



Now- und Forecasting touristischer Näch- tigungen, Umsätze und Wertschöpfung für Österreich

Oliver Fritz, Anna Burton, Philipp Piribauer

Wissenschaftliche Assistenz: Sabine Ehn-Fragner

Dezember 2022

Österreichisches Institut für Wirtschaftsforschung

Now- und Forecasting touristischer Nächtigungen, Umsätze und Wertschöpfung für Österreich

Oliver Fritz, Anna Burton, Philipp Piribauer

Dezember 2022

**Österreichisches Institut für Wirtschaftsforschung
Im Auftrag der Österreich Werbung**

Begutachtung: Christian Glocker

Wissenschaftliche Assistenz: Sabine Ehn-Fragner

Durch die Anwendung geeigneter Modellansätze sollen vorherrschende Informationslücken geschlossen und der Tourismusindustrie damit neue Entscheidungshilfen zur Verfügung gestellt werden, um sich nicht nur auf das quantitative Wachstum der Gästeankünfte und der touristischen Übernachtungen zu konzentrieren, sondern auch auf die Steigerung des durch die touristischen Dienstleistungen generierten Wertes. Dafür soll ein Instrument geschaffen werden, das die Überwachung der touristischen Zyklen anhand von Umsatz- und Wertschöpfungskennzahlen ermöglicht. Für die zu prognostizierenden Größen werden verschiedene Prognosemodelle verwendet und deren Leistungsfähigkeit anhand von Prognosegenauigkeit und Fehlerminimierung gegeneinander abgewogen. Über die drei Prognosevariablen zeigten sich robuste Ergebnisse mit den geringsten durchschnittlichen absoluten Prognosefehlern bei der Prognostizierung der Bruttowertschöpfung des Sektor I, gefolgt von den Umsätzen in der Beherbergung und Gastronomie. Die angewandten Shrinkage-Modelle wiesen relativ zu den anderen Prognosemodellen die höchste Prognosegüte auf. Anhand dieser Ergebnisse sollen Branchenvertreter und Tourismusorganisationen zukünftig fundiertere Entscheidungen über Entwicklungsziele treffen können, während die gewonnenen Erkenntnisse auch in die Formulierung künftiger politischer Maßnahmen Eingang finden sollen.

2022/3/S/WIFO-Projektnummer: 22059

© 2022 Österreichisches Institut für Wirtschaftsforschung

Medieninhaber (Verleger), Herausgeber und Hersteller: Österreichisches Institut für Wirtschaftsforschung,
1030 Wien, Arsenal, Objekt 20 • Tel. (+43 1) 798 26 01-0 • <https://www.wifo.ac.at/> • Verlags- und Herstellungsort: Wien

Verkaufspreis: 30 € • Kostenloser Download: <https://www.wifo.ac.at/wwa/pubid/69823>

Inhaltsverzeichnis

1	Einleitung	4
2	Datengrundlagen	4
2.1	Entwicklung der Nächtigungen	5
2.2	Entwicklung der Umsatzsteuervoranmeldungen	5
2.3	Entwicklung der realen Bruttowertschöpfung	6
3	Modellspezifikation und Prognose	7
4	Prognoseergebnisse	10
4.1	Prognosegüte für die Entwicklung der Nächtigungen	10
4.2	Prognosegüte für die Entwicklung der Umsatzsteuervoranmeldung	16
4.3	Prognosegüte für die Entwicklung der reale Bruttowertschöpfung	22
5	Zusammenfassung und Vorschläge zur Überleitung in den Regelbetrieb	28
6	Referenzen	30

Abbildungsverzeichnis

1	Prognosegüte der Nächtigungen	11
2	Prognosegüte der Nächtigungen in Wachstumsraten	11
3	Kontrafaktische Prognosefehler für unterschiedliche Schätzansätze – Nächtigungen	12
4	Kumulierte absolute und quadrierte Prognosefehler über die Zeit – Nächtigungen	14
5	Prognosegüte der Umsatzsteuervoranmeldungen	16
6	Prognosegüte der Umsatzsteuervoranmeldungen in Wachstumsraten	17
7	Kontrafaktische Prognosefehler für unterschiedliche Schätzansätze – Umsatzsteuervoranmeldungen	18
8	Kumulierte absolute und quadrierte Prognosefehler über die Zeit – Umsatzsteuervoranmeldungen	19
9	Prognosegüte der realen Bruttowertschöpfung	22
10	Prognosegüte der realen Bruttowertschöpfung in Wachstumsraten	23
11	Kontrafaktische Prognosefehler für unterschiedliche Schätzansätze – reale Bruttowertschöpfung	24
12	Kumulierter absolute Prognosefehler über die Zeit – reale Bruttowertschöpfung	25
13	Kumulierter quadrierte Prognosefehler über die Zeit – reale Bruttowertschöpfung	25

Verzeichnis der Übersichten

1	Übersicht der verwendeten Modelle	9
2	Absolute Prognosefehler über die Zeit und Modellspezifikationen – Nächtigungen	15
3	Absolute Prognosefehler über die Zeit und Modellspezifikationen – Umsatzsteuervoranmeldungen	21
4	Absolute Prognosefehler über die Zeit und Modellspezifikationen – reale Bruttowertschöpfung	27

1 Einleitung

Der Plan T, der 2019 vom österreichischen Tourismusministerium veröffentlichte nationale Masterplan für den Tourismus, bekennt sich klar zu einem qualitätvollen Tourismus: Nicht das Wachstum von Gästeankünften oder Gästenächtigungen soll im Vordergrund stehen, sondern die Steigerung der durch touristische Dienstleistungen erwirtschafteten Wertschöpfung. Die Verwirklichung dieses Ziels bringt jedoch ein Messproblem mit sich: Während Ankünfte und Nächtigungen von inländischen und ausländischen Gästen von Statistik Austria auf Monatsbasis mit rund einem Monat Verzögerung regelmäßig veröffentlicht werden, stehen zu touristischen Umsätzen und der Wertschöpfung weit weniger Informationen zur Verfügung. In den von Statistik Austria und dem Österreichischen Institut für Wirtschaftsforschung (WIFO) erstellten Tourismussatellitenkonten auf nationaler und regionaler Ebene werden Umsätze und Wertschöpfung auf Jahresbasis und mit zeitlicher Verzögerung berechnet – so wurden erst zu Beginn des II. Quartals 2022 Berechnungen für das Jahr 2020 sowie eine Schätzung für 2021 fertiggestellt. Die Schließung dieser zeitlichen Informationslücke und die Beobachtung der monatlichen Tourismuskonjunktur auf Basis von Umsätzen und vor allem der Wertschöpfung steht im Zentrum dieses Forschungsprojektes: Es soll untersucht werden, ob es auf Basis vorhandener Daten möglich und sinnvoll ist, diese Variablen für den aktuellen Rand zu prognostizieren, ohne dabei einen zu großen Prognosefehler in Kauf nehmen zu müssen. Ist die Prognosegüte zufriedenstellend, könnte in einem weiteren Schritt (und außerhalb dieses Projektes) ein operatives Prognose-Tool aufgesetzt werden, welches laufend Now- und Forecasts zur Tourismuswirtschaft in Österreich anbietet. Im Folgenden sollen Datengrundlagen, Modellidentifikation sowie die Evaluierung der einzelnen Prognosen im Detail beschrieben und erläutert werden. Schlussfolgerungen zur weiteren Verwendung der Modelle im Rahmen laufender Prognosen stehen am Ende des Projektberichtes.

2 Datengrundlagen

Die in diesem Projekt zu erstellenden Prognosen umfassen drei Variablen: Die Zahl der Nächtigungen, die nominellen Umsätze in Euro auf Basis der Umsatzsteuervoranmeldungen des NACE Sektors I (Beherbergungswesen und Gastronomie) sowie die reale Bruttowertschöpfung desselben Sektors. Nächtigungen und Umsatzsteuervoranmeldungsdaten werden auf monatlicher Basis von Statistik Austria veröffentlicht und daher auch monatlich prognostiziert. Die reale Bruttowertschöpfung schätzt Statistik Austria nach Quartalen, für die dann auch die Prognosen erstellt werden.¹

¹Die Daten wurden mit dem Stichtag 31.05.2023 abgerufen, die reale Bruttowertschöpfung bezieht sich auf das Basisjahr 2015.

2.1 Entwicklung der Nächtigungen

Auf nationaler Ebene wuchs der österreichische Tourismus – gemessen an der Zahl der touristischen Nächtigungen insgesamt – in den Jahren von 2010 bis 2019 mit $-0,5\%$ bis $+4,0\%$, was einer durchschnittlichen jährlichen Zunahme von $+2,3\%$ entspricht. Dabei stieg die Nachfrage internationaler Tourist:innen stärker als jene von Binnenreisenden (durchschnittliche jährliche Wachstumsrate 2010/2019 $+2,6\%$ zu $+1,5\%$). In absoluten Zahlen setzte sich das Nächtigungsvolumen zwischen 2010 und 2019 im Verhältnis von rund 30:70 aus inländischen bzw. ausländischen Reisenden zusammen (\emptyset 2010/19: Gesamtnächtigungen 137,0 Mio., davon Binnenreisende 37,0 Mio., ausländische Gäste 100,0 Mio.). Dieser recht stetige touristische Nachfragezuwachs in den vergangenen Jahren, mit einem vorläufigen Höhepunkt im Jahr 2019 mit knapp 152,7 Mio. Nächtigungen und 46,2 Mio. Ankünften, wurde durch den Ausbruch der COVID-19-Pandemie im März 2020 abrupt unterbrochen. Im selben Jahr verzeichneten österreichische Beherbergungsunternehmen lediglich 97,9 Mio. an touristischen Nächtigungen, was einer Reduktion im Vergleich zum Vorkrisenniveau von 2019 von insgesamt $35,9\%$ entspricht. Ausschlaggebend für den erheblichen Rückgang der Gesamtnächtigungen war dabei das Ausbleiben ausländischer Gäste (Nächtigungen $-41,2\%$). Die Nachfrage der inländischen Reisenden ging mit $-20,9\%$ vergleichsweise geringer zurück. Im Folgejahr 2021 sanken durch den Ausfall der gesamten Wintersaison die Nächtigungen weiter auf 79,6 Mio. (inländische Reisende 29,6 Mio., internationale Gäste: 50,0 Mio.). Damit verschob sich im Kalenderjahr 2021 auch die Herkunftsstruktur der Reisenden: Obwohl internationale Gäste mit $62,8\%$ immer noch die Mehrheit der Tourist:innen in Österreich ausmachten, erhöhte sich der Anteil Binnenreisender im Vergleich zu 2019 um 11,0 Prozentpunkte auf $37,2\%$. Auch auf Basis der touristischen Ankünfte unterschieden sich die Corona-geprägten Jahre 2020 und 2021 stark von den vorangegangenen. Zwischen 2010 und 2019 wuchs die diesbezügliche Nachfrage in Österreich mit $+1,9\%$ bis $+5,2\%$ um durchschnittlich $+3,7\%$ pro Jahr, auf 23,8 Mio. im 10-Jahres-Schnitt. In den Pandemie-jahren 2020 und 2021 sanken die Ankünfte relativ stärker als die Nächtigungen. 25,0 Mio. Ankünfte 2020 (9,9 Mio. aus dem Inland, 15,1 Mio. aus dem Ausland) entsprachen einem Rückgang gegenüber dem Vorjahr von $45,8\%$, 2021 ging die Nachfrage nochmals um $11,5\%$ zurück. Dieser im Vergleich zu den Nächtigungen stärkere Rückgang bei den Ankünften ist mit einer entsprechenden Zunahme der Aufenthaltsdauer verbunden, womit 2020 der über viele Jahre zu beobachtende Trend zu kürzeren Reisen unterbrochen wurde (\emptyset 2010/2019 3,5 Nächte, 2020 3,9 Nächtigungen). Längere Aufenthalte wurden sowohl bei internationalen Reisenden (Aufenthaltsdauer $+24,2\%$ auf 4,4 Nächte) als auch bei nationalen Gästen ($+13,9\%$ auf 3,2 Nächte) verzeichnet.

