



In Auftrag gegeben von:

 Bundesministerium
Finanzen

Hochfrequente Konjunkturbeobachtung

**Sandra Bilek-Steindl, Julia Bock-Schappelwein,
Christian Glocker, Serguei Kaniovski (WIFO),
Sebastian Koch, Richard Sellner (IHS)**

Wissenschaftliche Assistenz: Astrid Czaloun,
Peter Reschenhofer (WIFO)

Oktober 2020
Österreichisches Institut für Wirtschaftsforschung

Hochfrequente Konjunkturbeobachtung

Sandra Bilek-Steindl, Julia Bock-Schappelwein,
Christian Glocker, Serguei Kaniovski (WIFO),
Sebastian Koch, Richard Sellner (IHS)

Oktober 2020

**Österreichisches Institut für Wirtschaftsforschung, Institut für Höhere Studien
Im Auftrag des Bundesministeriums für Finanzen**

Begutachtung: Josef Baumgartner (WIFO)

Wissenschaftliche Assistenz: Astrid Czaloun, Peter Reschenhofer (WIFO)

In dieser Studie wird eine große Zahl hochfrequenter Indikatoren gesammelt und hinsichtlich ihres Informationsgehaltes im Hinblick auf die Aktivität der österreichischen Volkswirtschaft analysiert. Dies geschieht anhand von Kreuzkorrelationen dieser und anderer häufig verwendeter Indikatoren für verschiedene Referenzreihen, u. a. für das BIP, das verarbeitende Gewerbe, den Bausektor, Teile des Dienstleistungssektors, Investitionen, Konsum, Importe und Exporte. Auf Basis dieser Erkenntnisse werden dynamische Faktormodelle (DFM) für die Referenzreihen spezifiziert. Dies ermöglicht eine Echtzeiteinschätzung und eine Prognose des BIP sowohl durch einen direkten (wöchentlicher WIFO-Wirtschaftsindex – WWWI) als auch durch einen indirekten Ansatz (Cluster dynamischer Faktormodelle – CDFM). Eine Auswahl an hochfrequenten Indikatoren ist auch über den IHS Economic High-Frequency Monitor abrufbar.

2020/288-1/S/WIFO-Projektnummer: 5220

© 2020 Österreichisches Institut für Wirtschaftsforschung, Institut für Höhere Studien

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: 50 € • Kostenloser Download: <https://www.wifo.ac.at/wwa/pubid/66530>

Endbericht zur WIFO und IHS Studie:

Hochfrequente Konjunkturbeobachtung

2 Oktober 2020

Zusammenfassung

In dieser Studie sammeln wir eine große Anzahl hochfrequenter Indikatoren und analysieren ihren Informationsgehalt im Hinblick auf die Aktivität der österreichischen Volkswirtschaft. Dies geschieht anhand einer dynamischen Korrelationsanalyse zwischen diesen (hochfrequenten und auch anderen häufig verwendeten) und verschiedenen Referenzreihen, unter anderem für das BIP, das verarbeitende Gewerbe (Industrie), den Bausektor, Teile des Dienstleistungssektors, Investitionen, Konsum, Importe und Exporte. Auf Basis dieser Erkenntnisse spezifizieren wir dynamische Faktormodelle (DFM) für die Referenzreihen. Dies ermöglicht eine Echtzeiteinschätzung und eine Prognose des BIP sowohl durch einen direkten (Wöchentlicher-WIFO-Wirtschaftsindex – WWWI) als auch durch einen indirekten (Cluster dynamischer Faktormodelle – CDFM) Ansatz. Eine Auswahl an hochfrequenten Indikatoren ist auch über den IHS Economic High-Frequency Monitor abrufbar.

Dieser Bericht wurde mit finanzieller Unterstützung des Bundesministeriums für Finanzen (BMF), Abteilung III/1 Allgemeine Wirtschaftspolitik im Rahmen des Projektes “Wachstum, Wohlstand, solide Finanzen und die Corona-Krise” erstellt und umfasst zwei Teilprojekte:

- Projektteil 1-1: *Hochfrequente Konjunkturbeobachtung* [Bearbeitung: WIFO und IHS]
- Ergänzung zum Projektteil 1-1: *Indikatoren für BIP-Teilaggregate der Verwendungs- und Entstehungsseite* [Bearbeitung: WIFO]

WIFO-Autoren: Sandra Bilek-Steindl, Julia Bock-Schappelwein,
Christian Glocker, Serguei Kaniovski.

Wissenschaftliche Assistenz: Astrid Czaloun, Peter Reschenhofer.

IHS-Autoren: Sebastian Koch, Richard Sellner.

Begutachtung: Josef Baumgartner (WIFO).

Inhaltsverzeichnis

1	Kurzfassung	1
2	WIFO-Teil zum Projektbericht	3
2.1	Einleitung	3
2.2	Auswahl und Analyse der Indikatoren	6
2.2.1	Zur Bedeutung von hochfrequenten Daten in der aktuellen Situation . .	6
2.2.2	Indikatorenansatz	8
2.2.3	Korrelationsanalyse	16
2.3	Direkter Ansatz zur Echtzeitschätzung und Prognose des BIP auf wöchentlicher Basis	19
2.3.1	Wöchentlicher-WIFO-Wirtschaftsindex (WWWI)	20
2.3.2	Gesamtjahresprognose auf Basis des WWWI	28
2.4	Indirekter Ansatz zur Echtzeitschätzung und Prognose des BIP: Modellierung der Teilaggregate	33
2.4.1	Das CDFM im Überblick	33
2.4.2	Datengrundlage und Spezifikation des CDFM	36
2.4.3	Die Funktionsweise eines CDFM	38
2.4.4	Ergebnisse des CDFM	42
2.5	Anhang: Finanzmarktstressindikator	48
2.5.1	Die ökonometrische Methodologie	50
2.6	Anhang: Korrelationsanalyse	52
3	IHS-Teil zum Projektbericht	62
3.1	Economic High-Frequency Monitor	62
3.1.1	Schienengüterverkehrsleistung	62
3.1.2	Arbeitslosenquote	63
3.1.3	Stromverbrauch	63
3.1.4	Tool	64
3.1.5	Ausblick	65
	Literaturverzeichnis	65

Abbildungsverzeichnis

1	Stromverbrauch	10
2	Schadstoffe	11
3	Zahlungsverkehrsdaten	11
4	Google Mobilitätsdaten	12
5	Ankünfte am Flughafen Wien	13
6	Arbeitslosigkeit	14
7	Kurzarbeit	15
8	Beschäftigung	15
9	Arbeitsmarkt	16
10	Finanzmarktstressindikator	17
11	Robustheit	26
12	Echtzeitaktualisierung	27
13	Wöchentliche Indizes im Vergleich	29
14	Wöchentlicher Verlauf der Gesamtjahresprognose 2020	31
15	Verlauf der Gesamtjahresprognose 2020	32
16	Granger-kausalitätsbasierte Modellstruktur	37
17	Monatliche Indikatoren für Teilaggregate 1997Q1-2020Q2	44
18	Monatliche Indikatoren für Teilaggregate 2020Q1-2020Q2	45
19	Vergleich mit den Expertenprognosen für 2009	46
20	Bruttoinlandsprodukt	52
21	Bruttowertschöpfung Industrie	53
22	Bruttowertschöpfung Bau	54
23	Bruttowertschöpfung Marktdienstleistungen	55
24	Bruttowertschöpfung Tourismus	56
25	Bruttowertschöpfung Marktdienstleistungen ohne Tourismus	57
26	Privater Konsum	58
27	Bruttoanlageinvestitionen	59
28	Exporte i.w.S.	60
29	Importe i.w.S.	61
30	Bildausschnitt High-Frequency Monitor	65

Tabellenverzeichnis

1	Anordnung der Verhaltensmodelle im CDFM	40
2	Anordnung der Verhaltensmodelle im CDFM	41

1 Kurzfassung

Das Bruttoinlandsprodukt, als wichtigster Indikator zur Beschreibung der wirtschaftlichen Lage, wird vierteljährlich mit einer Verzögerung von einem Monat nach Ende eines Quartals als erste Schnellschätzung veröffentlicht. Das zeitnahe Vorliegen von Indikatoren, die Anhaltspunkte über die aktuelle wirtschaftliche Lage liefern, ist jedoch für eine antizipierende, rasche und angemessene Reaktion der Wirtschaftspolitik unabdingbar. Zu diesem Zweck stützt sich die Konjunkturanalyse zunehmend auf monatliche Daten, doch selbst diese sind manchmal lediglich eingeschränkt aussagekräftig bzw. mit einer zu großen Verzögerung verfügbar. Im Besonderen, wenn sich die Entwicklung so rasch und ohne vergleichbare Erfahrungswerte vollzieht, wie dies in der COVID-19-Krise geschah: innerhalb von nur zwei Wochen hat sich die Einschätzung von “der wirtschaftliche Abschwung verstärkt sich durch Lieferverzögerungen bei Rohstoffen, Vor- und Endprodukten aus China” zu “größte globale Rezession” verschärft.

