- lm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
                   + levelNN_median_100 + EW_km + ln_LF_sitz
                   + GVE_ha + tour_int + ln_pile1_ha
                   + ln_oepul_az_ha + ln_invest_betrieb
                   + ln_pile2_sub_EW + acker_share100, data=data_aggr)

model_means_LF <- lm(ln_LF_je_betrieb ~ bio_share100
                    + ln_BRP_pp_NUTS3 + levelNN_median_100
                    + EW_km + GVE_ha + tour_int
                    + ln_pile1_ha + ln_oepul_az_ha
                    + ln_invest_betrieb + ln_pile2_sub_EW
                    + acker_share100, data=data_aggr)
```

Anhang

```
res_means_n <- c(model_means_n$residuals)
res_means_LF <- c(model_means_LF$residuals)

lm.morantest(model_means_n, lokal_W, alternative = "two.sided")
lm.morantest(model_means_LF, lokal_W, alternative = "two.sided")

local_means_n <- localmoran(res_means_n, lokal_W)
local_means_LF <- localmoran(res_means_LF, lokal_W)

### Schatzen der SLX-Modelle ###

pile1_ha_W <- paneldata$ln_pile1_ha
pile1_ha_W2 <- paneldata$ln_pile1_ha
oepul_az_ha_W <- paneldata$ln_oepul_az_ha
oepul_az_ha_W2 <- paneldata$ln_oepul_az_ha
invest_betrieb_W <- paneldata$ln_invest_betrieb
invest_betrieb_W2 <- paneldata$ln_invest_betrieb
pile2_sub_EW_W <- paneldata$ln_pile2_sub_EW
pile2_sub_EW_W2 <- paneldata$ln_pile2_sub_EW

bio_share100_W <- paneldata$bio_share100
bio_share100_W2 <- paneldata$bio_share100
EW_km_W <- paneldata$EW_km
EW_km_W2 <- paneldata$EW_km
GVE_ha_W <- paneldata$GVE_ha
GVE_ha_W2 <- paneldata$GVE_ha
tour_int_W <- paneldata$tour_int
tour_int_W2 <- paneldata$tour_int
acker_share100_W <- paneldata$acker_share100
acker_share100_W2 <- paneldata$acker_share100

SLX_n <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ ln_pile1_ha + slag(pile1_ha_W, listw = lokal_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = lokal_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = lokal_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = lokal_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_n025 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg025_W)
+ slag(oepul_az_ha_W2, listw = reg025_W)
+ slag(invest_betrieb_W2, listw = reg025_W)
+ slag(pile2_sub_EW_W2, listw = reg025_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX_n035 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg035_W)
+ slag(oepul_az_ha_W2, listw = reg035_W)
+ slag(invest_betrieb_W2, listw = reg035_W)
+ slag(pile2_sub_EW_W2, listw = reg035_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_n045 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg045_W)
+ slag(oepul_az_ha_W2, listw = reg045_W)
+ slag(invest_betrieb_W2, listw = reg045_W)
+ slag(pile2_sub_EW_W2, listw = reg045_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_n055 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg055_W)
+ slag(oepul_az_ha_W2, listw = reg055_W)
+ slag(invest_betrieb_W2, listw = reg055_W)
+ slag(pile2_sub_EW_W2, listw = reg055_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_n065 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg065_W)
+ slag(oepul_az_ha_W2, listw = reg065_W)
+ slag(invest_betrieb_W2, listw = reg065_W)
```

Anhang