2.2 Entwicklung der Umsatzsteuervoranmeldungen

Bei der Umsatzsteuer handelt es sich um eine Unternehmensabgabe. In der im Regelfall monatlich zu erstellenden Umsatzsteuervoranmeldung (UVA) werden der Umsatzsteuer die Vorsteuerbeträge gegenübergestellt. Aus einem Vorsteuerüberhang resultiert eine

Gutschrift, anderenfalls eine Zahllast, wodurch monatliche Differenzen zwischen Steuerzahlungen und Steuerlasten ausgeglichen werden. Die Voranmeldungen der steuerpflichtigen Umsätze gelten als robuster Schätzindikator für die nominellen Umsätze einer Branche. Auf nationaler Ebene stieg die Summe der Umsatzsteuer laut Voranmeldungen des NACE-Sektors I (Beherbergung und Gastronomie) von 2010 bis 2019 um 2,2% bis 6,8%, durchschnittlich um 4,6% jährlich. 2019 wurde in der österreichischen Beherbergung und Gastronomie ein steuerpflichtiges Umsatzvolumen von 21,6 Mrd.€ gemeldet. Mit dem Ausbruch der COVID-19-Pandemie 2020 gingen die Umsätze in diesem Jahr um 31,6% zurück, im zweiten Pandemiejahr 2021 um weitere 3,9% auf ein steuerpflichtiges Umsatzvolumen von 14,2 Mrd.€. Damit lagen die steuerpflichtigen Umsätze des Sektors I (nicht inflationsbereinigt) knapp unter dem Wert des Jahres 2010. Eine Gegenüberstellung mit der Nächtigungsentwicklung in den von der Pandemie betroffenen Jahren zeigt, dass die (allerdings nicht preisbereinigten) Umsätze weniger stark einbrachen und somit höhere nominelle Erlöse erzielt werden konnten.

2.3 Entwicklung der realen Bruttowertschöpfung

Bei der Bruttowertschöpfung (BWS) handelt es sich um eine volkswirtschaftliche Kennzahl, die den entlang der sektoralen Wertschöpfungsketten geschaffenen Mehrwert erfasst. Die Bruttowertschöpfung zu Herstellungspreisen berechnet sich für jeden Wirtschaftsbereich durch Abzug der Vorleistungen (bewertet zu Anschaffungspreisen) vom Produktionswert (bewertet zu Herstellungspreisen). Das Bruttoinlandsprodukt (bewertet zu Marktpreisen) ergibt sich in weiterer Folge aus der Summe der sektoralen Bruttowertschöpfungsbeiträge (zu Herstellungspreisen) abzüglich der Gütersteuern zuzüglich der Gütersubventionen. Bruttoinlandsprodukt wie Bruttowertschöpfung können zudem unter Heranziehung geeigneter Deflatoren preisbereinigt, also als reale Größen, ausgewiesen werden. Die Bruttowertschöpfung eines einzelnen Sektors kann als Beitrag dieses Sektors zu gesamtwirtschaftlichen Leistung betrachtet werden. Im Jahr 2019 betrug die nominelle Bruttowertschöpfung des Sektors I (Beherbergung und Gastronomie) 18,675 Mrd.€, was einem Anteil von 5,3% an der Gesamtwertschöpfung entspricht. In den beiden Folgejahren verringerte sich die nominelle sektorale Bruttowertschöpfung um 30,3% (2020) bzw. 3,9% (2021). Damit entwickelte sich die Kenngröße seit 2019 nominell ähnlich wie die oben beschriebenen nominellen Umsätze. Die reale Bruttowertschöpfung in Beherbergung und Gastronomie expandierte zwischen 2010 und 2019 um durchschnittlich 0,6% pro Jahr (jährliche Wachstumsraten zwischen -0,4% und +1,8%). 2020 sank die reale BWS jedoch von 16,3 Mrd.€ auf 9,8 Mrd.€ und damit um 40,1% 2021 um weitere 16,8%. Die preisbereinigte Entwicklung unterschied sich damit erheblich von der nominellen – weit weniger starken – Dynamik, was auf relativ hohe Preissteigerungsraten im Sektor I in den Krisenjahren 2020 und 2021 zurückzuführen ist.

3 Modellspezifikation und Prognose

Für die zu prognostizierenden Größen (Nächtigungen, Umsatzsteuer laut Voranmeldungen im NACE-Sektor I, reale Bruttowertschöpfung in Beherbergung und Gastronomie) werden eine Reihe von univariaten Prognosemodellen verwendet. Als Basisspezifikation zur Prognose der Größe y_t zum Zeitpunkt t ($t = 1, \dots, T$) wird folgende allgemeine Modellstruktur angewendet:

$$y_t = \alpha + \sum_{p=1}^P y_{t-p} \beta_p + \sum_{q=1}^Q \mathbf{x}_{t-q} \gamma_q + \mathbf{z}_t \boldsymbol{\delta} + \varepsilon_t \quad (3.1)$$

Die zu prognostizierende Größe y_t wird dabei mit einer allgemeinen Konstante α durch den vergangenen Verlauf von P Perioden der eigenen Reihe sowie der Vergangenheit von Q Perioden von anderen relevanten touristischen bzw. makroökonomischen Größen (welche im Vektor \mathbf{x}_{t-q} zusammengefasst sind) erklärt. Zusätzlich dazu kommen noch etwaige weitere Daten infrage, welche stets zeitgleich zu y_t verfügbar und im Vektor \mathbf{z}_t enthalten sind. Dazu zählen etwa Kalendereffekte oder saisonale Muster. Die oben dargestellte Modellspezifikation wird oft als eine generelle Form eines ARX-Modells bezeichnet, wobei P und Q die autoregressiven *lags* (die Anzahl der vergangenen Werte von y_t und \mathbf{x}_t) angeben. $\alpha, \beta_1, \dots, \beta_P, \gamma_1, \dots, \gamma_Q$, sowie der Vektor $\boldsymbol{\delta}$ sind unbeobachtete, zu schätzende Modellparameter. ε_t ist ein Fehlerterm, welcher standardmäßig als normalverteilt mit Mittelwert null und Varianz σ^2 angenommen wird, also $\varepsilon_t \sim \mathcal{N}(0, \sigma^2)$. Da die zu prognostizierende Größen im Tourismus im Allgemeinen zeitlichen Trends unterliegen, erfüllen diese Zeitreihen nicht die statistische Eigenschaft der Stationarität. Um diesem Problem entgegenzutreten – und somit die Prognosegüte zu erhöhen – bietet es sich an, die Größen (Nächtigungen, Umsatzsteuervoranmeldungen, reale Bruttowertschöpfung) als Wachstumsrate gegenüber dem Vorjahr zu definieren. Die Betrachtung von jährlichen Wachstumsraten (anstelle von Niveaus) in der Modellspezifikation hat zudem den Vorteil, dass diese implizit saisonbedingten Schwankungen Rechnung trägt. Ausgehend von der Basisstruktur des Modells bietet sich eine Vielzahl an Modellerweiterungen bzw. etwas flexiblere Spezifikationen an, welche kurz skizziert werden sollen:

- **Methoden zur Vermeidung von Überparametrisierung:** Die internationale Literatur im Bereich Fore- und Nowcasting kommt recht einhellig zum Ergebnis, dass möglichst schlank gehaltene Modelle tendenziell eine bessere Prognosegüte aufweisen als sehr große Modellstrukturen (was als Überparametrisierungsproblem bezeichnet wird). Somit entsteht ein Zielkonflikt zwischen der Inklusion und Exklusion von externer Modellinformation (etwa im Rahmen der Information in \mathbf{x}_t und \mathbf{z}_t). Moderne Prognosemethoden aus der Bayes'schen Statistik erlauben es, diese Probleme zu verringern, ohne dabei auf möglicherweise für die Prognose besonders nützliche Zusatzinformationen zu verzichten.

- **Mischungen von unterschiedlichen Modellen:** Auch zeigt sich in vielen Studien, dass die Kombination aus mehreren Modellen und Schätzmethoden oft bessere Ergebnisse liefert als Prognosen von Einzelmodellen.
- **„Lernende“ Modelle:** Das oben skizzierte Modell kann als ein statisches bezeichnet werden, da die unbeobachteten Modellparameter über den Schätzzeitraum konstant bleiben. Das sich ständig verändernde (konjunkturelle) Umfeld sowie das Auftreten von Strukturbrüchen (wie beispielsweise der Ausbruch der COVID-19-Pandemie oder des Ukraine-Kriegs) legt die Vermutung nahe, dass dynamische Modelle für die gegenständliche Prognose von besonderer Relevanz sein dürften. Diese dynamischen Modelle lernen über den Zeitablauf, indem sie die Modellparameter über die Zeit variieren lassen.

Die Wahl der konkreten Spezifikation und Methode sollte dabei aber an die spezifischen Datengegebenheiten angepasst werden. Aus historischem Datenmaterial der zu prognostizierenden Kenngrößen kann dabei aus einem Pool an alternativen Methoden gewählt werden, welche die beste Prognosegüte aufweisen (sogenanntes 'forecasting horse race', [Bhattacharya et al. 2015](#)). Die folgende Tabelle ([Tabelle 1](#)) dient als Übersicht der verwendeten Modelle und beschreibt jedes kurz.

Für die Schätzung der unterschiedlichen Ansätze und Prognosegrößen wurden zahlreiche sogenannter Robustheits- und Sensitivitätschecks unterzogen, um ein möglichst optimales Set an Information für die Prognose zu verwenden. In allen Fällen erwiesen sich jene Spezifikationen mit einer Länge der *lags* ($P = Q = 1$) als die besten. Darüber hinaus wurden jedoch die Entwicklungen des jeweiligen Vorjahres ebenfalls explizit mitberücksichtigt (für monatliche Reihen der zwölfte lag und für Quartalsreihen der vierte lag). Für die Schätzungen auf Quartalsebene wurden monatliche Basisdaten auf Quatalswerte aggregiert. Die Prognoseschätzungen entstehen in einem 'rolling window': Bei rollierenden Prognosen wird das jeweils nächste Monat (bzw. Quartal) basierend auf den vorangehenden Ist-Daten, sowie den vorrangegangenen prognostizierten Werten erstellt. Somit wird jede Zeitperiode einzeln prognostiziert und dann Schritt für Schritt die darauffolgende Periode. Als exogene Variablen in den endgültigen Prognosen wurden in jeweils etwas unterschiedlichen Kombinationen touristische Nächtigungen (inländischer und ausländischer Gäste), Feiertage pro Zeitperiode, Erwartungswerte zur zukünftigen Entwicklung des Bereichs Beherbergung und Gastronomie und die Einschätzung der aktuellen Lage des Sektor I aus dem WIFO-Konjunkturtest sowie die Anzahl der offenen Stellen und der unselbständig aktiven Beschäftigten herangezogen.²

²Andere Variablen, wie etwa die Anzahl der Arbeitslosen, Flugbewegungen am Flughafen Wien, die Anzahl der Passagiere am Flughafen Wien, Hotelumsätze aus unterschiedlichen Quellen, Gastronomieumsätze aus unterschiedlichen Quellen, Tourimusexporte und -importe wurden auf ihre Prognosefähigkeit hin überprüft, jedoch aufgrund fehlender Prognosegüte nicht in die Modellspezifikationen aufgenommen.

Tabelle 1: Übersicht der verwendeten Modelle

	Akronym	Kurzbeschreibung
Standardmodelle	OLS	<i>ordinary least squares</i> – Schätzung der Modellparameter mit der Methode der kleinsten Quadrate; stellt den Standardansatz dar.
	AR1	<i>autoregressive model of order 1</i> – Ähnlich wie OLS, allerdings beinhaltet das Modell keine exogenen Variablen, sondern besteht lediglich aus einem um eine Periode zeitverzögerten Wert (<i>1 lag</i>) sowie einer Konstanten. Der sog. AR1-Prozess ist ebenfalls Standard und stellt für viele Prognosen <i>die</i> absolute Benchmark dar.
	RW	<i>random walk</i> oder naive Prognose – Die Prognose der Wachstumsrate ergibt sich aus der Fortschreibung des letzten verfügbaren Level-Wertes (d.h. kein Wachstum zum Vorjahr). Der <i>random walk</i> sollte in jedem Fall systematisch schlechter ausfallen, sodass eine modellhafte Prognose in Zukunft auch hinreichend begründbar ist.
Dimensionsreduktion & Kombination von mehreren	DLshrink	<i>Dirichlet-Laplace shrinkage</i> (Bhattacharya et al. 2015) – Sehr moderne Methode zur Dimensionsreduktion bzw. um verschiedene Modellprognosen miteinander zu verbinden; wird in vielen rezenten Prognoseansätzen verwendet.
	NGshrink	<i>Normal-Gamma shrinkage</i> (Brown & Griffin 2010) – Sehr ähnlich zu 'DLshrink', allerdings mit einer etwas anderen Modellarchitektur.
	BMA	<i>Bayesian model averaging</i> (Fernandez et al. 2001) – Mittlerweile weit verbreiteter Ansatz, welcher Prognosen von Modellen mit unterschiedlichen Variablenkombinationen miteinander 'mischt' bzw. kombiniert.
	BMS	<i>Bayesian model selection</i> – Ähnlich zu 'BMA', allerdings werden nicht die Prognosen von mehreren Methoden miteinander kombiniert, sondern verwendet zur Prognose nur jenes Modell, welches in der Vergangenheit am besten performt hat.
Nichtlinearitäten	BART	<i>Bayesian additive regression trees</i> (Hill et al. 2020) – Moderne Methode aus dem sog. Maschinlernen (<i>machine learning</i>), welche in der Prognoseliteratur oft für die Berücksichtigung von Nichtlinearitäten verwendet wird.
	DMA	<i>Dynamic model averaging</i> (Koop & Korobilis 2012) – Mischmodell, ähnlich wie 'BMA', allerdings mittels dynamischen, zeitvariierenden Modellen. Diese zeitvariierenden Modellen passen sich im Zeitverlauf an und reagieren entsprechend auf strukturelle Veränderungen.