Vor diesem Hintergrund beschreibt dieser Projektbericht eine Erweiterung der Konjunkturanalyse hin zu einer wöchentlichen Frequenz. In einem ersten Schritt beschreiben wir die aus theoretischer Sicht motivierte Beschaffenheit eines idealen Indikators. In einem weiteren wird ein Satz an Indikatoren gesammelt um die Aktivität der österreichischen Volkswirtschaft anhand hochfrequenter Wirtschaftsdaten zeitnah analysieren zu können. Der Schwerpunkt liegt hierbei auf Wochendaten. Aufbauend darauf analysieren wir deren Informationsgehalt: Diese und andere häufig verwendete Indikatoren werden anhand dynamischer Kreuzkorrelationsstatistiken analysiert. Dies geschieht für verschiedene Referenzreihen: für das BIP, VGR-entstehungsseitig für das verarbeitende Gewerbe (Industrie), den Bausektor, Teile des Dienstleistungssektors, sowie VGR-verwendungsseitig für den Konsum, die Investitionen, die Importe und Exporte.

Mit Blick auf das BIP haben Daten zur LKW-Fahrleistung, arbeitsmarktspezifische Variablen, wie die beim AMS gemeldeten offenen Stellen, Erhebungen zu den Warenausfuhren, realwirtschaftliche Aktivitätsindizes wichtiger Handelspartner sowie Unternehmensumfragen, wie dem WIFO-Konjunkturtest, eine besonders hohe Aussagekraft. Daten hierfür liegen zum Teil auf monatlicher sowie auf wöchentlicher Basis vor.

Auf Basis der Erkenntnisse der Korrelationsanalyse spezifizieren wir dynamische Faktormodelle (DFM) für die Referenzreihen um gesamtwirtschaftliche sowie sektorspezifische Aktivitäts- bzw. Nachfrageindikatoren zu bestimmen. Da die Indikatoren auch auf hochfrequenter (wöchentlicher/monatlicher) Basis vorliegen, erlauben sie eine zeitnahe Echtzeiteinschätzung der jeweiligen Referenzreihen. Dies ermöglicht eine Echtzeiteinschätzung und eine Prognose des BIP sowohl durch einen direkten (Wöchentlicher-WIFO-Wirtschaftsindex – WWWI) als auch durch einen indirekten (Cluster dynamischer Faktormodelle – CDFM) Ansatz.

Aus dem direkten Ansatz zur Echtzeitschätzung und Prognose des BIP geht der *Wöchentliche-*

WIFO-Wirtschaftsindex hervor. Die Entwicklungen im Zusammenhang mit der COVID-19-Rezession führten dazu, dass der WWWI in den Wochen ab Mitte März 2020 deutlich unter jene Werte von 2008/09 fiel. Konkret verzeichnete der WWWI einen plötzlichen und starken Rückgang der wirtschaftlichen Aktivität. Ein Tiefpunkt von rund –22 Prozent wird in Kalenderwoche 14 (30. März bis 05. April) erreicht. Die rasante Entwicklung im ersten Halbjahr 2020 ist im WWWI adäquat abgebildet. Somit leistet der WWWI vor allem in diesen Wochen einen Mehrwert zur bestehenden Konjunkturanalyse. Außerhalb dieser beschreibt der WWWI einen ähnlich persistenten Pfad wie die jährlichen Zuwachsraten des BIP. Somit liefern in Nicht-Krisenzeiten bislang häufig verwendete makroökonomische Aggregate mit einer nur kurzen zeitlichen Verzögerung eine adäquate Beschreibung der wirtschaftlichen Bedingungen. Wenn sich allerdings die Bedingungen von Tag zu Tag und von Woche zu Woche rasch ändern, wie es im Umfeld der COVID-19-Krise der Fall ist, geben hochfrequente Indikatoren ein informatives und zeitnahe Signal über den Zustand der Wirtschaft.

Der indirekte Ansatz – mittels eines Clusters dynamischer Faktormodelle (CDFM) – ermöglicht eine Echtzeiteinschätzung und Prognose des BIP-Wachstums für das laufende Jahr im Rahmen eines disaggregierten Ansatzes über die zentralen Komponenten der Entstehungs-, Verwendungs- und Verteilungsseite der Volkswirtschaftlichen Gesamtrechnung hinweg. Das CDFM beinhaltet in Summe 30 eigenständige dynamische Faktormodelle, die jedoch miteinander verknüpft sind. Dies erlaubt einen Blick ins Detail hinsichtlich der Elemente, welche die gesamtwirtschaftliche Dynamik prägen und haben damit einen Mehrwert für die Konjunkturanalyse zur Folge. Nicht zuletzt vereinfacht der indirekte (disaggregierte) Ansatz die Interpretation und Beschreibung des aktuellen Konjunkturverlaufes, und hat tendenziell genauere Prognosen der Referenzreihen zur Folge.

Der *Economic High-Frequency Monitor* des IHS (<https://monitor.ihs.ac.at/>) stellt eine Auswahl an drei hochfrequenten Indikatoren dar: die Schienengüterverkehrsleistung, der Stromverbrauch und die Arbeitslosenquote. Der Vorteil dieser Indikatoren ist die zeitnahe Verfügbarkeit und der geringe Revisionsumfang.

2 WIFO-Teil zum Projektbericht

2.1 Einleitung

Im Rahmen der Konjunkturanalyse ist die Betrachtung von Indikatoren, die im Voraus Hinweise auf wirtschaftliche Schwankungen geben könnten, essentiell. So stellte sich vor allem im Zuge der durch die COVID-19-Pandemie ausgelösten Wirtschaftskrise die zeitnahe Beobachtung des wirtschaftlichen Geschehens als besonders wichtig heraus. Es besteht kein Zweifel daran, dass das reale BIP als Maß für den Gesamtzustand einer Volkswirtschaft einer der wichtigsten koinzidenten Indikatoren ist. Die zeitliche Verzögerung bei der Veröffentlichung von BIP-Statistiken, der bloße Umstand, dass diese Zahlen nur vierteljährlich verfügbar sind, und die Tatsache, dass sie beträchtlichen Revisionen unterliegen, schränken die Eignung des BIP, Konjunkturlagen frühzeitig zu beurteilen, jedoch ein. Es gibt noch einen weiteren wichtigen Aspekt, der die Relevanz der BIP-Zahlen für die Ermittlung konjunktureller Schwankungen beeinträchtigt. Tatsächlich enthält das BIP auch Elemente, die überhaupt nicht mit dem Konjunkturzyklus verbunden sind: Beispiele für solche Elemente sind nicht-zyklische BIP-Komponenten, wie die Wertschöpfung des öffentlichen Sektors oder die Wertschöpfung von Sektoren, die wiederholt idiosynkratischen Ereignissen (Wettereffekte u.a.) ausgesetzt sind. Vor diesem Hintergrund sollte das BIP (und seine verschiedenen Transformationen) nicht als Synonym für den Konjunkturzyklus betrachtet werden, obwohl das BIP neben anderen Indikatoren als eine Variable wahrgenommen werden kann, die wertvolle Informationen über den Konjunkturzyklus enthält.

In der empirischen Literatur wurde versucht, diese Nachteile auszugleichen, indem mehr Aufmerksamkeit auf andere Indikatoren wie jene aus Umfragen oder harten Daten¹ gelenkt wurde (siehe Diebold und Rudebusch, 1989; Veloce, 1996, um nur wenige zu nennen), die ein genaues Bild der aktuellen und kurzfristigen Entwicklungen einer Volkswirtschaft vermitteln sollen. Ihre Nützlichkeit beruht auf ihrer Fähigkeit, das zyklische Verhalten einiger Referenzreihen, in der Regel das BIP-Wachstum, vorzuzeichnen. Der ideale Indikator zeichnet sich durch die folgenden Merkmale aus:

- Korrelation: Ein guter Indikator sollte eine hohe Korrelation mit den interessierenden Variablen (*Referenzreihen*) aufweisen.
- Vorauseilung: Ein guter Indikator sollte einen Vorlauf relativ zu den interessierenden Variablen haben.
- Aktualität: Ein guter Indikator sollte zeitnah verfügbar sein.

¹Unter *harten* Daten werden Indikatoren verstanden, die eine tatsächliche wirtschaftliche Größe abbilden, wie zum Beispiel, die Industrieproduktion als Kennzahl für die Wertschöpfung der Sachgütererzeugung oder die Einzelhandelsumsätze als Kennzahl für die Wertschöpfung im Handel.

- Robustheit: Ein guter Indikator sollte durch eine stabile Korrelation und eine stabile Vorlaufeigenschaft mit den interessierenden Variablen gekennzeichnet sein.
- Stabilität: Ein guter Indikator sollte keinen größeren Revisionen unterworfen werden (dies ist entscheidend für die Bestimmung des tatsächlichen Nutzens des Echtzeit-Informationsgehalts bei zeitnahen Beobachtungen).
- Verlässlichkeit: Indikatoren sollten regelmäßig verfügbar sein.
- Glaubwürdigkeit: Die Qualität der auf Umfragen basierenden Indikatoren hängt u.a. von der Rücklaufquote, vom Ausmaß in dem die Fragen wahrheitsgemäß beantwortet werden, der Schichtung der Stichprobe, und von der Methodik ab, die zur Erstellung eines Index aus qualitativen Daten angewandt wird.
- Länge: Der praktische Nutzen von Indikatoren hängt nicht zuletzt von der Zeitspanne ab, die sie abdecken.