```
+ slag(pile2_sub_EW_W2, listw = reg065_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_n075 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + ln_LF_sitz
+ GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg075_W)
+ slag(oepul_az_ha_W2, listw = reg075_W)
+ slag(invest_betrieb_W2, listw = reg075_W)
+ slag(pile2_sub_EW_W2, listw = reg075_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ ln_pile1_ha + slag(pile1_ha_W, listw = lokal_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = lokal_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = lokal_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = lokal_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF025 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg025_W)
+ slag(oepul_az_ha_W2, listw = reg025_W)
+ slag(invest_betrieb_W2, listw = reg025_W)
+ slag(pile2_sub_EW_W2, listw = reg025_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF035 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg035_W)
+ slag(oepul_az_ha_W2, listw = reg035_W)
+ slag(invest_betrieb_W2, listw = reg035_W)
+ slag(pile2_sub_EW_W2, listw = reg035_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF045 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg045_W)
+ slag(oepul_az_ha_W2, listw = reg045_W)
+ slag(invest_betrieb_W2, listw = reg045_W)
+ slag(pile2_sub_EW_W2, listw = reg045_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF055 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg055_W)
+ slag(oepul_az_ha_W2, listw = reg055_W)
+ slag(invest_betrieb_W2, listw = reg055_W)
+ slag(pile2_sub_EW_W2, listw = reg055_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF065 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg065_W)
+ slag(oepul_az_ha_W2, listw = reg065_W)
+ slag(invest_betrieb_W2, listw = reg065_W)
+ slag(pile2_sub_EW_W2, listw = reg065_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX_LF075 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
+ EW_km + GVE_ha + tour_int + acker_share100
+ slag(pile1_ha_W2, listw = reg075_W)
+ slag(oepul_az_ha_W2, listw = reg075_W)
+ slag(invest_betrieb_W2, listw = reg075_W)
+ slag(pile2_sub_EW_W2, listw = reg075_W),
data = paneldata, index = c("GKZ", "year"),
model = "within", effect = "twoways")

SLX2_n <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = lokal_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = lokal_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = lokal_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = lokal_W)
+ bio_share100 + slag(bio_share100_W, listw = lokal_W)
+ EW_km + slag(EW_km_W, listw = lokal_W)
+ GVE_ha + slag(GVE_ha_W, listw = lokal_W)
+ tour_int + slag(tour_int_W, listw = lokal_W)
+ acker_share100 + slag(acker_share100_W, listw = lokal_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")
```

Anhang

```
SLX2_n025 <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg025_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg025_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg025_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg025_W)
+ bio_share100 + slag(bio_share100_W, listw = reg025_W)
+ EW_km + slag(EW_km_W, listw = reg025_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg025_W)
+ tour_int + slag(tour_int_W, listw = reg025_W)
+ acker_share100 + slag(acker_share100_W, listw = reg025_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_n035 <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg035_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg035_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg035_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg035_W)
+ bio_share100 + slag(bio_share100_W, listw = reg035_W)
+ EW_km + slag(EW_km_W, listw = reg035_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg035_W)
+ tour_int + slag(tour_int_W, listw = reg035_W)
+ acker_share100 + slag(acker_share100_W, listw = reg035_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_n045 <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg045_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg045_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg045_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg045_W)
+ bio_share100 + slag(bio_share100_W, listw = reg045_W)
+ EW_km + slag(EW_km_W, listw = reg045_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg045_W)
+ tour_int + slag(tour_int_W, listw = reg045_W)
+ acker_share100 + slag(acker_share100_W, listw = reg045_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_n055 <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg055_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg055_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg055_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg055_W)
+ bio_share100 + slag(bio_share100_W, listw = reg055_W)
+ EW_km + slag(EW_km_W, listw = reg055_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg055_W)
+ tour_int + slag(tour_int_W, listw = reg055_W)
+ acker_share100 + slag(acker_share100_W, listw = reg055_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_n065 <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg065_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg065_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg065_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg065_W)
+ bio_share100 + slag(bio_share100_W, listw = reg065_W)
+ EW_km + slag(EW_km_W, listw = reg065_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg065_W)
+ tour_int + slag(tour_int_W, listw = reg065_W)
+ acker_share100 + slag(acker_share100_W, listw = reg065_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_n075 <- plm(ln_betriebe ~ ln_BRP_pp_NUTS3 + ln_LF_sitz
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg075_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg075_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg075_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg075_W)
+ bio_share100 + slag(bio_share100_W, listw = reg075_W)
+ EW_km + slag(EW_km_W, listw = reg075_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg075_W)
+ tour_int + slag(tour_int_W, listw = reg075_W)
+ acker_share100 + slag(acker_share100_W, listw = reg075_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = lokal_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = lokal_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = lokal_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = lokal_W)
+ bio_share100 + slag(bio_share100_W, listw = lokal_W)
+ EW_km + slag(EW_km_W, listw = lokal_W)
+ GVE_ha + slag(GVE_ha_W, listw = lokal_W)
+ tour_int + slag(tour_int_W, listw = lokal_W)
+ acker_share100 + slag(acker_share100_W, listw = lokal_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF025 <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg025_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg025_W)
```

Anhang