4 Prognoseergebnisse

Im folgenden Abschnitt werden die Prognoseergebnisse für die drei zu schätzenden Variablen (d.h. touristische Nächtigungen, Umsatzsteuervoranmeldungen des NACE-Sektors I, reale Bruttowertschöpfung des NACE-Sektors I) zusammengefasst. Dabei werden die angewendeten Prognosemodelle miteinander verglichen und die Prognosegüte anhand verschiedener Parameter evaluiert. Um die Prognosegüte der Modelle objektiv vergleichen zu können, wird ein Prognosehorizont gewählt, für den es bereits realisierte Werte gibt. Somit werden prognostizierte Werte verschiedener Prognosemodelle mit den realisierten Werten verglichen und die Größe der Abweichungen (d.h. die Prognosefehler) evaluiert. Eine größere Differenz zwischen prognostiziertem und realisiertem Wert ist gleichbedeutend mit einem höheren Prognosefehler. Wenn die Prognosewerte eines Modells sehr nahe an den realisierten Werten liegen, zeichnet sich wiederum ein geringer Prognosefehler ab. Prognosemodelle mit geringen Abweichungen (d.h. kleinen Prognosefehlern) erweisen sich damit als geeigneter, um die Schätzvariable treffsicher zu prognostizieren.

4.1 Prognosegüte für die Entwicklung der Nächtigungen

Für die monatliche Prognose der touristischen Nächtigungen erstreckt sich der Prognosehorizont von Jänner 2017 bis Dezember 2019. Damit können die prognostizierten monatlichen Werte verschiedener Modelle mit den realisierten Nächtigungen in diesem Zeitraum verglichen werden. Die folgende Abbildung ([Abbildung 1](#)) vergleicht die prognostizierten (logarithmierten) monatlichen Übernachtungen ausgewählter Modelle mit den (logarithmierten) realisierten Werten. ([Abbildung 2](#)) zeigt dagegen die Prognosegüte anhand der (logarithmierten) Wachstumsraten zum Vorjahreswert. Die schwarz eingefärbte Linie in den [Abbildung 1](#) und [Abbildung 2](#) zeigt dabei die realisierten (logarithmierten) Werte von Jänner 2017 bis Dezember 2019, die bunten Linien die prognostizierten Werte verschiedener Prognosemodelle. Je näher die prognostizierten Werte an den tatsächlichen Nächtigungen ([Abbildung 1](#)) bzw. Wachstumsraten ([Abbildung 2](#)) in diesem Zeitraum liegen, desto höher ist die Prognosegüte. In [Abbildung 1](#) ist vor allem das Problem variabler Feiertage, allen voran Ostern, zu erkennen – trotz Berücksichtigung in den Prognosemodellen. Dies wird zum Beispiel im Jahr 2017 ersichtlich, da es hier zu einer abweichenden Lage der Osterwoche (im April) im Vergleich zu 2016 (im März) gekommen ist, so dass sich eine relativ große Abweichung zwischen prognostizierten und realisierten Werten zeigt. Ähnliches gilt für die Jahre 2018 und 2019.

Abbildung 1: Prognosegüte der Nächtigungen

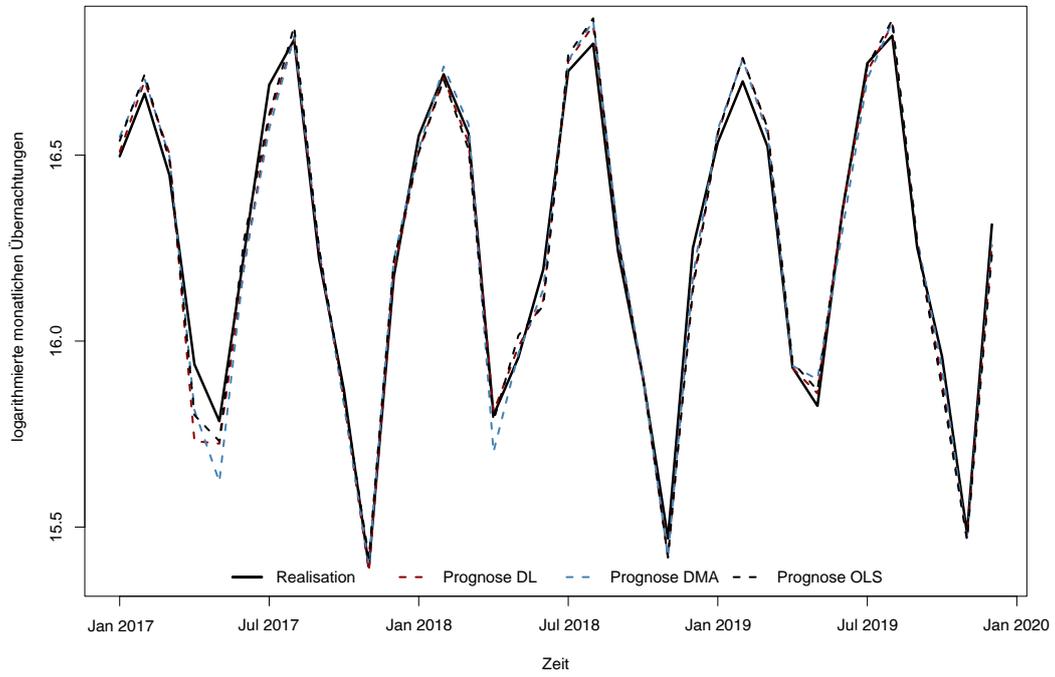


Abbildung 2: Prognosegüte der Nächtigungen in Wachstumsraten

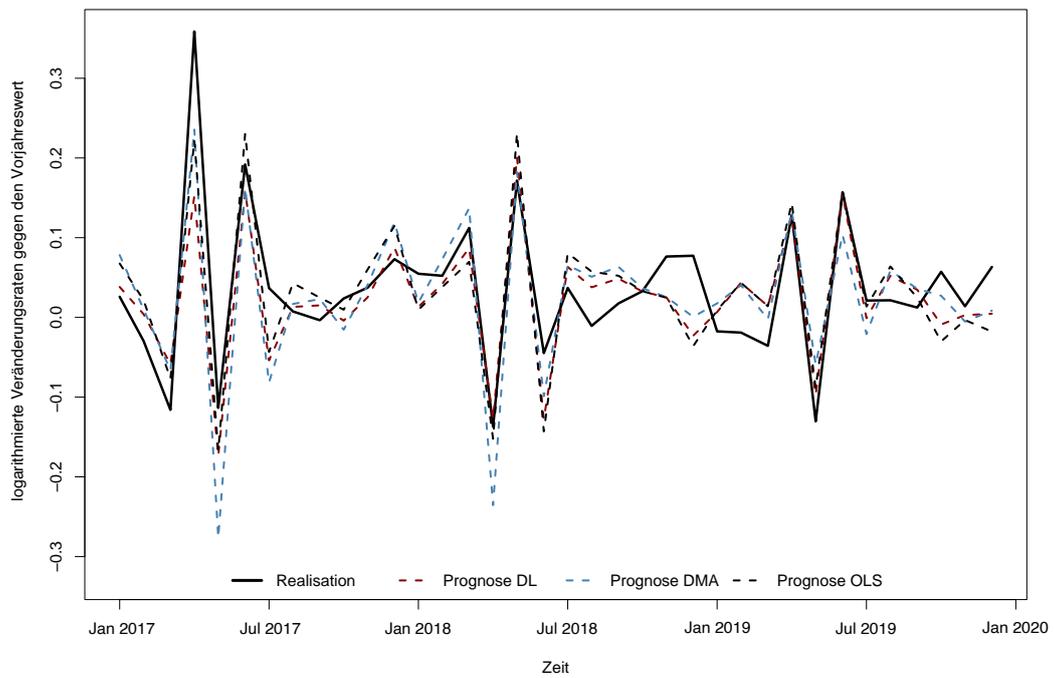


Abbildung 3: Kontrafaktische Prognosefehler für unterschiedliche Schätzansätze – Nüchtigungen

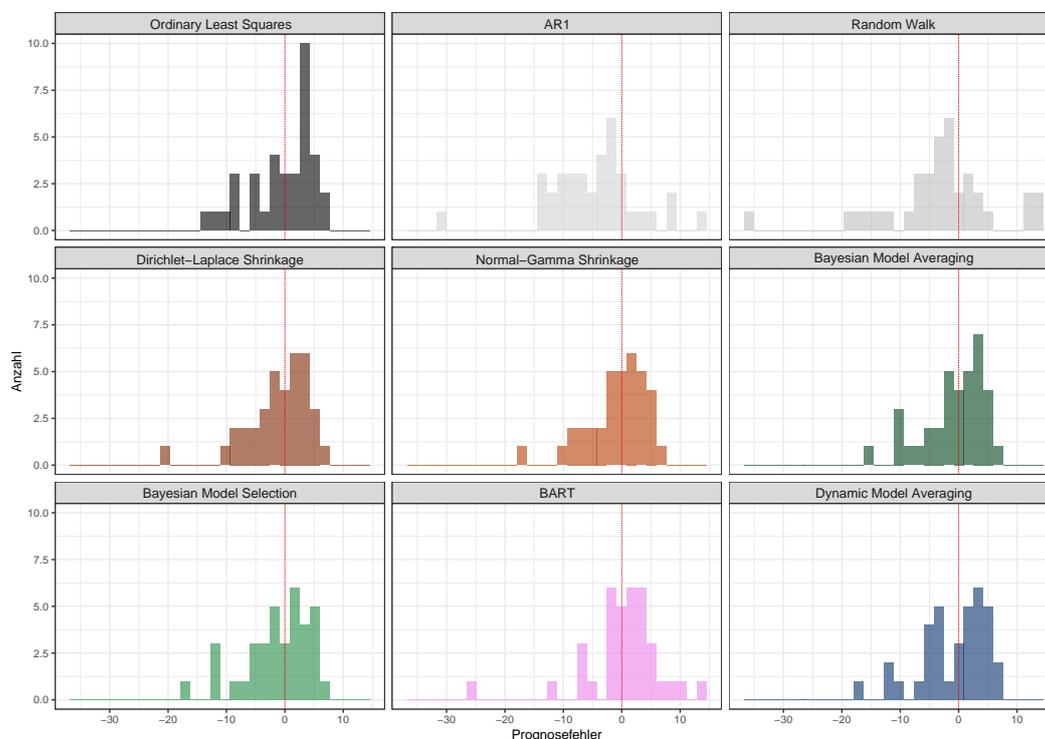


Abbildung 3 stellt die Prognosefehler der unterschiedlichen Schätzansätze in Form von Balkendiagrammen dar. Dabei beschreibt die rote Querlinie einen Prognosefehler von 0 (d.h. keine Abweichung zwischen prognostizierten und realisierten Werten). Eine regelmäßige, glockenförmige Verteilung um die rote Linie deutet auf normalverteilte Prognosefehler hin. Dies weist generell darauf hin, dass keine strukturellen Trends oder Variablen im Prognosemodell ignoriert wurden. Je weiter ein Balken von der roten Linie auf der Horizontalachse entfernt ist, umso größer ist der Prognosefehler für die jeweilige Beobachtung. Die Höhe der Balken gibt an, wie häufig prognostizierte Werte den selben Prognosefehler aufweisen. Anders ausgedrückt bedeutet das, dass ein häufig auftretender Prognosefehlerwert als höherer Balken ersichtlich wird. In allen neun Grafiken zeigt sich eine Gruppierung der Balken um die rote Querlinie mit einem abflachenden Trend auf beide Seiten. Das bedeutet, dass kleine Prognosefehler häufiger auftreten als größere Abweichungen.