Vor diesem Hintergrund ist es ein Ziel der vorliegenden Studie, eine Reihe von Indikatoren zu identifizieren, welche die günstigsten Eigenschaften für die Früherkennung des Konjunkturzyklus der österreichischen Volkswirtschaft aufweisen. Der Schwerpunkt liegt hierbei auf hochfrequenten Indikatoren. Zu diesem Zweck sammeln wir in einem ersten Schritt eine Reihe an Indikatoren, die es ermöglichen, die reale Wirtschaftsaktivität auf wöchentlicher Basis zu beurteilen. Danach klassifizieren wir diese und andere häufig verwendete Indikatoren in vorlaufende, zeitgleiche und nachlaufende Indikatoren, indem wir dynamische Kreuzkorrelationsstatistiken berechnen. Diese Analyse wird für verschiedene Referenzreihen, wie das BIP, das verarbeitende Gewerbe, den Bausektor, Teile des Dienstleistungssektors, Investitionen, Konsum, Importe und Exporte durchgeführt. Unsere erweiterte Modellumgebung ermöglicht eine Echtzeiteinschätzung und eine Prognose des BIP sowohl durch einen *direkten* (aggregierten) als auch durch einen *indirekten* (disaggregierten) Ansatz.

Der *direkte* Ansatz erlaubt die Bestimmung eines wöchentlichen Indikators, der einen Schwerpunkt dieser Arbeit darstellt. In Nicht-Krisenzeiten verläuft die reale Wirtschaftstätigkeit kontinuierlich, sodass vertraute monatliche und vierteljährliche makroökonomische Daten Informationen in einem Zeitraum liefern, der für die makroökonomische Beobachtung und Prognose ausreichend präzise ist. Ist das makroökonomische Umfeld stattdessen hochfrequenten Schocks ausgesetzt - auf einer Zeitskala von Wochen oder sogar Tagen, wie es in der ersten Hälfte des Jahres 2020 im Zuge der COVID-19-Krise der Fall war - ist es unerlässlich, dass ein systematisches Maß der realen wirtschaftlichen Aktivität in höherer Frequenz zur Verfügung steht, um zeitnahe Informationen über das Wirtschaftsgeschehen bereitstellen zu können. Vor diesem Hintergrund wird ein wöchentlicher Indikator (Wöchentlicher-WIFO-Wirtschaftsindex

– WWWI) für das BIP erstellt. Der WWWI wird in einer Form normiert, sodass er dem Mittelwert und der Standardabweichung der vierteljährlichen Vorjahreswachstumsraten des BIP entspricht. Der Hauptzweck des WWWI besteht darin, einen wöchentlichen Index der realen Aktivität bereitzustellen, was eine monatliche oder vierteljährliche Reihe nicht leisten kann. Zusätzlich soll der WWWI auch zeitnahe Information liefern um eine Echtzeiteinschätzung von monatlichen und vierteljährlichen Aktivitätsreihen zu ermöglichen. Wir zeigen, dass der WWWI nützliche Echtzeiteinschätzungseigenschaften für das vierteljährliche Wachstum des BIP hat. Zum Beispiel wies der WWWI einen unmittelbar nach Quartalsende verfügbaren Wert für das BIP-Wachstum für das zweite Quartal 2020 von -12,1 Prozent gegenüber dem entsprechenden Vorjahresquartal aus. Gemäß der 30 Tage nach Quartalsende veröffentlichten Schnellschätzung (WIFO Flashrechnung) fiel das BIP im zweiten Quartal mit einer Jahresrate von 13,3 Prozent. Nach der zweiten und somit regulären Schätzung, die 60 Tage nach Quartalsende verfügbar ist, sank das BIP im zweiten Quartal mit einer Jahresrate von 12,9 Prozent. Der WWWI liefert somit eine adäquate Echtzeiteinschätzung des BIP und erlaubt damit eine zeitnahe Konjunkturanalyse.

Zudem wird ein erweiterter Satz an dynamischen Faktormodellen für diverse Teilkomponenten des BIP spezifiziert – dies kennzeichnet den *indirekten* Ansatz. Die Modelle sind innerhalb eines Clusters miteinander verbunden, dessen Verknüpfungen aus Granger-Kausalitätstests abgeleitet sind. Dieser Ansatz vereint die Vorteile groß angelegter makroökonomischer und kleinräumiger Faktormodelle, wodurch unser Cluster dynamischer Faktormodelle (CDFM) für modellkonsistente Echtzeiteinschätzungen und Prognosen für eine große Anzahl an makroökonomischen Variablen nützlich ist. Das CDFM hat eine einfache Struktur und ist leicht zu replizieren, seine Prognosen sind überdies präziser als die einer breiten Palette konkurrierender Modelle und jene professioneller Prognostiker (Glocker und Kaniovski, 2020). Das CDFM beinhaltet in Summe 30 eigenständige dynamische Faktormodelle, die jedoch miteinander verknüpft sind. Dieser von uns vorgeschlagene Prognoseansatz ermöglicht (i) die Erstellung modellkonsistenter Vorhersagen für eine breite Palette von Variablen, (ii) die Durchführung von Szenarioanalysen auf der Grundlage bedingter Prognosen, (iii) die Verwendung von Daten mit unterschiedlichen Frequenzen und Zeitreihen mit fehlenden Beobachtungen, (iv) schnelle Erweiterungen für bestimmte Variablen und Modelle usw. Darüber hinaus ermöglicht dieser Ansatz nicht nur die Schätzung vieler makroökonomischer Aggregate und damit eine Echtzeiteinschätzung des BIP auf disaggregierter Basis, sondern auch die Einbeziehung von Informationen über die Komponenten, die zur Erklärung der Echtzeiteinschätzung beitragen, wodurch ein Einblick in die Ursachen von BIP-Prognose-Revisionen ermöglicht wird. Nicht zuletzt erlaubt der CDFM-Ansatz, dass auch subjektive Urteile eines Praktikers (judgemental forecast adjustment – (Sanders und Ritzman, 2001)) einbezogen und somit bedingte Prognosen erstellt werden können (zum Beispiel in Form einer Vorgabe des zukünftigen Pfades des

Rohölpreise, oder ähnliches).

Der WIFO-Teil des Projektberichtes gliedert sich wie folgt. Kapitel 2.2 behandelt neben der Beschreibung der Indikatoren und datenspezifischen Details zur Bereinigung von Temperatur- und Kalendereffekten auch die Korrelationsanalyse. Darauf aufbauend wird in Kapitel 2.3 ein Ansatz zur modellgestützten Echtzeiteinschätzung und Prognosen des BIP in *direkter Form* beschrieben. Der Ansatz fokussiert sich auf eine hochfrequente Analyse der realwirtschaftlichen Aktivität. Kapitel 2.4 beschreibt den erweiterten Satz an dynamischen Faktormodellen für diverse Teilkomponenten des BIP und damit jenen Ansatz, der eine Echtzeiteinschätzung und Prognosen für das BIP im Rahmen einer *indirekten Form* ermöglicht.

2.2 Auswahl und Analyse der Indikatoren

Im Rahmen dieser Arbeit wurde ein Satz von Indikatoren zusammengestellt, welcher zur Messung der wirtschaftlichen Aktivität auf wöchentlicher Basis (Kapitel 2.3) sowie zur quartalsweisen Prognose des BIP und seiner Teilaggregate herangezogen werden kann (Kapitel 2.4). Neben den monatlichen und quartalsweisen Indikatoren, welche üblicherweise in kurzfristige Prognosemodelle eingehen, enthält dieser Datensatz hochfrequente Indikatoren, welche auf Tages- oder Wochenbasis verfügbar sind. In einem weiteren Schritt wurden diese Indikatoren den auf Quartalsbasis vorliegenden Zielgrößen (BIP sowie seinen entstehungs- und verwendungsseitigen Komponenten) gegenübergestellt um jene Indikatoren aus dem Datensatz zu identifizieren, die geeignet sind, die aktuelle und nahe zukünftige konjunkturelle Entwicklung vorauszuschätzen.

2.2.1 Zur Bedeutung von hochfrequenten Daten in der aktuellen Situation

Die COVID-19 Pandemie und die zur Eindämmung gesetzten Maßnahmen führten zu einem Rückgang der Wirtschaftsleistung, welcher sowohl in der Dimension als auch in der Geschwindigkeit einmalig in der Geschichte seit dem zweiten Weltkrieg ist. Dieser Einbruch manifestierte sich in den Zahlen des ersten und zweiten Quartals 2020 der volkswirtschaftlichen Gesamtrechnung mit massiven Rückgängen in den konsumrelevanten Bereichen Tourismus, Verkehr, Handel und persönliche Dienstleistungen. Auch die Industrie- sowie die Baukonjunktur brachen in Folge der COVID-19-Pandemie ein.

Die Arbeitslosigkeit stieg innerhalb weniger Wochen auf das höchste Niveau in der Zweiten Republik und die Beschäftigung ging in einem Ausmaß wie zuletzt vor fast 70 Jahren während der *Stabilisierungskrise 1952/53* zurück (siehe u.a. Kramer, 1967; Bock-Schappelwein et al., 2020). Die Corona-Kurzarbeit verhinderte einen noch stärkeren Beschäftigungsabbau. Der Arbeitsmarkt reagiert auf einen Konjunkturerinbruch – wie zuletzt 2008/09 – mit einem spezifischen Muster, wonach Männer und junge Arbeitskräfte unmittelbarer betroffen sind

als Frauen oder Personen im Haupterwerbsalter (Mahringer, 2009). Begründet wird dies mit einem höheren Beschäftigungsanteil der Männer in konjunkturreagiblen Sektoren bzw. der geringen Berufserfahrung jüngerer Menschen, die im Konjunkturabschwung eher ihren Arbeitsplatz verlieren bzw. keine offene Stelle finden können.