```
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg025_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg025_W)
+ bio_share100 + slag(bio_share100_W, listw = reg025_W)
+ EW_km + slag(EW_km_W, listw = reg025_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg025_W)
+ tour_int + slag(tour_int_W, listw = reg025_W)
+ acker_share100 + slag(acker_share100_W, listw = reg025_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF035 <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg035_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg035_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg035_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg035_W)
+ bio_share100 + slag(bio_share100_W, listw = reg035_W)
+ EW_km + slag(EW_km_W, listw = reg035_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg035_W)
+ tour_int + slag(tour_int_W, listw = reg035_W)
+ acker_share100 + slag(acker_share100_W, listw = reg035_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF045 <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg045_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg045_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg045_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg045_W)
+ bio_share100 + slag(bio_share100_W, listw = reg045_W)
+ EW_km + slag(EW_km_W, listw = reg045_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg045_W)
+ tour_int + slag(tour_int_W, listw = reg045_W)
+ acker_share100 + slag(acker_share100_W, listw = reg045_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF055 <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg055_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg055_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg055_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg055_W)
+ bio_share100 + slag(bio_share100_W, listw = reg055_W)
+ EW_km + slag(EW_km_W, listw = reg055_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg055_W)
+ tour_int + slag(tour_int_W, listw = reg055_W)
+ acker_share100 + slag(acker_share100_W, listw = reg055_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF065 <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg065_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg065_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg065_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg065_W)
+ bio_share100 + slag(bio_share100_W, listw = reg065_W)
+ EW_km + slag(EW_km_W, listw = reg065_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg065_W)
+ tour_int + slag(tour_int_W, listw = reg065_W)
+ acker_share100 + slag(acker_share100_W, listw = reg065_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX2_LF075 <- plm(ln_LF_je_betrieb ~ ln_BRP_pp_NUTS3
+ ln_pile1_ha + slag(pile1_ha_W, listw = reg075_W)
+ ln_oepul_az_ha + slag(oepul_az_ha_W, listw = reg075_W)
+ ln_invest_betrieb + slag(invest_betrieb_W, listw = reg075_W)
+ ln_pile2_sub_EW + slag(pile2_sub_EW_W, listw = reg075_W)
+ bio_share100 + slag(bio_share100_W, listw = reg075_W)
+ EW_km + slag(EW_km_W, listw = reg075_W)
+ GVE_ha + slag(GVE_ha_W, listw = reg075_W)
+ tour_int + slag(tour_int_W, listw = reg075_W)
+ acker_share100 + slag(acker_share100_W, listw = reg075_W),
data = paneldata, index = c("GKZ", "year"), model = "within", effect = "twoways")
```

Schatzen der SLX-Modelle fuer unterschiedliche Hauptproduktionsgebiete

Subsets erstellen

```
paneldata1 = subset(paneldata, HPG == 1)
paneldata78 = subset(paneldata, HPG > 6)
```