Abbildung 4 stellt die kumulierten absoluten bzw. quadrierten Prognosefehler über den gesamten Prognosehorizont in einem Liniendiagramm dar. Jene Modellprognose, die am rechten Rand der jeweiligen Grafik (gilt sowohl bei den absoluten wie auch den quadrierten Prognosefehlern) an oberster Stelle liegt, weist die größten kumulierten Prognosefehler auf. Bei der Analyse mittels absoluter Prognosefehler zählen die absoluten Werte der positiven bzw. negativen Abweichungen gleichermaßen. Durch das Quadrieren werden größere Prognosefehler stärker penalisiert. Diese stärkere Penalisierung lässt sich auch anhand der stärker ausgeprägten Divergenz auf der rechten Grafik zwischen den verschiedenen Prognosemodellen erkennen. Die größten absoluten Prognosefehler zeigen das Random Walk-Modell sowie die AR1-Modellspezifikation. Gemessen an den quadrierten Prognosefehlern weist das BART-Modell zusätzlich zu den beiden genannten Prognosemodellen noch eine wesentlich geringere Prognosegüte auf.

Die folgende Übersicht (Tabelle 2) zeigt die absoluten Prognosefehler unterschiedlicher Modelle über den gesamten Prognosehorizont. Die bedingte Formatierung der Zellen weist größere Prognosefehler in dunklerer Rotschattierung aus. Dünklerer Schattierungen in der Horizontalen zeigen dabei größere Prognosefehler aller Modelle in Bezug auf ein bestimmtes Monat auf (wie zum Beispiel April 2017). Dies ist im vorangegangenen Beispiel des April 2017 trotz Einbeziehung der Feiertage in die Modellspezifikationen auf die Verschiebung von Ostern von März (2016) auf April (2017) zurückzuführen. Andere Ausreißermonate (wie zum Beispiel Dezember 2018) können jedoch nicht durch einen Feiertageffekt erklärt werden. Dünklerer Schattierungen entlang der Vertikalen weisen hingegen auf eine unterdurchschnittliche Performance eines bestimmten Prognosemodells über den Prognosehorizont hin (wie zum Beispiel AR1). Damit können zeitliche Aufreißer bezüglich der Modellgenauigkeit unterschieden werden. Eine größere Anzahl an weißen Zellen verdeutlicht dabei eine höhere Prognosegüte. Am Ende der Tabelle werden zudem die durchschnittlichen absoluten Prognosefehler der einzelnen Prognosemodelle über den Prognosehorizont sowie die Standardabweichung der Prognosefehler ausgewiesen. Mit Hilfe der farbigen Markierungen lassen sich die verschiedenen Modellspezifikationen miteinander vergleichen. So zeigen grüne Markierungen kleine Werte, rote Markierungen weisen hingegen auf größere absolute Prognosefehler bzw. eine höhere Schwankung dieser Prognosefehler hin. Beide Indikatoren sind wesentlich, um die Modelle miteinander vergleichen zu können, da ein kleiner durchschnittlicher Prognosefehler gleichbedeutend mit einer hohen Prognosegüte ist und eine geringe Schwankung dieser Fehler auf eine konsistente Prognoseperformance hinweist. Anhand beider Indikatoren lassen sich die Modelle in Bezug auf ihre Prognosefähigkeit der monatlichen Nüchtigungen beurteilen. Die geringsten durchschnittlichen Prognosefehler zeigen die zwei getesteten Shrinkage-Modelle (Dirichlet Laplace Shrinkage und Normal Gamma Shrinkage). Das AR1- sowie das Random Walk-Modell weisen nicht nur die größten durchschnittlichen absoluten Prognosefehler auf, sondern auch die größte Schwankung in der Modelperformance.

Abbildung 4: Kumulierte absolute und quadrierte Prognosefehler über die Zeit – Nachtigungen

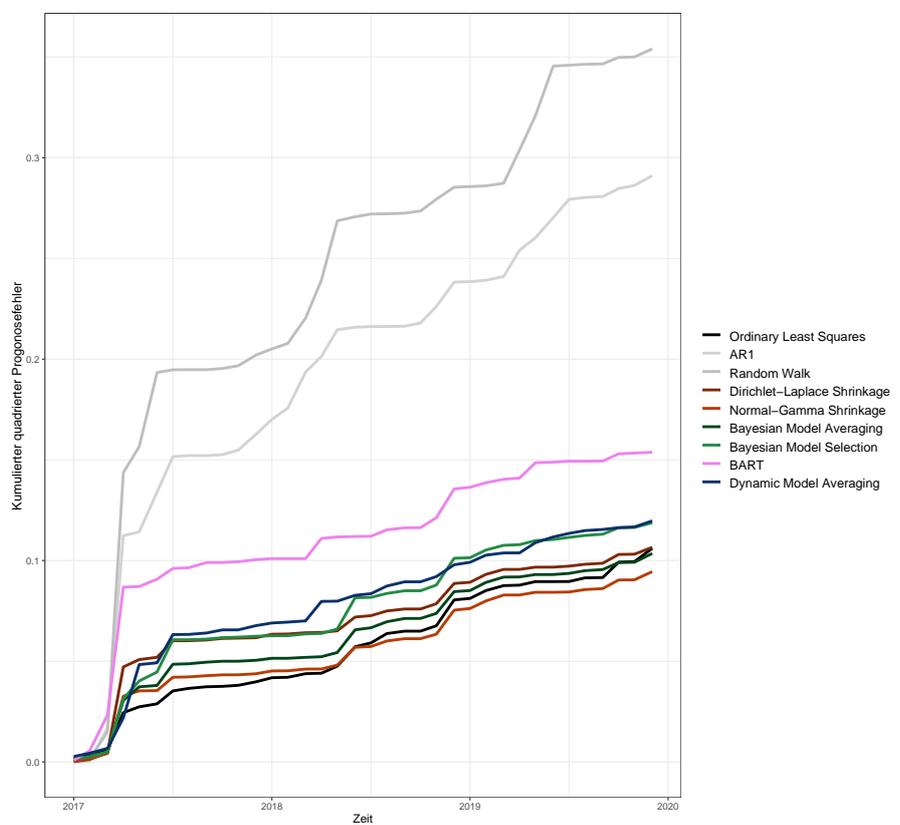
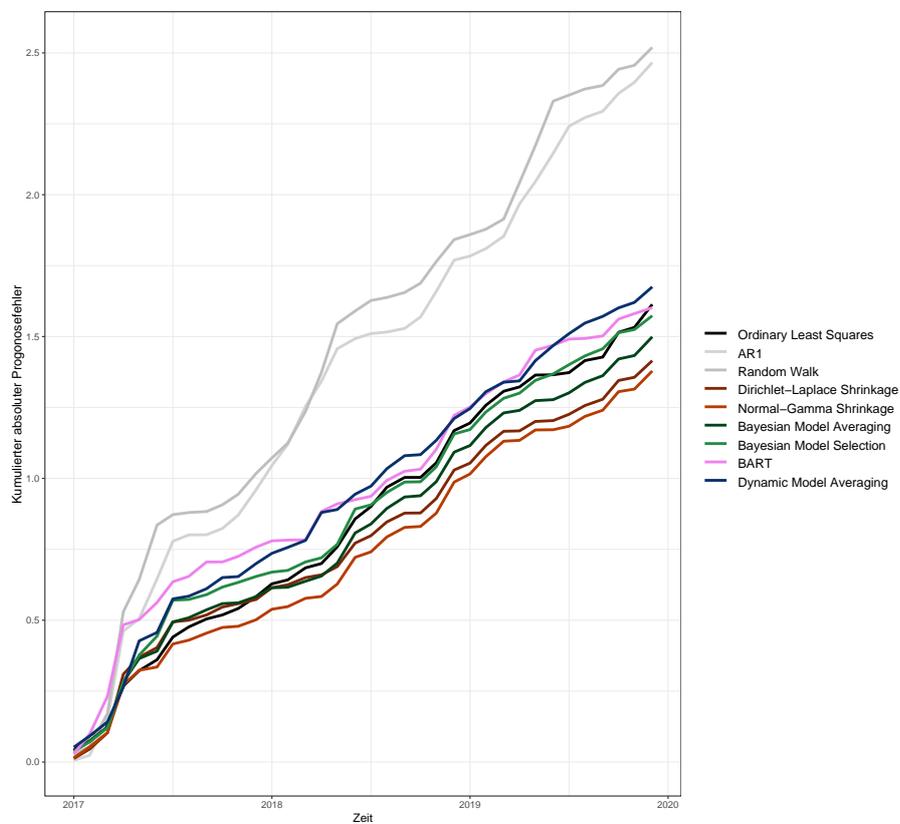


Tabelle 2: Absolute Prognosefehler über die Zeit und Modellspezifikationen –
Nächtigungen

Absolute Prognosefehler	OLS	ARI	Random Walk	Dirichlet Laplace Shrinkage	Normal Gamma Shrinkage	Bayesian Model Averaging	Bayesian Model Selection	BART	Dynamic Model Averaging
Jan 2017	0,042	0,005	0,026	0,018	0,016	0,039	0,037	0,030	0,052
Feb 2017	0,051	0,018	0,029	0,033	0,039	0,037	0,034	0,066	0,040
Mrz 2017	0,039	0,129	0,116	0,052	0,047	0,048	0,050	0,138	0,050
Apr 2017	0,136	0,307	0,359	0,189	0,178	0,159	0,163	0,253	0,123
Mai 2017	0,054	0,046	0,114	0,039	0,055	0,080	0,094	0,021	0,163
Jun 2017	0,038	0,140	0,192	0,042	0,010	0,025	0,067	0,057	0,030
Jul 2017	0,080	0,131	0,037	0,096	0,088	0,105	0,127	0,075	0,118
Aug 2017	0,036	0,023	0,007	0,005	0,012	0,014	0,003	0,020	0,009
Sep 2017	0,028	0,000	0,004	0,021	0,023	0,027	0,017	0,055	0,026
Okt 2017	0,014	0,022	0,024	0,025	0,019	0,021	0,027	0,002	0,039
Nov 2017	0,023	0,048	0,037	0,009	0,005	0,003	0,017	0,018	0,003
Dez 2017	0,042	0,089	0,073	0,012	0,027	0,022	0,021	0,034	0,046
Jan 2018	0,045	0,086	0,055	0,038	0,037	0,032	0,015	0,024	0,036
Feb 2018	0,014	0,075	0,052	0,009	0,009	0,002	0,006	0,002	0,021
Mrz 2018	0,043	0,134	0,112	0,021	0,025	0,022	0,030	0,003	0,025
Apr 2018	0,015	0,091	0,137	0,026	0,001	0,016	0,015	0,100	0,098
Mai 2018	0,059	0,116	0,172	0,036	0,044	0,045	0,048	0,029	0,010
Jun 2018	0,098	0,034	0,045	0,096	0,102	0,107	0,124	0,019	0,054
Jul 2018	0,044	0,017	0,037	0,017	0,022	0,034	0,014	0,016	0,028
Aug 2018	0,068	0,005	0,011	0,046	0,052	0,056	0,044	0,053	0,062
Sep 2018	0,035	0,013	0,018	0,030	0,036	0,040	0,037	0,032	0,046
Okt 2018	0,000	0,041	0,033	0,004	0,005	0,005	0,001	0,006	0,004
Nov 2018	0,052	0,091	0,076	0,051	0,048	0,049	0,053	0,069	0,051
Dez 2018	0,113	0,107	0,077	0,106	0,107	0,104	0,115	0,119	0,077
Jan 2019	0,027	0,016	0,018	0,025	0,029	0,024	0,016	0,030	0,035
Feb 2019	0,062	0,027	0,019	0,058	0,062	0,064	0,062	0,046	0,059
Mrz 2019	0,050	0,043	0,036	0,050	0,053	0,052	0,048	0,044	0,033
Apr 2019	0,015	0,114	0,129	0,012	0,008	0,009	0,018	0,021	0,005
Mai 2019	0,042	0,076	0,130	0,034	0,035	0,035	0,045	0,085	0,071
Jun 2019	0,001	0,097	0,157	0,008	0,002	0,004	0,023	0,014	0,053
Jul 2019	0,008	0,095	0,021	0,021	0,018	0,023	0,033	0,019	0,042
Aug 2019	0,042	0,031	0,021	0,036	0,038	0,037	0,031	0,002	0,037
Sep 2019	0,012	0,022	0,012	0,021	0,019	0,023	0,025	0,005	0,024
Okt 2019	0,087	0,063	0,057	0,057	0,067	0,063	0,057	0,060	0,030
Nov 2019	0,017	0,040	0,014	0,011	0,007	0,012	0,011	0,016	0,019
Dez 2019	0,081	0,070	0,063	0,056	0,066	0,064	0,049	0,018	0,055
Durchschnitt	0,045	0,068	0,070	0,039	0,039	0,042	0,044	0,045	0,047
Standardabweichung	0,031	0,058	0,070	0,035	0,036	0,034	0,037	0,048	0,034

4.2 Prognosegüte für die Entwicklung der Umsatzsteuervoranmeldung

Für die monatliche Prognose der Umsatzsteuervoranmeldung des NACE-Sektors I erstreckt sich der Prognosehorizont ebenfalls von Jänner 2017 bis Dezember 2019. Wie eingangs erwähnt, können die Umsatzsteuervoranmeldungen des steuerpflichtigen Umsatzes als Schätzdindikator für die unbeobachtbaren Umsätze der Unternehmen in der Beherbergung und Gastronomie angenommen werden.