Um den rasanten Einbruch der Wirtschaftsleistung ab Mitte März sowie die Effekte des stufenweisen Wiederhochfahrens der wirtschaftlichen Aktivität ab Mitte April zeitnah analysieren zu können, erwies sich sowohl in Österreich als auch international – Wöchentliche Aktivitätsindizes der Deutschen Bundesbank und der Federal Bank of New York, (siehe Bundesbank, 2020a; Lewis et al., 2020) – der Einsatz von hochfrequenten Daten, z.B. auf wöchentlicher, oder sogar täglicher Basis, als sehr hilfreich. Bereits ab Mitte März 2020 wurden vom WIFO hochfrequente Daten in Modellschätzungen miteinbezogen. Im Rahmen der Prognosetätigkeit wurde hier ein erster Indikatorensatz herangezogen (Baumgartner et al., 2020). Ebenso veröffentlichte die OeNB einen neuen wöchentlichen BIP-Indikator, welcher in ihren Kurzfristprognosen des BIP-Wachstums und der Nachfragekomponenten Verwendung findet (OeNB, 2020).

Im Rahmen dieses Projekts wurde das bestehende Datenset an Indikatoren am WIFO ausgeweitet und ein umfangreicher Satz an hochfrequenten Indikatoren (auf täglicher oder wöchentlicher Basis) zusammengestellt. Dieser wird für die zeitnahe Analyse der heimischen Wirtschaft sowie der Prognose des laufenden Jahres herangezogen. Auch am Arbeitsmarkt bietet die zeitnahe Beobachtung des Geschehens einen unmittelbaren Einblick in dessen Reaktionen. Besonderes Augenmerk gilt hierbei der Phase zwischen Mitte März und Ende Juni und den Lockerungsschritten dazwischen. Die ersten Lockerungen gab es Mitte April bei den COVID-19-bedingten Einschränkungen in Teilbereichen des Handels (Öffnung von Geschäften mit weniger als 400 Quadratmetern Verkaufsfläche, aber auch größere Baumärkte, Gartencenter, Holzhandlungen) und weitere folgten Anfang Mai (übriger Handelsbereich, persönliche Dienstleistungen, Freiluftsport) bzw. Mitte Mai (Gaststättenwesen, Museen etc.). Ende Mai öffnete die Hotellerie wieder und es gab Lockerungen bei Veranstaltungen im Kunst- und Kulturbereich und beim Sport.

Abgesehen von den unmittelbaren Hinweisen auf die Arbeitsmarktlage dienen die zeitnahen Arbeitsmarktindikatoren auch dazu, die Entwicklung in entstehungsseitigen Komponenten des BIP zu antizipieren, wie beispielsweise die offenen Stellen für die Bruttowertschöpfung im Bauwesen (siehe Kapitel 2.4). Die Zahl und Entwicklung der offenen Stellen (monatlich und auf sektoraler Ebene verfügbar) liefern zeitnahe Hinweise auf die konjunkturelle Entwicklung, wie sich auch am Einbruch der offenen Stellen laut AMS zwischen Februar und April 2020 ablesen lässt (Abbildung 9). Besonders deutlich fiel dieser in der Sachgütererzeugung, im Handel, im Tourismus, und in den sonstigen wirtschaftlichen Dienstleistungen aus.

2.2.2 Indikatorensatz

Die Basis der hochfrequenten Indikatoren bildet einerseits die freiwillige und regelmäßige Übermittlung von Daten von einer Vielzahl an Unternehmen, andererseits wird auf entgeltliche und unentgeltliche Datenanbieter sowie offizielle Statistiken zurückgegriffen. Einige Indikatoren wurden dem WIFO vertraulich übermittelt, sie fließen in die Modellberechnungen ein, können jedoch in diesem Projektbericht weder grafisch noch gemäß ihrer Quelle angeführt werden. Im Rahmen der Datenzusammenstellung waren allerdings auch einige Bemühungen zur Beschaffung von Daten letzten Endes nicht erfolgreich. Dies betrifft beispielsweise Mobilitätsdaten von Mobilfunkunternehmen oder Buchungskennzahlen von touristischen Plattformen.

Eine Reihe an hochfrequenten Daten liegt auf täglicher Basis vor, diese werden in der weiteren Verarbeitung zu Wochengrößen aggregiert und fließen dann in dieser Form in die in Kapitel 2.3 und 2.4 beschriebenen Modelle ein.

Somit werden auf wöchentlicher Basis die LKW-Fahrleistung (ASFINAG), Stromverbrauch*, Kreditkartentransaktionsvolumina (inländisch, international, E-commerce), Schadstoffemissionen (Stickstoffdioxidausstoß und Feinstaubbelastung)*, SEPA-EDIFACT-TN Zahlungsverkehr (Anzahl sowie Volumina von Überweisungen)*, Google-Daten zur Mobilität (Einzelhandel und Erholung, Lebensmittelhandel und Apotheken, Bahnhöfe, Arbeitsplätze)*, Flugdaten zum Passagier- und Frachtvolumen*, Ergebnisse der Wochenauswertungen ausgewählter Indikatoren aus dem WIFO-Konjunkturtest (Lageindex der Gesamtwirtschaft), sowie Daten zum Arbeitsmarkt betrachtet. Darüber hinaus fließen auch internationale Daten wie der wöchentliche Aktivitätsindex der Federal Reserve Bank von New York und der Deutschen Bundesbank, sowie der Baltic Dry Index* ein (* teilweise täglich verfügbar). Die Indikatoren werden in der Folge kurz beschrieben.

Die **LKW-Fahrleistung** wird dem WIFO von der ASFINAG auf wöchentlicher Basis zur Verfügung gestellt. Der Datensatz umfasst die zurückgelegten Kilometer in regionaler Gliederung. Im Aggregat betrachtet erweist sie sich als verlässlicher Vorlaufindikator für wichtige wirtschaftliche Größen wie das BIP, Wertschöpfung der Industrie, sowie die Nachfrage nach Investitionen, Exporten und Importen (siehe Kapitel 2.4). Die Daten zeigen Veränderungen im konjunkturellen Verlauf sehr rasch an und werden auch im wöchentlichen BIP-Indikator der OeNB sowie im OeNB-Exportindikator für die Prognose der Güterexporte herangezogen (Schneider und Fenz, 2009).

In der ökonomischen Literatur wird oft auf einen positiven Zusammenhang zwischen dem **Stromverbrauch** und dem Wirtschaftswachstum verwiesen (siehe Hirsh und Koomey, 2015; López-Prol und Sungmin, 2020, unter anderen). Der enge Zusammenhang, sowie die rasche Verfügbarkeit der Daten machen den Stromverbrauch zu einem häufig verwendeten Indikator in der COVID-19 Pandemieanalyse. So verwendet beispielsweise das Breugel Institut (McWilliams und Zachmann, 2020) Daten zum Stromverbrauch um die wirtschaftlichen Effekte

der behördlichen Schließungsmaßnahmen in einem internationalen Vergleich zu analysieren.

Daten zum Stromverbrauch unterliegen Kalender- und wetterbedingten Schwankungen: so erhöht eine stärkere Nutzung für Heizung und Kühlung an besonders kalten bzw. heißen Tagen den Verbrauch. Aus diesem Grund werden die Daten vor der Analyse um diese Effekte bereinigt. In dieser Studie verwenden wir Daten der ENTSO-E, diese liegen auf stündlicher Basis vor und werden von uns in unterschiedlichen Zeitintervallen betrachtet. In die laufende Analyse fließen jene von 8-18 Uhr ein, da diese den Verbrauch, der für die wirtschaftliche Produktionstätigkeit anfällt, am besten abbilden. Sie werden auf Tagesbasis zusammengestellt und um Kalender- und Temperatureffekte bereinigt. Hierfür wird folgende Spezifikation verwendet:

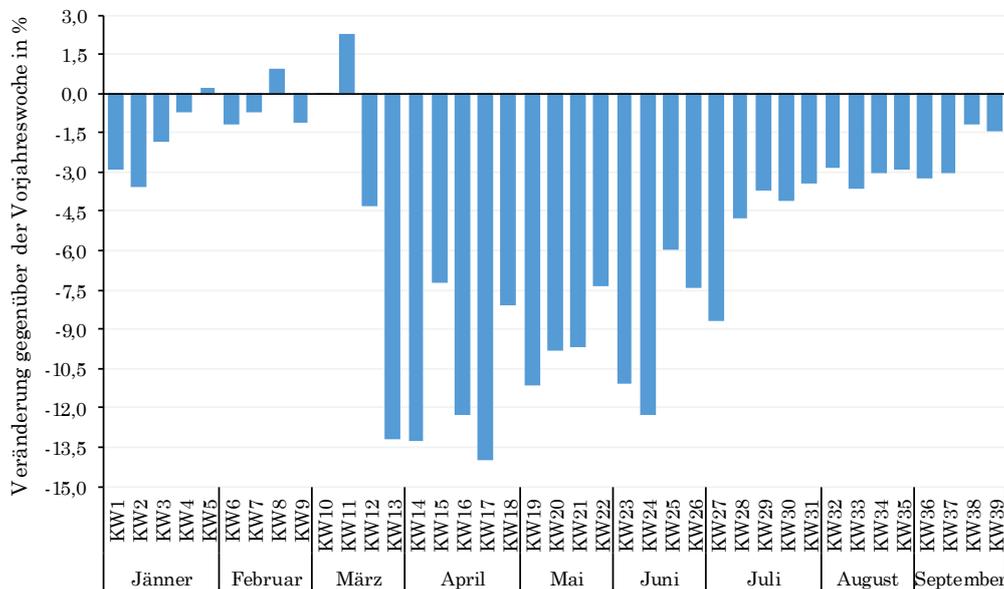
$$ENDAY_t = \beta_1 + \beta_2 \cdot CAL_t + \beta_3 \cdot TDevSOM_t + \beta_4 \cdot TDevWIN_t + u_t.$$

wobei $u_t \sim N(0, \sigma_u^2) \quad \forall t$. $ENDAY_t$ stellt den täglichen Energieverbrauch zwischen 8 und 18 Uhr in MWh dar. Der Kalendereffekt, inklusive beweglicher Feiertage, wird mit Dummy-Variablen für Arbeits- bzw. Nicht-Arbeitstage (Wochenende und Feiertage) berechnet (wobei $CAL_t = 0$ für Arbeitstage und $CAL_t = 1$ andernfalls). Für die Temperaturbereinigung wird eine Abweichung von der durchschnittlichen Temperatur $TDevWIN_t$ sowie $TDevSOM_t$ für die Wintermonate Oktober bis April bzw. die Sommermonate Juni bis August ermittelt. Diese zeigen den erhöhten Bedarf für Heizung an Wintertagen mit unterdurchschnittlicher Temperatur in Form eines negativen Koeffizienten, bzw. für Kühlung in Form eines positiven Koeffizienten an Sommertagen mit überdurchschnittlich hohen Temperaturen. Informationen zur Temperatur (Global Surface Summary of the Day) entnehmen wir der NOAA (National Oceanic and Atmospheric Administration). Hier wird ein Durchschnitt über die Messstationen aus den Daten der neun Bundeshauptstädte angewandt. Darüber hinaus wird die Reihe des Stromverbrauchs um nicht erklärbare Extremwerte an einzelnen Tagen im Jahr 2015 bereinigt.

Der bereinigte Stromverbrauch in Abbildung 1 zeigt eine unmittelbare Reaktion auf das Einsetzen der COVID-19-Pandemie. Mit Beginn der behördlichen Schließungsmaßnahmen in Kalenderwoche 12 (16. bis 22. März) lag der Stromverbrauch um 4,8 Prozent unter dem Vorjahreswert. In den Folgewochen verschärfte sich der Rückgang mit bis zu -14 Prozent dramatisch. Ab Mitte Juni Kalenderwoche 25 kann eine Erleichterung beobachtet werden.

Ähnlich wie der Stromverbrauch sind auch **Schadstoffemissionen** mit der wirtschaftlichen Aktivität verbunden. Im vorliegenden Projekt werden die Konzentration von Stickstoffdioxid in der Luft (NO_2) und die Feinstaubbelastung (PM10 und PM2.5) betrachtet. Sie stehen sowohl mit der Industrieproduktion als auch der Mobilität im Sinne von Transport- und Individualverkehr im Zusammenhang. Die Daten für die NO_2 -Belastung stammen von der European Environment Agency und werden als Durchschnitt der für Österreich verfügbaren verkehrsnahen und industrienahen Messstellen angeführt. Weiters verwenden wir Daten zur

Abbildung 1: Stromverbrauch



Quelle: ENTSO-E, WIFO Berechnungen, Macrobond, bereinigte Werte.

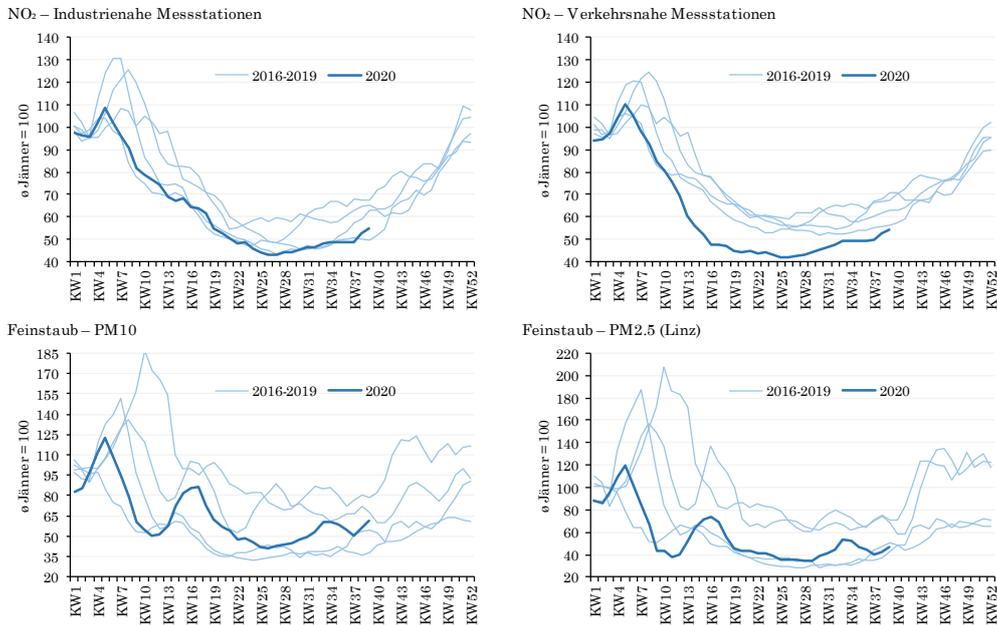
PM10-Feinstaubbelastung (Durchschnitt für Österreich), sowie die PM2.5-Feinstaubbelastung an der Messstation Linz. Diese Daten werden von Macrobond abgerufen. Die Daten werden ähnlich wie der Stromverbrauch um Kalender- und Temperatureffekte bereinigt². Aufgrund der hohen Volatilität in den Daten der Schadstoffemissionen wird auch ein gleitender Durchschnitt gebildet. Die Grafiken zeigen, dass die Schadstoffemissionen der beobachteten Aggregate seit dem Ausbruch der Krise großteils unter den Werten der vergangenen Jahre liegen. Dies gilt besonders für die Konzentration von Stickstoffdioxid in der Luft, welche an verkehrsnahen Messstationen verzeichnet wurden (Abbildung 2).

Weiters werden **Zahlungsverkehrsdaten** (SEPA-EDIFACT-TN) des Geldservice Austria (GSA) der österreichischen Nationalbank (OeNB) in Bezug auf Anzahl sowie Volumina von nationalen sowie grenzüberschreitende Bewegungen in Form von Überweisungen und Lastschriften betrachtet. Die Tageswerte werden auf Wochenbasis aggregiert. Der Datensatz beinhaltet sowohl Transaktionen zwischen Unternehmen als auch zwischen Nicht-Unternehmen. Im Vergleich zum Vorjahr wurde mit dem Ausbruch der Krise in den betrachteten Kategorien ein deutlicher Rückgang verzeichnet. Seit den Sommermonaten deutet die Entwicklung großteils auf eine Stabilisierung hin (Abbildung 3).

Durch die zur Eindämmung des Virus gesetzten Maßnahmen haben sich die Bewegungsmuster der Bevölkerung stark verändert. In den **Google-Daten zur Mobilität** aus den Google

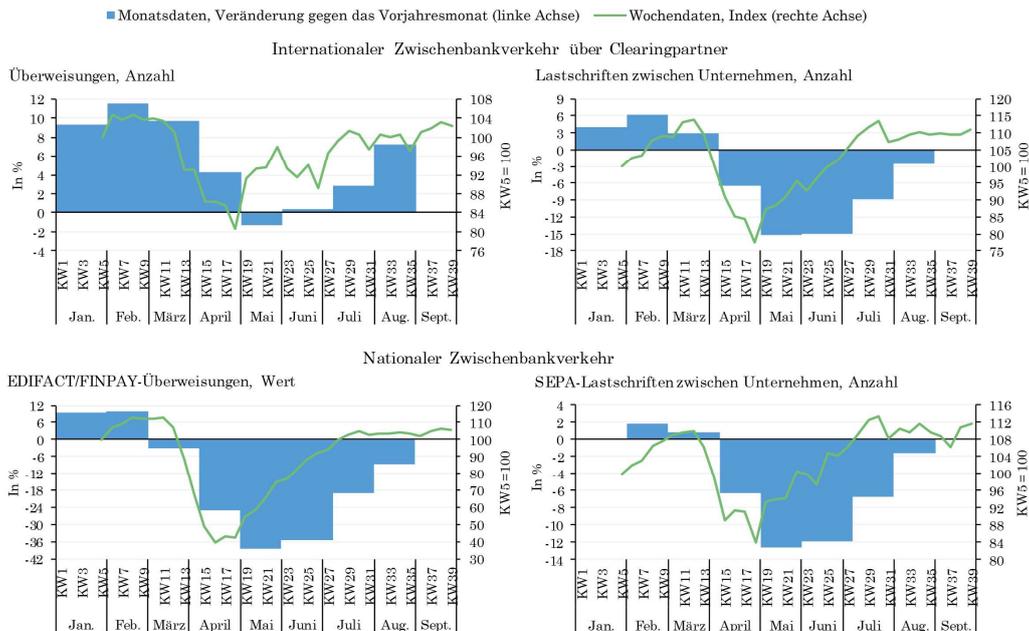
²Eine Bereinigung um weitere witterungsbedingte Effekte (wie Windstärke oder Niederschlag) wurde bislang nicht vorgenommen, ist aber in der Zukunft angedacht.