```
pile1_ha_W1 <- paneldata1$ln_pile1_ha
pile1_ha_W78 <- paneldata78$ln_pile1_ha
oepul_az_ha_W1 <- paneldata1$ln_oepul_az_ha
oepul_az_ha_W78 <- paneldata78$ln_oepul_az_ha
invest_betrieb_W1 <- paneldata1$ln_invest_betrieb
invest_betrieb_W78 <- paneldata78$ln_invest_betrieb
pile2_sub_EW_W1 <- paneldata1$ln_pile2_sub_EW
pile2_sub_EW_W78 <- paneldata78$ln_pile2_sub_EW
```

Nachbarschaftsmatrizen

```
GKZ_shape1 <- readOGR("GKZ_HPG1.shp")
```

Anhang

```
coord1 <- coordinates(GKZ_shape1)
ID1 <- GKZ_shape1$GKZ

Gem_nb_lokal1 <- dnearneigh(coord1, d1 = 0, d2 = 25000, row.names = ID1)

lokal_W1 <- nb2listw(Gem_nb_lokal1, glist = NULL, style = "W",
                    zero.policy = TRUE)

GKZ_shape78 <- readOGR("GKZ_HPG78.shp")

coord78 <- coordinates(GKZ_shape78)
ID78 <- GKZ_shape78$GKZ

Gem_nb_lokal78 <- dnearneigh(coord78, d1 = 0, d2 = 25000,
                             row.names = ID78)

lokal_W78 <- nb2listw(Gem_nb_lokal78, glist = NULL, style = "W",
                     zero.policy = TRUE)

# Modelle #

SLX_n_HPG1 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
                 + EW_km + ln_LF_sitz + GVE_ha + tour_int + acker_share100
                 + ln_pile1_ha + slag(pile1_ha_W1, listw = lokal_W1)
                 + ln_oepul_az_ha + slag(oepul_az_ha_W1, listw = lokal_W1)
                 + ln_invest_betrieb + slag(invest_betrieb_W1, listw = lokal_W1)
                 + ln_pile2_sub_EW + slag(pile2_sub_EW_W1, listw = lokal_W1),
                 data = paneldata1,
                 index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX_n_HPG78 <- plm(ln_betriebe ~ bio_share100 + ln_BRP_pp_NUTS3
                  + EW_km + ln_LF_sitz + GVE_ha + tour_int + acker_share100
                  + ln_pile1_ha + slag(pile1_ha_W78, listw = lokal_W78)
                  + ln_oepul_az_ha + slag(oepul_az_ha_W78, listw = lokal_W78)
                  + ln_invest_betrieb + slag(invest_betrieb_W78, listw = lokal_W78)
                  + ln_pile2_sub_EW + slag(pile2_sub_EW_W78, listw = lokal_W78),
                  data = paneldata78,
                  index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX_LF_HPG1 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
                  + EW_km + GVE_ha + tour_int + acker_share100
                  + ln_pile1_ha + slag(pile1_ha_W1, listw = lokal_W1)
                  + ln_oepul_az_ha + slag(oepul_az_ha_W1, listw = lokal_W1)
                  + ln_invest_betrieb + slag(invest_betrieb_W1, listw = lokal_W1)
                  + ln_pile2_sub_EW + slag(pile2_sub_EW_W1, listw = lokal_W1),
                  data = paneldata1,
                  index = c("GKZ", "year"), model = "within", effect = "twoways")

SLX_LF_HPG78 <- plm(ln_LF_je_betrieb ~ bio_share100 + ln_BRP_pp_NUTS3
                   + EW_km + GVE_ha + tour_int + acker_share100
                   + ln_pile1_ha + slag(pile1_ha_W78, listw = lokal_W78)
                   + ln_oepul_az_ha + slag(oepul_az_ha_W78, listw = lokal_W78)
                   + ln_invest_betrieb + slag(invest_betrieb_W78, listw = lokal_W78)
                   + ln_pile2_sub_EW + slag(pile2_sub_EW_W78, listw = lokal_W78),
                   data = paneldata78,
                   index = c("GKZ", "year"), model = "within", effect = "twoways")
```