Die folgenden Abbildungen ([Abbildung 5](#) und [Abbildung 6](#)) vergleichen die prognostizierten (logarithmierten) monatlichen Umsatzsteuervoranmeldungen bzw. die (logarithmierten) Wachstumsraten zum jeweiligen Vorjahreswert ausgewählter Modelle mit den realisierten Werten. Die Prognosegüte lässt sich in beiden Abbildungen mittels Abweichung zwischen der schwarz eingefärbten Linie (realisierte Werte) und den farbigen Linien (prognostizierte Werte) evaluieren. Je weiter eine farbige Linie von der schwarzen Linie entfernt ist, umso größer ist der Prognosefehler des jeweiligen Prognosemodells. Gleichzeitig bedeuten große Divergenzen zwischen prognostizierten und realisierten Werten eine geringe Prognosegüte.

Abbildung 5: Prognosegüte der Umsatzsteuervoranmeldungen

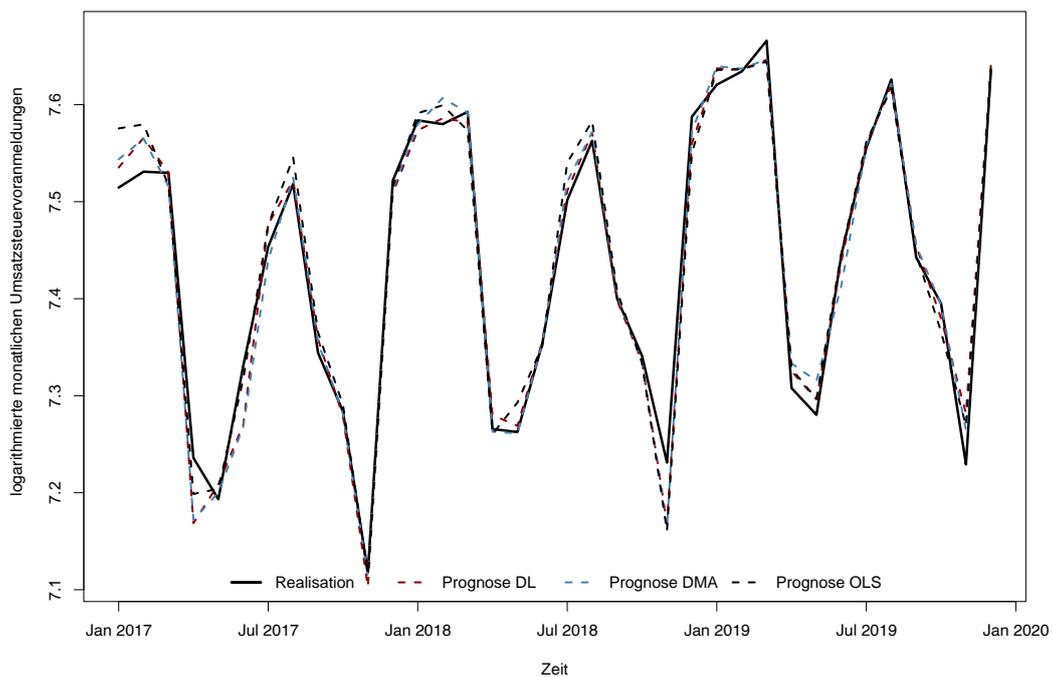


Abbildung 6: Prognosegüte der Umsatzsteuervoranmeldungen in Wachstumsraten

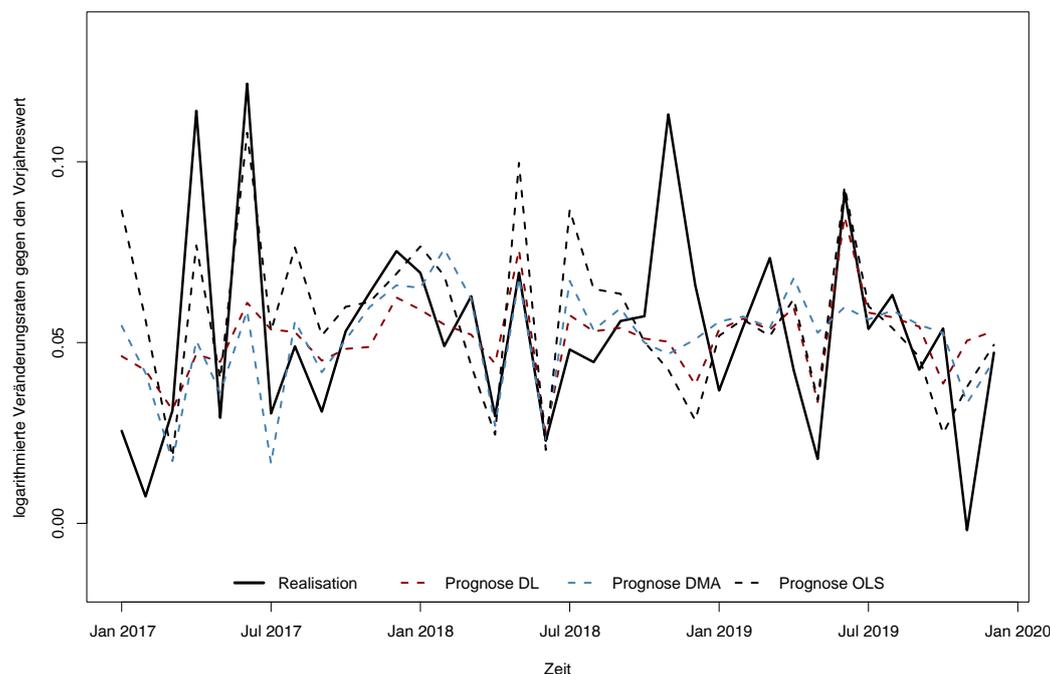


Abbildung 7 stellt die Prognosefehler der unterschiedlichen Schätzansätze in Balkendiagrammen dar. Dabei beschreibt die rote Querlinie einen Prognosefehler von 0 (d.h. keine Abweichung zwischen prognostizierten und realisierten Werten). Eine regelmäßige, glockenförmige Verteilung um die rote Linie deutet auf normalverteilte Prognosefehler hin. Dies bedeutet, dass keine strukturellen Trends oder Variablen im Prognosemodell ignoriert wurden. In sieben von neun Grafiken zeigt sich eine Gruppierung der Balken um die rote Querlinie mit einem abflachenden Trend auf beide Seiten. Das impliziert, dass kleine Prognosefehler häufiger auftreten als größere Abweichungen. Das Random Walk-Modell hingegen zeigt eine Häufung der Balken unter der roten Querlinie, was darauf hindeutet, dass dieses Prognosemodell generell unterschätzte Werte ausweist. Auch beim AR1-Modell zeigt sich keine glockenförmig Kurve der Balken, sondern eine Häufung der Balken ober- sowie unterhalb roten Querlinie. Daraus kann geschlossen werden, dass das AR1- und das Random Walk-Modell in Bezug auf die Prognose der Umsatzsteuervoranmeldungen besonders schlecht performen.

Abbildung 7: Kontrafaktische Prognosefehler für unterschiedliche Schätzansätze – Umsatzsteuervoranmeldungen

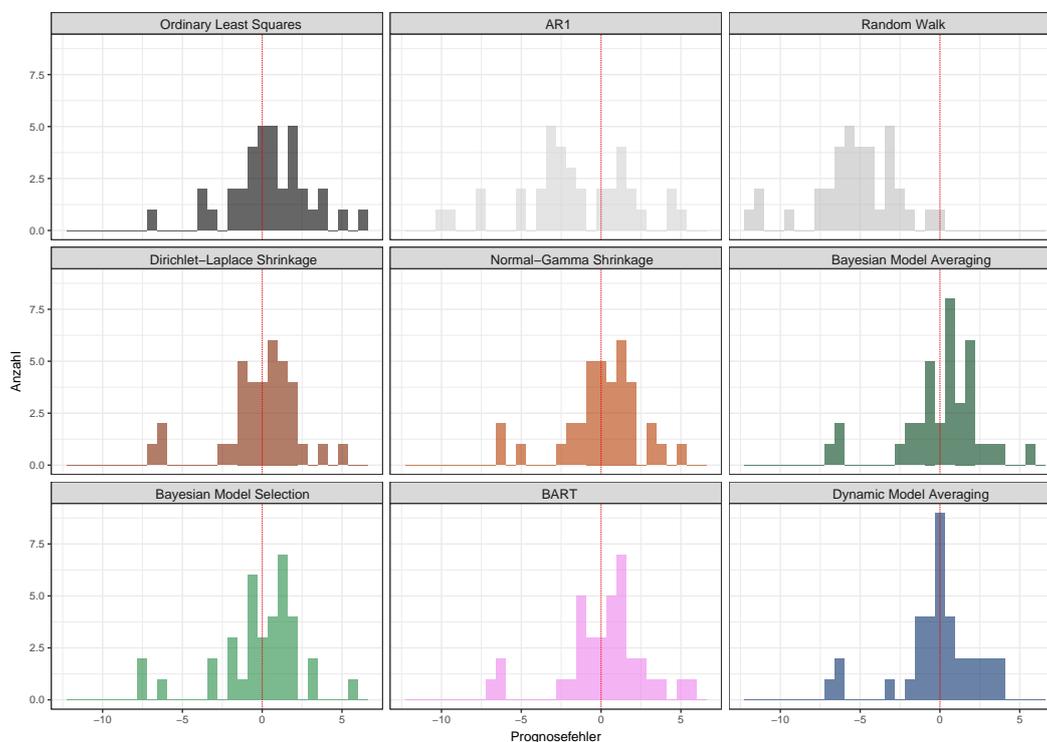
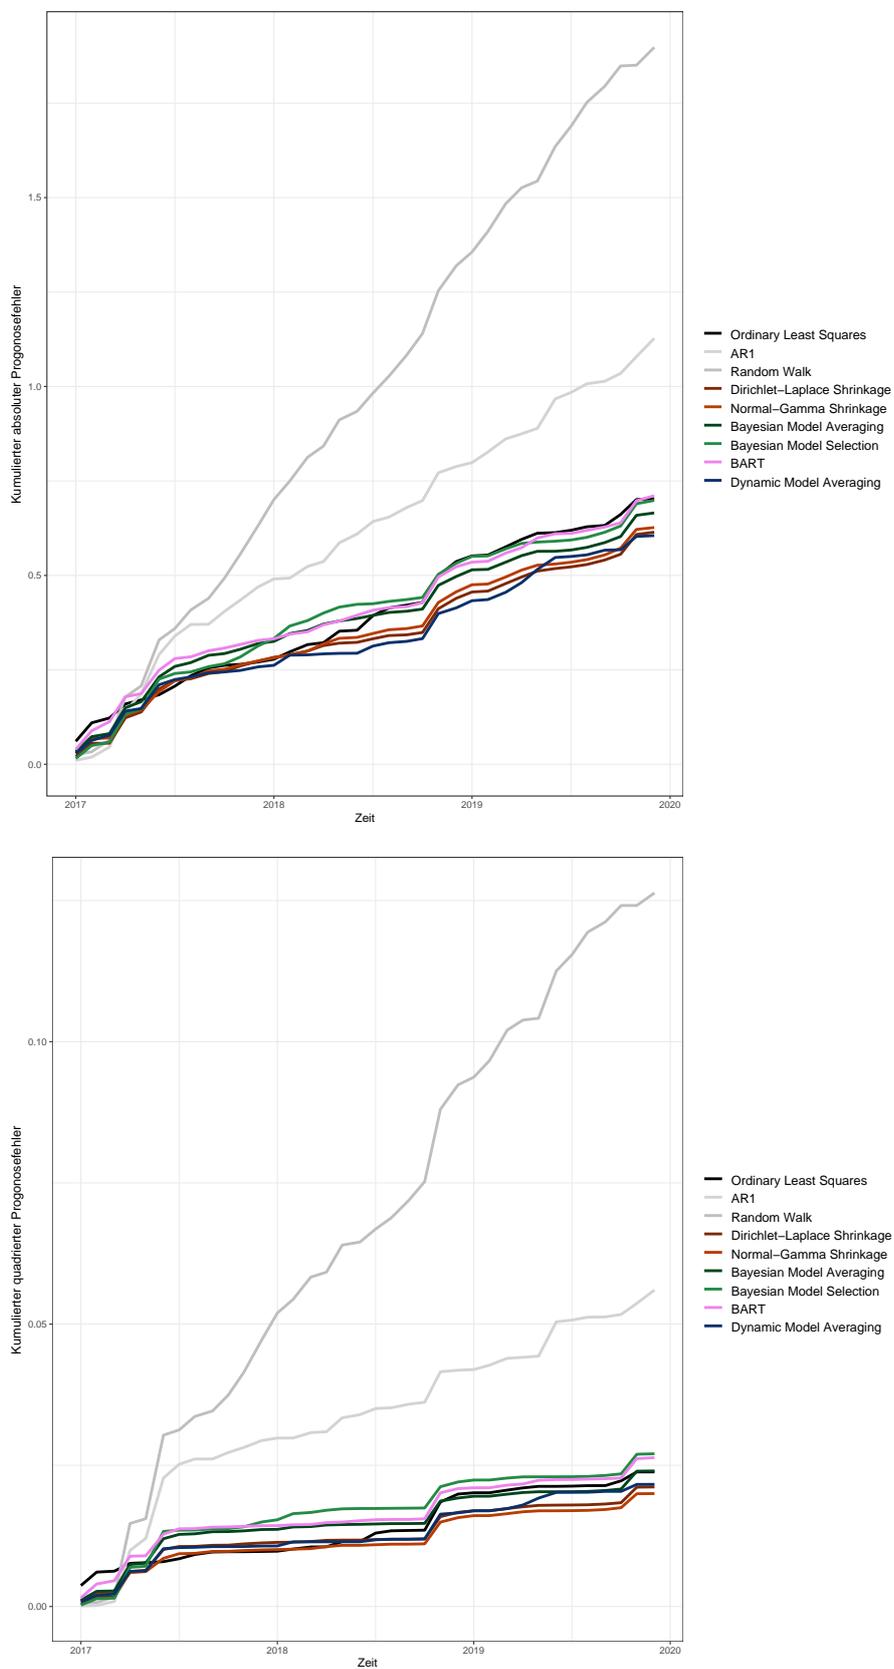