Abbildung 2: Schadstoffe



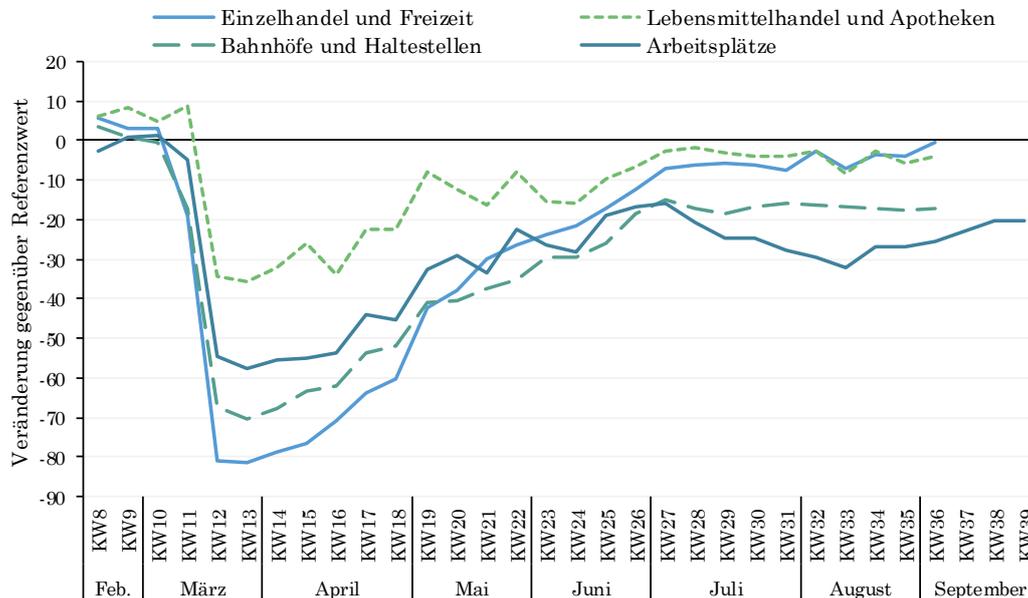
Quelle: EEA, WIFO Berechnungen, Macrobond, bereinigte Werte.

Abbildung 3: Zahlungsverkehrsdaten



Quelle: OeNB. Gleitende Quartals- (3 Monate) bzw. Monats- (4 Wochen) Durchschnitte.

Abbildung 4: Google Mobilitätsdaten



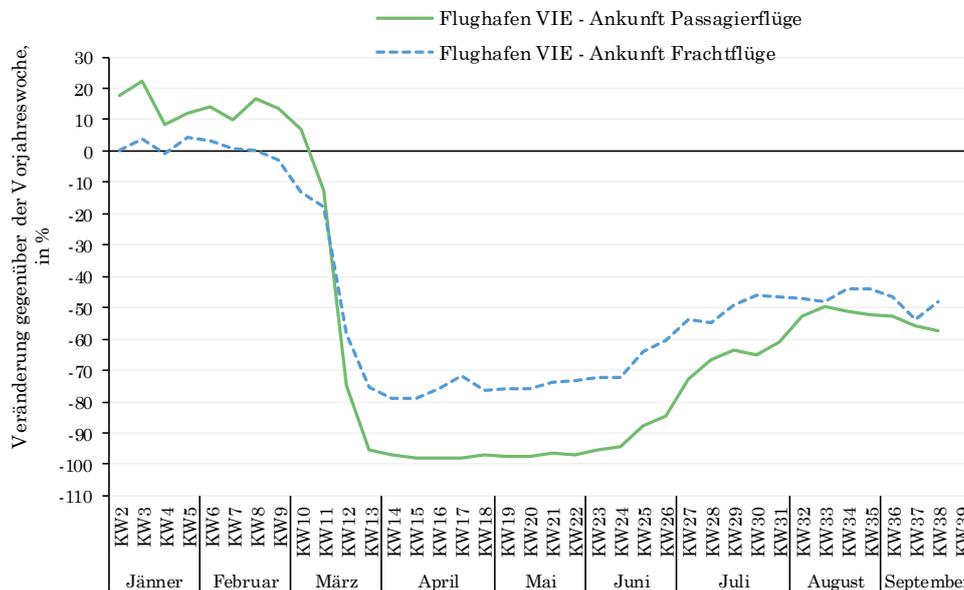
Quelle: Google, Macrobond.

Mobilitätsberichten (abgerufen von Macrobond) werden die Bewegungstrends für verschiedene Länder und unterschiedliche Kategorien wie Arbeit und Freizeit, im Zeitverlauf dargestellt. Die Daten zeigen die Veränderung in Bezug auf einen Referenzwert, welcher dem Medianwert der fünf Wochen vom 3. Januar bis 6. Februar 2020 entspricht. Für Österreich ist diese Information im Aggregat sowie nach Bundesländern gegliedert verfügbar. Im Rahmen dieses Projekts werden die Daten für Gesamt-Österreich in Bezug auf die vier Bereiche Lebensmittelhandel und Apotheken, Einzelhandel und Freizeit, Bahnhöfe und Haltestellen sowie Arbeitsplätze herangezogen.

Die Daten aus den Google Mobilitätsberichten zeigen einen dramatischen Einbruch im Bewegungsverhalten der österreichischen Bevölkerung zu Beginn der behördlichen Schließungsmaßnahmen in der Kalenderwoche 12 über alle vier beobachteten Aktivitätsbereiche. Im Bereich Einzelhandel und Freizeit wurde der stärkste Rückgang verzeichnet, jener im Bereich Lebensmittelhandel und Apotheken, welcher die Einkäufe für den täglichen Bedarf abdeckt, verlief flacher. Am aktuellen Rand zeigen die Bewegungstrends für Einzelhandel und Freizeit erstmals Werte nahe dem Referenzwert, in den drei anderen Bereichen ist weiterhin eine negative Abweichung zu beobachten (Abbildung 4).

Mit dem weltweiten Konjunkturreinbruch und den internationalen Reisebeschränkungen kam es zu einem deutlichen Rückgang im **Passagier- und Transportaufkommen**. Das zeigt sich deutlich in den Flugdaten zu Passagieren und Fracht am Flughafen Wien. Zu Beginn der behördlichen Schließungsmaßnahmen wurde ein massiver Rückgang der Ankünfte von

Abbildung 5: Ankünfte am Flughafen Wien



Quelle: Hadrien Bosetti (Österreich Werbung) und Holger Sicking (Österreich Werbung).

Passagierflügen verzeichnet, welcher erst mit den Grenzöffnungen langsam abebbte. Dennoch lag das Aufkommen auch während der Sommermonate noch deutlich unter dem Wert des vergangenen Jahres³ (Abbildung 5).

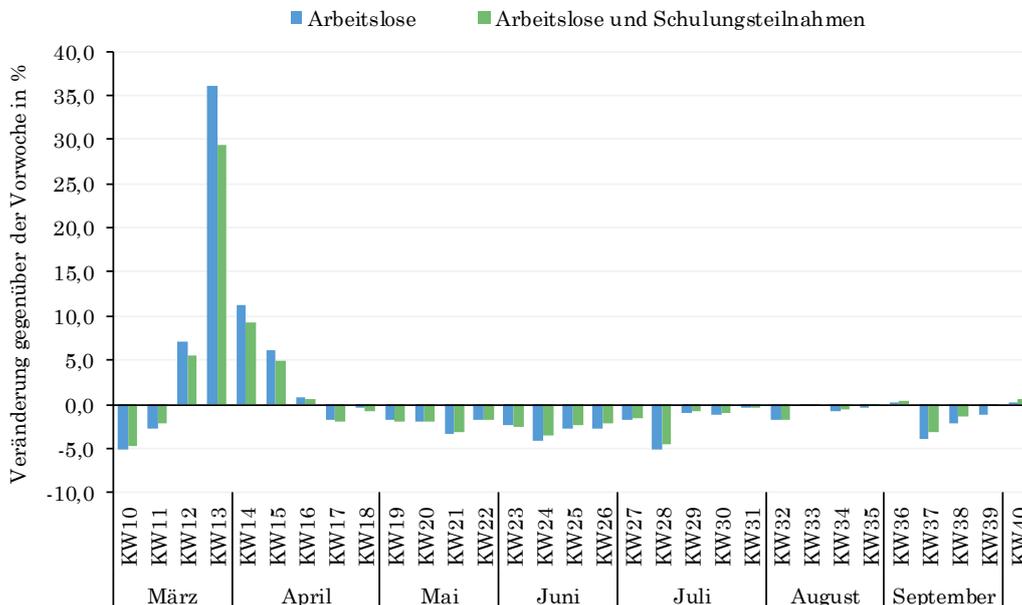
Umfragewerte von Unternehmen zeigen konjunkturelle Veränderungen sehr rasch an. Aus diesem Grund werden auch ausgewählte Indikatoren aus einer speziellen Wochenauswertung des **WIFO-Konjunkturtests** einbezogen, welche in den Monaten März und April die Veränderung der Einschätzungen der Unternehmen im Wochenverlauf zeigen. Wir betrachten den Lageindex der Gesamtwirtschaft, welcher jene Fragen des WIFO-Konjunkturtests zusammenfasst, die die derzeitige Situation und die rezente Geschäftsentwicklung der befragten Unternehmen betreffen.