Abbildung 8 stellt die kumulierten absoluten bzw. quadrierten Prognosefehler über den gesamten Prognosehorizont in einem Liniendiagramm dar. Jene Modellprognose, die am rechten Rand der jeweiligen Grafik (gilt sowohl bei den absoluten, wie auch den quadrierten Prognosefehlern) an oberster Stelle liegt, weist die größten kumulierten Prognosefehler auf. Gemessen sowohl an den absoluten wie auch den quadrierten Prognosefehlern zeigt die Abbildung 8 klar die wesentlich geringere Prognosegüte des Random Walk-Modells auf, gefolgt von der AR1-Spezifikation.

Abbildung 8: Kumulierte absolute und quadrierte Prognosefehler über die Zeit – Umsatzsteuervoranmeldungen



Nachdem [Abbildung 8](#) aufgrund der überproportionalen Prognosefehler der prognostizierten Werte des Random Walk- und AR1-Modells schwierig zu interpretieren ist, soll die folgende Tabelle mehr Klarheit schaffen ([Tabelle 3](#)). Sie illustriert die absoluten Prognosefehler unterschiedlicher Modelle über den gesamten Prognosehorizont. Die bedingte Formatierung der Zellen weist größere Prognosefehler in dunklerer Rotschattierung aus. Dünkler Schattierungen in der Horizontalen sind gleichbedeutend mit größeren Prognosefehlern aller Modelle in Bezug auf ein bestimmtes Monat (wie zum Beispiel Juni 2017 oder November 2018). Einzelne 'Ausreißermonate' (wie zum Beispiel der April 2017) können trotz Einbeziehung der jährlich variablen Feiertage in den Modellspezifikationen nicht zufriedenstellend erklärt werden. Dünkler Schattierungen entlang der Vertikalen weisen hingegen auf eine unterdurchschnittliche Performance eines bestimmtes Prognosemodells über den Prognosehorizont hin (allen voran im Random Walk-Modell ersichtlich). Anhand der farbigen Markierung am Ende der Tabelle in Bezug auf den durchschnittlichen absoluten Prognosefehler und der Standardabweichung lassen sich die verschiedenen Modellspezifikationen miteinander vergleichen. So zeigen grüne Markierungen kleinere Werte, rote Markierungen weisen hingegen auf größere Fehler bzw. eine höhere Schwankung der Prognosefehler hin. Beide Indikatoren sind wesentlich, um die Modelle miteinander vergleichen zu können, da ein kleiner durchschnittlicher Prognosefehler eine hohe Prognosegüte impliziert und eine geringe Schwankung dieser Fehler auf eine konsistente Prognoseperformance hinweist.

Anhand beider Indikatoren lässt sich ablesen, dass die zwei getesteten Shrinkage-Modelle (Dirichlet Laplace Shrinkage und Normal Gamma Shrinkage) für die Prognose der Umsatzsteuervoranmeldungen des Sektors I am besten abschneiden. Das Dynamic Model Averaging und das Bayesian Model Averaging schlagen sich im Vergleich dazu ebenfalls relativ gut. Eindeutig am schlechtesten schneidet im Modellvergleich das Random Walk-Modell ab (gemessen sowohl am durchschnittlichen Prognosefehler als auch auf Basis der Standardabweichung).

Tabelle 3: Absolute Prognosefehler über die Zeit und Modellspezifikationen –
Umsatzvoranmeldungen

Absolute Prognosefehler	OLS	ARI	Random Walk	Dirichlet Laplace Shrinkage	Normal Gamma Shrinkage	Bayesian Model Averaging	Bayesian Model Selection	BART	Dynamic Model Averaging
Jan 2017	0,061	0,011	0,026	0,024	0,026	0,035	0,015	0,040	0,029
Feb 2017	0,049	0,008	0,007	0,035	0,039	0,039	0,034	0,049	0,034
Mrz 2017	0,013	0,027	0,031	0,002	0,001	0,009	0,010	0,024	0,014
Apr 2017	0,037	0,096	0,114	0,065	0,058	0,068	0,074	0,066	0,064
Mai 2017	0,011	0,046	0,029	0,011	0,011	0,017	0,014	0,007	0,007
Jun 2017	0,014	0,103	0,122	0,056	0,048	0,066	0,079	0,061	0,063
Jul 2017	0,023	0,050	0,030	0,025	0,027	0,028	0,015	0,030	0,014
Aug 2017	0,027	0,030	0,049	0,002	0,007	0,009	0,004	0,004	0,007
Sep 2017	0,021	0,001	0,031	0,014	0,016	0,019	0,014	0,016	0,011
Okt 2017	0,007	0,034	0,053	0,007	0,004	0,002	0,008	0,008	0,002
Nov 2017	0,003	0,030	0,064	0,011	0,010	0,011	0,018	0,008	0,004
Dez 2017	0,006	0,036	0,075	0,019	0,013	0,015	0,029	0,011	0,009
Jan 2018	0,007	0,022	0,069	0,014	0,012	0,000	0,020	0,005	0,004
Feb 2018	0,019	0,004	0,049	0,006	0,013	0,016	0,033	0,012	0,027
Mrz 2018	0,019	0,030	0,063	0,010	0,009	0,009	0,014	0,005	0,001
Apr 2018	0,005	0,012	0,030	0,018	0,013	0,017	0,020	0,018	0,003
Mai 2018	0,030	0,049	0,069	0,010	0,018	0,010	0,016	0,011	0,001
Jun 2018	0,003	0,023	0,023	0,006	0,001	0,006	0,007	0,016	0,000
Jul 2018	0,039	0,033	0,048	0,010	0,010	0,011	0,002	0,013	0,019
Aug 2018	0,020	0,011	0,045	0,009	0,009	0,008	0,006	0,007	0,009
Sep 2018	0,008	0,026	0,056	0,003	0,001	0,002	0,005	0,003	0,004
Okt 2018	0,007	0,018	0,057	0,006	0,005	0,005	0,006	0,010	0,007
Nov 2018	0,071	0,073	0,113	0,064	0,062	0,063	0,061	0,069	0,066
Dez 2018	0,037	0,018	0,066	0,026	0,028	0,022	0,029	0,027	0,015
Jan 2019	0,015	0,011	0,037	0,017	0,018	0,017	0,018	0,012	0,019
Feb 2019	0,002	0,028	0,054	0,003	0,002	0,001	0,001	0,003	0,003
Mrz 2019	0,022	0,034	0,073	0,019	0,019	0,019	0,019	0,022	0,019
Apr 2019	0,020	0,014	0,042	0,018	0,018	0,018	0,015	0,014	0,026
Mai 2019	0,016	0,014	0,018	0,020	0,012	0,011	0,003	0,027	0,035
Jun 2019	0,002	0,078	0,092	0,009	0,002	0,001	0,002	0,012	0,032
Jul 2019	0,006	0,017	0,054	0,004	0,005	0,003	0,003	0,000	0,003
Aug 2019	0,009	0,023	0,063	0,007	0,007	0,007	0,007	0,008	0,004
Sep 2019	0,004	0,005	0,042	0,011	0,012	0,013	0,013	0,008	0,012
Okt 2019	0,029	0,021	0,054	0,014	0,016	0,016	0,017	0,011	0,001
Nov 2019	0,040	0,043	0,002	0,051	0,053	0,056	0,059	0,058	0,035
Dez 2019	0,002	0,049	0,047	0,005	0,005	0,006	0,009	0,013	0,002
Durchschnitt	0,020	0,031	0,053	0,018	0,017	0,018	0,019	0,020	0,017
Standardabweichung	0,017	0,024	0,027	0,017	0,016	0,018	0,019	0,019	0,018

4.3 Prognosegüte für die Entwicklung der realen Bruttowertschöpfung

Abweichend von den vorherigen Kenngrößen (Nächtigungen und Umsatzsteuervoranmeldungen) werden Daten zur realen Bruttowertschöpfung von Statistik Austria lediglich auf Quartalsbasis ausgewiesen. Für die Prognose dieser Variable zum NACE-Sektor I erstreckt sich der Prognosezeitraum damit vom I. Quartal 2010 bis zum IV. Quartal 2019. Die folgenden Abbildungen ([Abbildung 9](#) und [Abbildung 10](#)) vergleichen die prognostizierte (logarithmierte) reale Bruttowertschöpfung in Beherbergung und Gastro bzw. die diesbezüglichen (logarithmierten) Wachstumsraten zum jeweiligen Vorjahreswert ausgewählter Modelle mit den entsprechenden realisierten Werten. Die Prognosegüte lässt sich in beiden Abbildungen mittels Abweichung zwischen der schwarz eingefärbten Linie (realisierte Werte) und den farbigen Linien (prognostizierte Werte) evaluieren. [Abbildung 9](#) zeigt bis auf wenige Ausnahmen (wie z.B. III. Quartal 2011 oder I. Quartal 2014) eine relativ hohe Prognosegüte der ausgewählten Prognosespezifikationen.

Abbildung 9: Prognosegüte der realen Bruttowertschöpfung

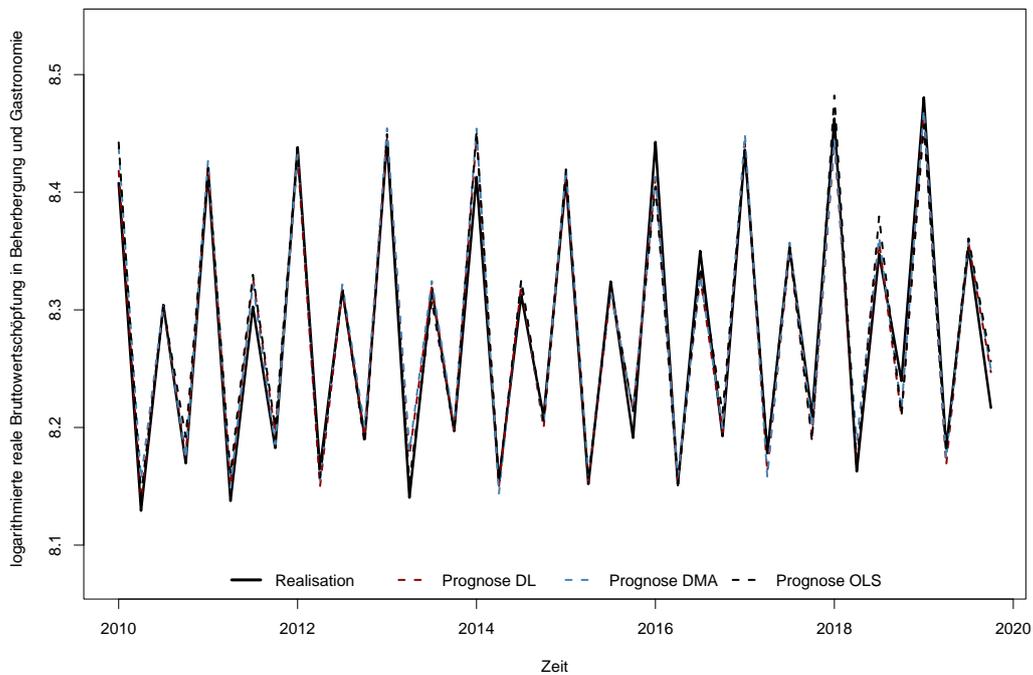


Abbildung 10: Prognosegüte der realen Bruttowertschöpfung in Wachstumsraten

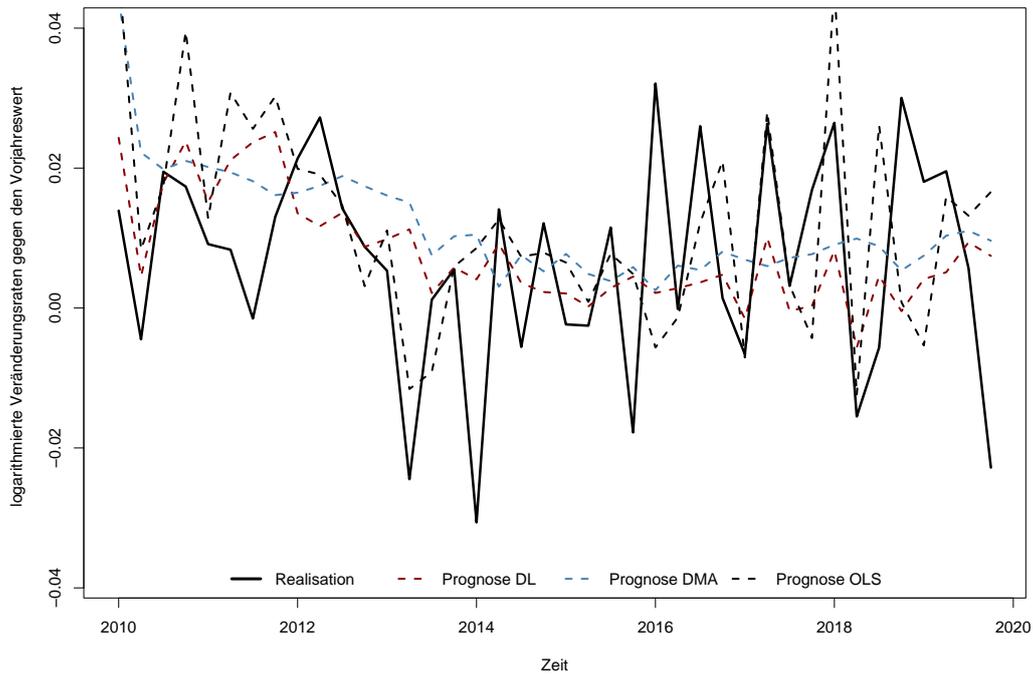


Abbildung 11 stellt die Prognosefehler der unterschiedlichen Schätzansätze in Balkendiagrammen dar. Dabei beschreibt die rote Querlinie einen Prognosefehler von 0 (d.h. keine Abweichung zwischen prognostizierten und realisierten Werten). In sechs von neun Grafiken zeigt sich eine glockenförmige Gruppierung der Balken um die rote Querlinie mit einem abflachenden Trend auf beide Seiten. Das bedeutet, dass kleine Prognosefehler häufiger auftreten als größere Abweichungen. Das AR1-Modell weist zwar auch annähernd eine Normalverteilung der Prognosefehler um 0 auf, jedoch ist der abnehmende Trend nach außen hin weniger ausgeprägt. Das Random Walk-Modell hingegen zeigt vor allem im negativen Bereich eine Häufung der jeweiligen Fehlerwerte. Dies deutet darauf hin, dass die prognostizierten Werte dieses Modells die 'wahren' Werte unterschätzen. Auch beim BART-Modell zeigt sich keine glockenförmig Kurve der Prognosefehlerbalken, sondern eine Häufung der Balken ober- sowie unterhalb der roten Querlinie (Prognosefehler = 0).

Abbildung 11: Kontrafaktische Prognosefehler für unterschiedliche Schätzansätze – reale Bruttowertschöpfung

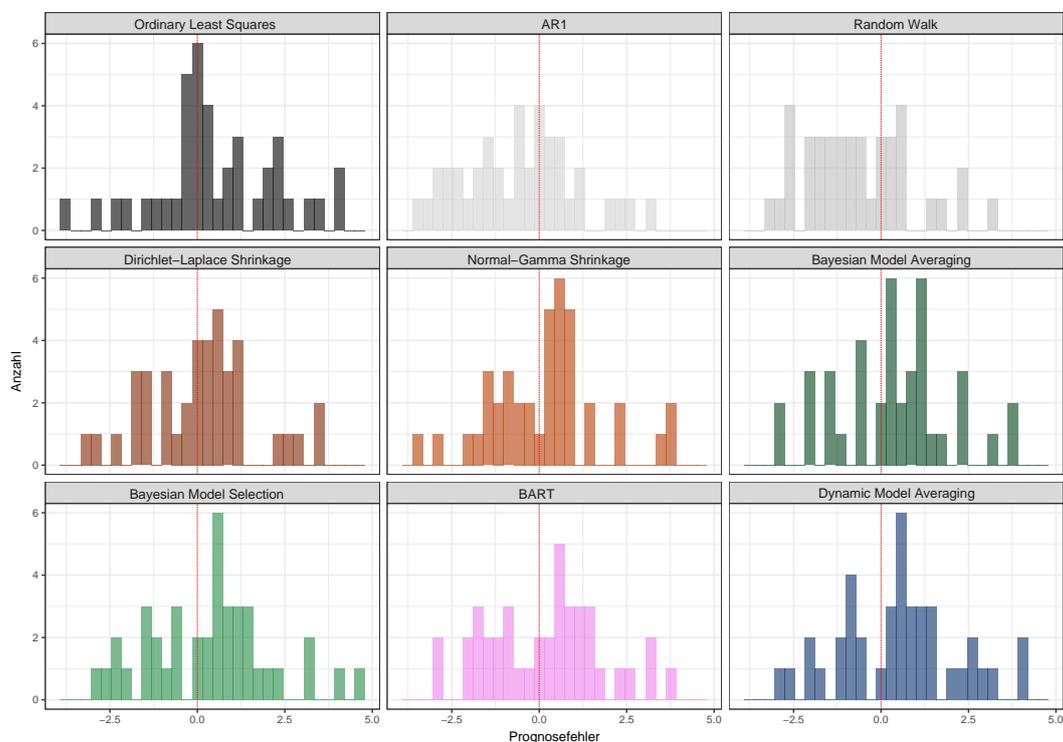


Abbildung 12 und Abbildung 13 stellen die kumulierten absoluten bzw. quadrierten Prognosefehler über den gesamten Prognosehorizont in einem Liniendiagramm dar. Im Vergleich zur Prognosegüte der verschiedenen Modelle für die Prognosen der Nüchtigungen und Umsatzsteuervoranmeldungen lässt sich anhand der Grafiken der kumulierten Prognosefehler bei der realen Bruttowertschöpfung kein Modell identifizieren, das deutlich schlechter abscheidet. Trotzdem lässt sich an dem Liniendiagramm erkennen, dass die zwei Bayesian-Modelle, das Dynamic Model Averaging und das OLS-Modell, die größten kumulierten Prognosefehler aufweisen. In Bezug auf die prognostizierte reale Bruttowertschöpfung performen die Shrinkage-Modelle am besten.

Abbildung 12: Kumulierter absolute Prognosefehler über die Zeit – reale Bruttowertschöpfung

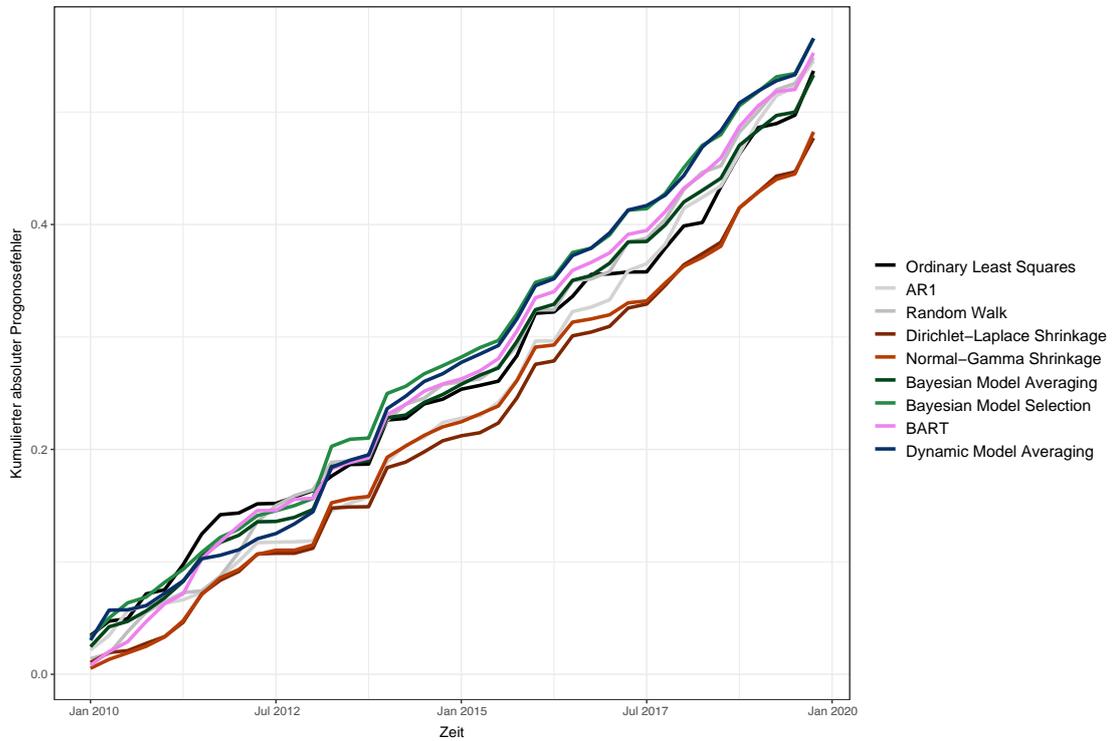
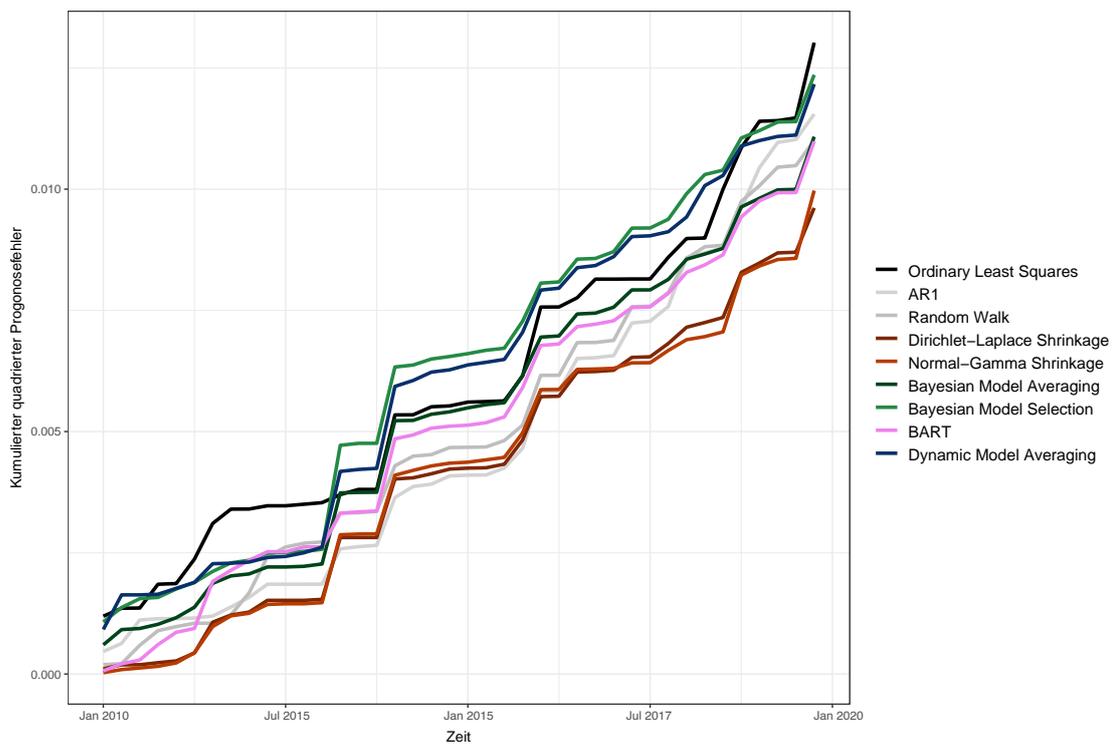