Die Daten zum **Arbeitsmarktgeschehen** (Arbeitslosigkeit, offene Stellen, Kurzarbeit, unselbständige Beschäftigung) bilden die unmittelbare Reaktion des Arbeitsmarktes auf die Maßnahmen der Bundesregierung zur Bewältigung der COVID-19-Pandemie zwischen Mitte März und den schrittweisen Lockerungen ab Mitte April bis Anfang Juni ab. Sie liegen auf wöchentlicher und monatlicher Basis vor.⁴ Ab Mitte März stieg die Arbeitslosigkeit innerhalb weniger Tage auf ein Rekordniveau, der Beschäftigungsrückgang erreichte Ende März ein Ausmaß wie zuletzt vor knapp 70 Jahren während der "Stabilisierungskrise 1952/53" (Kramer,

³Der Datensatz wurde von Herrn Hadrien Bosetti (Österreich Werbung) und Herrn Holger Sicking (Österreich Werbung) aufgebaut und uns dankenswerterweise zur Verfügung gestellt.

⁴Siehe: <https://www.bmajf.gv.at/Services/News/Aktuelle-Arbeitsmarktzahlen.html>

Abbildung 6: Arbeitslosigkeit



Quelle: <https://www.bma.fj.gv.at/Services/News/Aktuelle-Arbeitsmarktzahlen.html>
(wöchentlich abgerufen, KW33, KW35: Schätzwerte); WIFO Berechnungen.

1967) und Ende Mai gab es 1.361.000 (geplante) Kurzarbeitsfälle⁵. Nachdem Anfang Juni die meisten Einschränkungen wieder zurückgenommen worden waren, verringerte sich auch die wöchentliche Dynamik am Arbeitsmarkt. Zudem fiel der Beschäftigungsrückgang wieder sukzessive niedriger aus als noch im März oder April (Abbildung 8). Auch der Anstieg der Arbeitslosigkeit (einschließlich Personen in Schulungsmaßnahmen) war zwar immer noch vergleichsweise hoch, allerdings geringer als während der Phase der umfangreichen behördlichen Schließungsmaßnahmen (Abbildung 6). Die (geplante) Kurzarbeit ging im Juni noch zurück und stagnierte danach (Abbildung 7).⁶

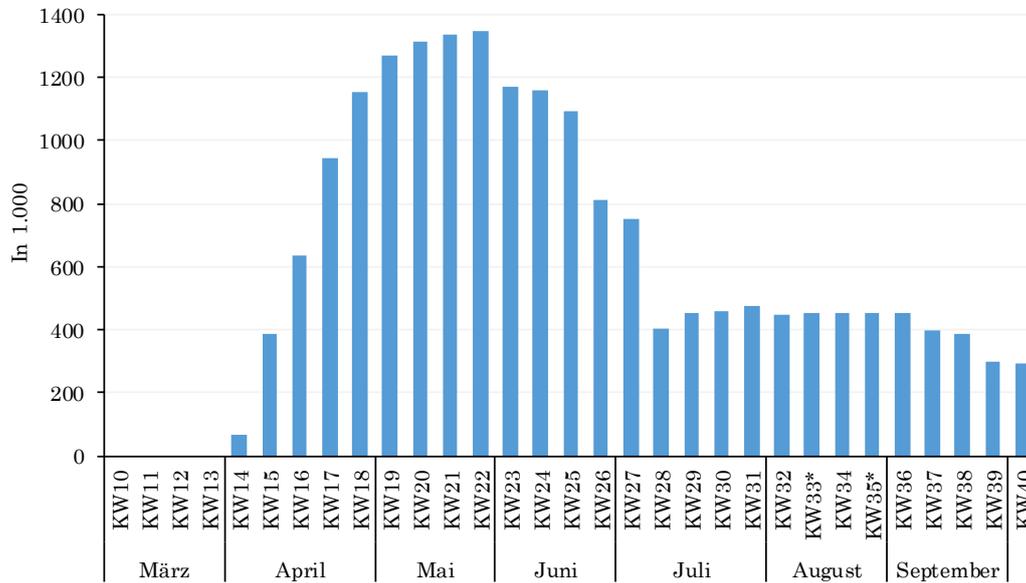
Im Zusammenhang mit hochfrequenten Daten betrachten wir den Informationsgehalt der Finanzmarktvariablen, der für die reale wirtschaftliche Aktivität relevant sein könnte. Zu diesem Zweck erstellen wir einen **Finanzmarktstressindikator** für die österreichische Wirtschaft. Er basiert auf einer täglichen Frequenz und beinhaltet für seine Konstruktion eine breite Palette an Variablen, die Schlüsselmerkmale von finanziellem Stress erfassen. Der Finanzmarktstressindikator wird in Abbildung 10 grafisch dargestellt und in Kapitel 2.5 im Anhang näher behandelt.

Die heimische Wirtschaftsleistung wird zu einem großen Teil vom internationalen Geschehen beeinflusst. Um dessen Entwicklung zeitnah verfolgen zu können, werden die wöchentlichen Aktivitätsindizes für Deutschland und die USA herangezogen. Diese sind zusammengesetzte

⁵Siehe: <https://orf.at/stories/3168917/>

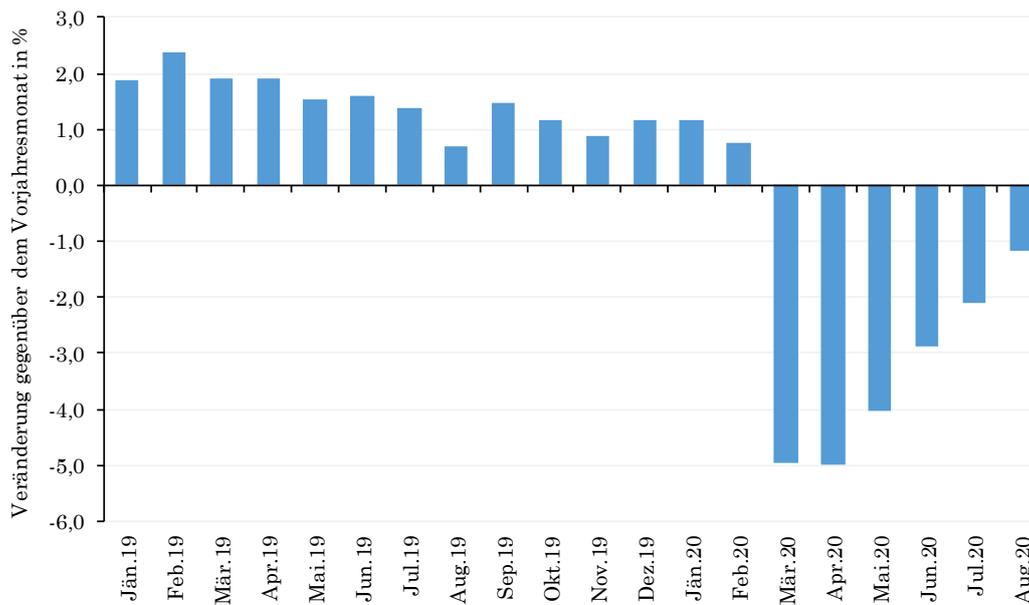
⁶Im Laufe des September war die Zahl der Personen in laufenden Kurzarbeitsprojekten abermals rückläufig.

Abbildung 7: Kurzarbeit



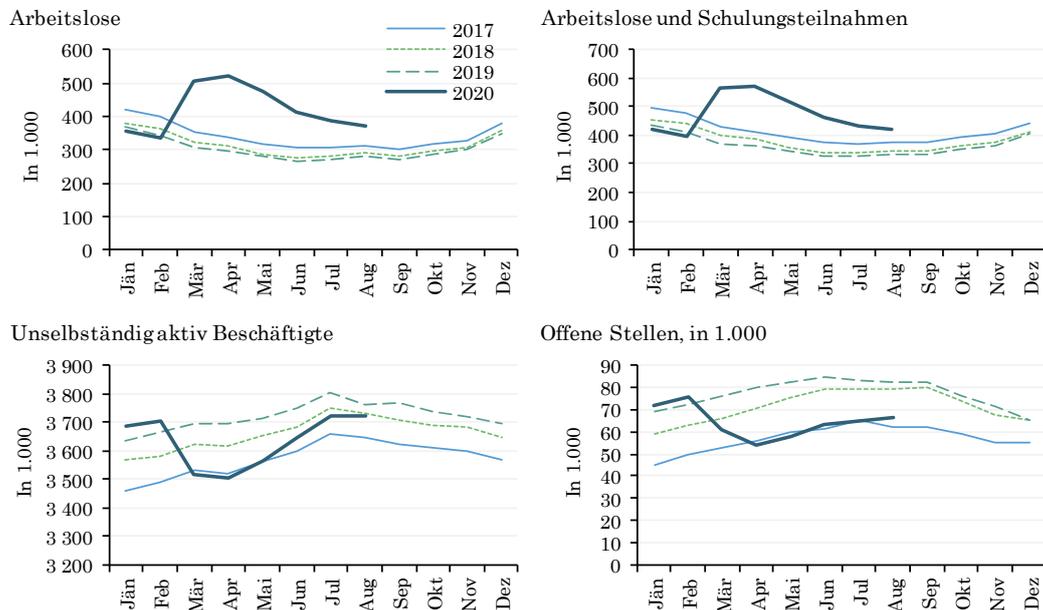
Quelle: <https://www.bmaef.gv.at/Services/News/Aktuelle-Arbeitsmarktzahlen.html>
(wöchentlich abgerufen, KW33, KW35: Schätzwerte); WIFO Berechnungen.