Abbildung 13: Kumulierter quadrierte Prognosefehler über die Zeit – reale Bruttowertschöpfung



Die folgende Tabelle (Tabelle 4) beinhaltet die absoluten Prognosefehler unterschiedlicher Modelle über den gesamten Prognosehorizont. Die bedingte Formatierung der Zellen weist größere Prognosefehler in dunklerer Rotschattierung aus. Dünkler Schattierungen in der Horizontalen zeigen dabei größere Prognosefehler aller Modelle in Bezug auf ein bestimmtes Quartal (wie zum Beispiel I. Quartal 2014 oder IV. Quartal 2019). Dünkler Schattierungen entlang der Vertikalen (wie z.B. beim Dynamic Model Averaging) weisen hingegen auf eine unterdurchschnittliche Performance eines bestimmten Prognosemodells über den Prognosehorizont hin. Damit können zeitliche Ausreißer hinsichtlich der Modellgenauigkeit unterschieden werden. Eine größere Anzahl an weißen Zellen illustriert dabei eine höhere Prognosegüte. Anhand der farbigen Markierung am Ende der Tabelle in Bezug auf den durchschnittlichen absoluten Prognosefehler und die Standardabweichung lassen sich die verschiedenen Modellspezifikationen einander gegenüberstellen. So zeigen grüne Markierungen kleine durchschnittliche Prognosefehler sowie eine geringere Schwankungsbreite der Prognosefehler an. Rote Markierungen weisen hingegen auf größere Fehler bzw. eine höhere Schwankung der Prognosefehler hin. Beide Indikatoren sind wesentlich, um die Modelle miteinander vergleichen zu können, da ein kleiner durchschnittlicher Prognosefehler gleichbedeutend mit einer hohen Prognosegüte ist und eine geringe Standardabweichung auf eine konsistente Prognoseperformance hinweist. Anhand beider Indikatoren lässt sich ablesen, dass die zwei getesteten Shrinkage-Modelle (Dirichlet Laplace Shrinkage und Normal Gamma Shrinkage) für die Prognose der realen Bruttowertschöpfung des Sektors I am besten abschneiden. Das Dynamic Model Averaging und die Bayesian Model Selection weisen die größten durchschnittlichen Prognosefehler auf, das OLS-Modell hingegen die größten Schwankungen in der Prognosegüte.

Tabelle 4: Absolute Prognosefehler über die Zeit und Modellspezifikationen – reale Bruttowertschöpfung

Absolute Prognosefehler	OLS	AR1	Random Walk	Dirichlet Laplace Shrinkage	Normal Gamma Shrinkage	Bayesian Model Averaging	Bayesian Model Selection	BART	Dynamic Model Averaging
1Q2010	0,035	0,022	0,014	0,006	0,006	0,025	0,033	0,007	0,030
2Q2010	0,013	0,013	0,004	0,011	0,004	0,017	0,017	0,011	0,027
3Q2010	0,002	0,022	0,019	0,006	0,001	0,002	0,014	0,009	0,000
4Q2010	0,022	0,006	0,017	0,005	0,006	0,009	0,005	0,017	0,004
1Q2011	0,004	0,001	0,009	0,008	0,007	0,011	0,013	0,016	0,011
2Q2011	0,022	0,003	0,008	0,012	0,013	0,015	0,012	0,009	0,011
3Q2011	0,027	0,006	0,002	0,024	0,026	0,022	0,015	0,030	0,020
4Q2011	0,017	0,014	0,013	0,012	0,012	0,013	0,013	0,014	0,003
1Q2012	0,001	0,014	0,021	0,010	0,008	0,006	0,007	0,015	0,005
2Q2012	0,008	0,016	0,027	0,015	0,012	0,012	0,012	0,013	0,010
3Q2012	0,000	0,001	0,014	0,001	0,003	0,002	0,004	0,000	0,005
4Q2012	0,006	0,001	0,009	0,001	0,000	0,004	0,005	0,010	0,009
1Q2013	0,006	0,000	0,005	0,005	0,007	0,007	0,006	0,001	0,011
2Q2013	0,013	0,027	0,024	0,036	0,038	0,036	0,046	0,027	0,040
3Q2013	0,010	0,007	0,001	0,001	0,004	0,003	0,006	0,005	0,006
4Q2013	0,000	0,005	0,006	0,000	0,001	0,002	0,001	0,004	0,005
1Q2014	0,039	0,031	0,031	0,036	0,035	0,039	0,040	0,039	0,041
2Q2014	0,001	0,013	0,014	0,009	0,009	0,002	0,006	0,010	0,011
3Q2014	0,013	0,007	0,006	0,010	0,009	0,011	0,011	0,012	0,013
4Q2014	0,004	0,013	0,012	0,009	0,009	0,007	0,007	0,006	0,007
1Q2015	0,009	0,004	0,002	0,005	0,004	0,008	0,008	0,005	0,010
2Q2015	0,003	0,002	0,003	0,004	0,007	0,008	0,008	0,007	0,007
3Q2015	0,004	0,012	0,012	0,008	0,007	0,006	0,006	0,011	0,008
4Q2015	0,023	0,020	0,018	0,022	0,022	0,024	0,024	0,025	0,024
1Q2016	0,038	0,035	0,032	0,031	0,030	0,028	0,028	0,030	0,030
2Q2016	0,001	0,001	0,000	0,001	0,003	0,005	0,005	0,005	0,006
3Q2016	0,014	0,026	0,026	0,022	0,018	0,021	0,022	0,019	0,021
4Q2016	0,020	0,003	0,001	0,003	0,006	0,004	0,004	0,007	0,007
1Q2017	0,000	0,007	0,007	0,005	0,006	0,011	0,012	0,008	0,014
2Q2017	0,002	0,026	0,026	0,019	0,009	0,019	0,022	0,017	0,020
3Q2017	0,000	0,005	0,003	0,003	0,003	0,000	0,001	0,003	0,004
4Q2017	0,021	0,018	0,017	0,019	0,018	0,015	0,013	0,017	0,009
1Q2018	0,020	0,031	0,026	0,019	0,014	0,021	0,023	0,020	0,017
2Q2018	0,003	0,009	0,016	0,010	0,007	0,011	0,020	0,012	0,025
3Q2018	0,032	0,011	0,006	0,010	0,011	0,010	0,010	0,014	0,014
4Q2018	0,029	0,029	0,030	0,032	0,034	0,029	0,026	0,028	0,025
1Q2019	0,023	0,026	0,018	0,016	0,013	0,013	0,012	0,019	0,011
2Q2019	0,004	0,022	0,020	0,014	0,011	0,013	0,013	0,012	0,009
3Q2019	0,007	0,007	0,006	0,003	0,005	0,003	0,003	0,002	0,005
4Q2019	0,039	0,023	0,023	0,031	0,036	0,033	0,031	0,033	0,032
Durchschnitt	0,013	0,013	0,014	0,012	0,012	0,013	0,014	0,014	0,014
Standardabweichung	0,012	0,010	0,009	0,010	0,010	0,010	0,010	0,009	0,010

5 Zusammenfassung und Vorschläge zur Überleitung in den Regelbetrieb

Mit der vorliegenden Studie wurde der Versuch unternommen, die für die österreichische Tourismuswirtschaft wesentlichen Erfolgsindikatoren – Nächtigungen, Umsätze und vor allem die reale Bruttowertschöpfung der touristischen Kernbereiche Beherbergung und Gastronomie – in die nähere Zukunft zu prognostizieren. Dazu wurden unterschiedliche Modelle und Modellspezifikationen verwendet und als 'Benchmark' die 'naive Prognose' (Random Walk) herangezogen: Eine modellhafte Prognose kann nur dann als sinnvoll erachtet werden, wenn ihr Prognosefehler unter jenem Fehler liegt, der sich aus der Fortschreibung des letztverfügbaren Wertes der Prognosevariable ergibt. Diese Bedingung wurde erfüllt; somit ist es sinnvoll, von der naiven Prognose abzuweichen und komplexere Modelle zu verwenden. Zudem sind die Prognosefehler in vielen Modellen annähernd normalverteilt, es kommt also zu keiner systematischen Unter- oder Überschätzung der Zielvariablen. Es ist wichtig, darauf hinzuweisen, dass die Prognosemodelle vor allem auf den in der Vergangenheit beobachteten Schwankungen der Zielvariablen beruhen und daraus die Variablenwerte ableiten, die für zukünftige Perioden zu erwarten sind. Zusätzlich wurden auch aktuell verfügbare exogene Variablen in die Modelle miteinbezogen (z.B. Feiertage, Einschätzungen der Unternehmen aus dem WIFO-Konjunkturtest, Arbeitsmarktdaten etc.). Die Zahl dieser exogenen Variablen in den einzelnen Modellen kann zudem in zukünftigen Prognosen je nach Verfügbarkeit neuer Daten (z.B. Hotelbuchungen oder Variablen aus der WIFO-Konjunkturprognose etc.) rasch erweitert werden, was die Prognosequalität überdies verbessern könnte. Darüber hinaus bietet die Integration zusätzlicher erklärender Variablen in die Prognosemodelle auch Vorteile hinsichtlich der Kommunikation der Prognosen an die Branche bzw. die Öffentlichkeit, indem die prognostizierten Veränderungen in den Nächtigungen oder der realen Bruttowertschöpfung mit Veränderungen in der Zahl der Buchungen, der Erwartungen der Tourismusunternehmen oder der Konjunktureinschätzung des WIFO in Zusammenhang gebracht werden können – zu den Prognosen kann also auch eine 'Geschichte' erzählt werden. Zudem erscheint es sinnvoll, die hier präsentierten 'maschinellen' Prognosen mit einer Einschätzung der touristischen Konjunktur durch Expert:innen zu ergänzen und somit quantitative und qualitative Prognosemethoden zu kombinieren, um dann zu einer endgültigen Beurteilung der zu erwartenden touristischen Entwicklung zu kommen. Die Berücksichtigung der Meinungen von Expert:innen ist auch aus einem anderen Grund unverzichtbar: Qualitativ hochwertige Prognosen zu erstellen ist prinzipiell eine herausfordernde Aufgabe, sie wird jedoch noch schwieriger, 'wenn sich die Zukunft von der Vergangenheit unterscheidet'. Prognosemodelle lernen wie erwähnt ganz wesentlich aus der Analyse der vergangenen Entwicklung der Zielvariablen und der erklärenden Variablen und leiten daraus den zukünftigen Entwicklungspfad der Prognosevariablen ab. Kommt es jedoch zu einem gänzlich unerwarteten und damit unprognostizierbaren Ereignis wie dem Ausbruch einer Pandemie oder eines Krieges, hat die Vergangenheit nur mehr wenig Erklärungskraft für das, was in der Zukunft passieren wird. Der Umgang mit solchen temporären oder sogar permanenten Strukturbrüchen ist bei einer

gemeinsam mit dem Auftraggeber/der Auftraggeberin zu entscheidenden Aufnahme eines 'regulären Prognosebetriebs' jedenfalls zu diskutieren.

6 Referenzen

- Bhattacharya, A., Pati, D., Pillai, N. S., & Dunson, D. B. (2015). Dirichlet–laplace priors for optimal shrinkage. *Journal of the American Statistical Association*, *110*(512), 1479–1490.
- Brown, P. J., & Griffin, J. E. (2010). Inference with normal-gamma prior distributions in regression problems. *Bayesian Analysis*, *5*(1), 171–188.
- Fernandez, C., Ley, E., & Steel, M. F. (2001). Benchmark priors for bayesian model averaging. *Journal of Econometrics*, *100*(2), 381–427.
- Hill, J., Linero, A., & Murray, J. (2020). Bayesian additive regression trees: A review and look forward. *Annual Review of Statistics and Its Application*, *7*(1).
- Koop, G., & Korobilis, D. (2012). Forecasting inflation using dynamic model averaging. *International Economic Review*, *53*(3), 867–886.