Abbildung 8: Beschäftigung



Quelle: Dachverband der Sozialversicherungsträger. Vor 1.1.2020: Hauptverband der österreichischen Sozialversicherungsträger; WIFO Berechnungen.

Abbildung 9: Arbeitsmarkt



Quelle: AMS, Dachverband der Sozialversicherungsträger. Vor 1.1.2020: Hauptverband der österreichischen Sozialversicherungsträger; WIFO Berechnungen.

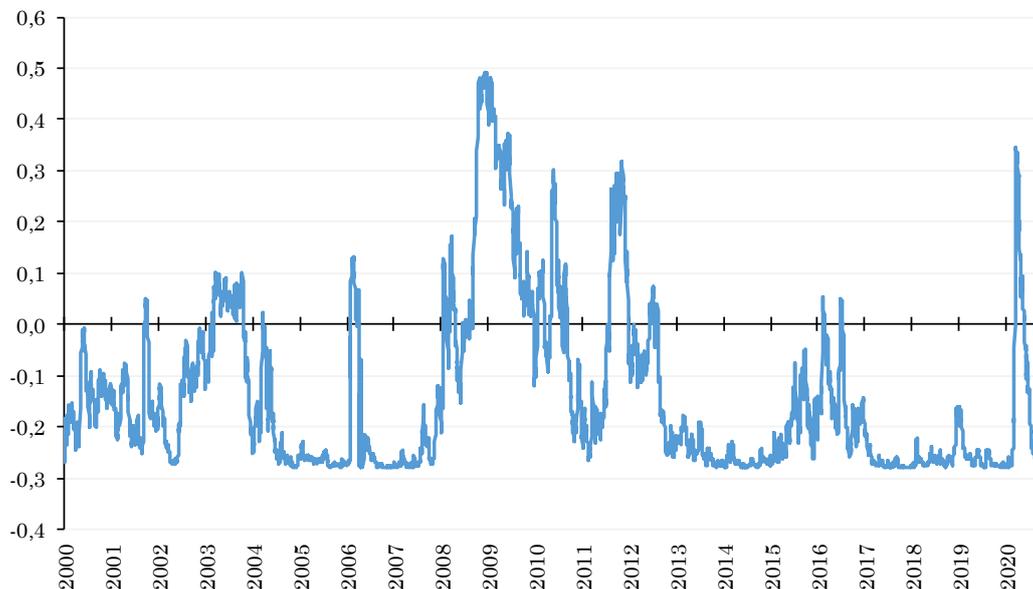
Indikatoren und werden von der Deutschen Bundesbank bzw. der Federal Bank of New York berechnet. Sie basieren auf täglichen, wöchentlichen, monatlichen und vierteljährlichen Indikatoren für die jeweilige Wirtschaft. Die Berechnung der Indikatoren ist in Bundesbank (2020a) und Lewis et al. (2020) beschrieben.

Neben den hochfrequenten Daten enthält der Datensatz auch Variablen auf monatlicher und quartalsweiser Basis. Diese umfassen heimische und internationale Stimmungsindikatoren. Hier werden vor allem Reihen aus dem WIFO-Konjunkturtest herangezogen (Auftragsbestände, Erwartungen sowie Einschätzungen zur aktuellen Lage in den Bereichen Industrie, Bau, Dienstleistungen und Tourismus), aber auch Indikatoren wie Industrieproduktionskennzahlen, Nächtigungszahlen, internationale BIP-Veränderungsraten (Euro-Raum, EU, Deutschland, Italien, MOEL5), Zahl der Flugpassagiere (Flughafen Wien), Handelsumsätze, Warenaußenhandelsdaten, Containerumschlag, und Daten zum Arbeitsmarkt (offene Stellen, Beschäftigung und Tarifföhne).

2.2.3 Korrelationsanalyse

Die Korrelationsanalyse prüft die Fähigkeit von Indikatoren, die Entwicklung der Quartalsaggregate der österreichischen Wirtschaft frühzeitig anzuzeigen. Die Indikatoren sind, wie oben beschrieben, auf Tages-, Wochen-, Monats- bzw. Quartalsfrequenz verfügbar. Das Wachstum des realen BIP und seiner Teilaggregate liegt auf Quartalsbasis vor. Um einen direkten Ver-

Abbildung 10: Finanzmarktstressindikator



Quelle: WIFO Berechnungen.

gleich zwischen den Größen zu ermöglichen, werden die Indikatoren je nach Verfügbarkeit für den Zeitraum vom ersten Quartal 2008 bis zum vierten Quartal 2019 auf Quartalsfrequenz aggregiert.

In einem ersten Schritt wurde das Ausmaß des Gleich- bzw. Vorlaufs (ein, zwei oder drei Quartale voraus) der potenziell zur Auswahl stehenden Indikatoren mit Hilfe von dynamischen Kreuzkorrelationskoeffizienten zwischen den Indikatoren und den Vorjahreswachstumsraten der vierteljährlichen Referenzreihe geprüft. Um die Auswahl zu treffen, wurden zunächst alle Indikatoren mit zumindest einem Korrelationskoeffizienten von 0,5 nach der Summe der absoluten Korrelationskoeffizienten gereiht. Ein hoher absoluter Wert des Korrelationskoeffizienten impliziert, dass der Indikator die Entwicklung der Referenzreihe gut abbildet. Ein hoher absoluter Korrelationskoeffizient mit einer verzögerten Referenzreihe deutet auf eine Vorlaufeigenschaft des Indikators hin. Jene Indikatoren, die weder kontemporär noch vorlaufend einen absoluten Wert des Korrelationskoeffizienten von mindestens 0,5 ausweisen, werden nicht weiter berücksichtigt. Die Korrelationsauswertung wird durch weitere zwei Maße ergänzt: der Prozentsatz korrekt erkannter Richtungsänderungen (*directional change* – DRC) und die statistische Kennzahl zur zyklischen Quartalsdominanz (*quarters-for-cyclical-dominance* – QCD). Um die Häufigkeit der korrekten Anzeige der Richtungsänderung zu bestimmen, vergleichen wir die Änderung (Anstieg oder Abnahme) eines Indikators mit der Änderung der Wachstumsrate der Referenzreihe. Die Kennzahl DRC gibt den Prozentsatz der Perioden wieder, in denen der Indikator die Richtungsänderung der Referenzreihe korrekt anzeigt.

Ein aussagekräftiger Indikator liefert einen zeitnahen und zuverlässigen Hinweis auf zyklische Entwicklungen einer volkswirtschaftlichen Referenzreihe. Meist wird das in einem Indikator enthaltene Signal von unsystematischem Hintergrundrauschen (Noise) begleitet. Filtertechniken können verwendet werden, um zwischen zyklischen und unregelmäßigen Bewegungen von Zeitreihen zu unterscheiden. Die gefilterten Reihen sind jedoch am aktuellen Rand oft weniger zuverlässig. Ein alternativer Ansatz besteht darin, die Unterscheidung zwischen einer echten zyklischen Bewegung und der unsystematischen Volatilität auf der Grundlage der Entwicklung in der Vergangenheit zu treffen. Das Verhältnis des Rauschens zum zyklischen Signal, das in einer Zeitreihe enthalten ist, ist daher ein Qualitätskriterium für den Indikator. Dieses Verhältnis zeigt die Anzahl der Perioden an, für welche die Änderung des Indikators beobachtet werden muss, um eine tatsächliche zyklische Entwicklung in der Referenzreihe mit hoher Wahrscheinlichkeit zu erkennen. Der Wert der QCD ist die Anzahl der Quartale, bei denen das Verhältnis des Rauschens zum zyklischen Signal zum ersten Mal kleiner als eins wird. Daher ist ein Indikator mit einem niedrigen QCD-Wert einem Indikator mit einer hohen QCD vorzuziehen.

In den Übersichten in Abschnitt 2.6 werden die 25 geeignetsten Indikatoren für die jeweilige Referenzreihe sowie die für ihre Bewertung wichtigen Maßzahlen dargestellt. Über alle Referenzreihen hinweg stellen sich besonders häufig die LKW-Fahrleistung laut ASFINAG, die beim AMS gemeldeten offenen Stellen, Stimmungsindikatoren aus dem WIFO-Konjunkturtest sowie das Wirtschaftswachstum der wichtigsten Handelspartner als verlässliche Vorlaufindikatoren heraus.

Für die Entwicklung des heimischen **BIP** spielt vor allem die wirtschaftliche Aktivität im Euro-Raum und in Italien eine wichtige Rolle. Darüber hinaus zeigen auch die beim AMS gemeldeten offenen Stellen, sowohl in der Industrie als auch im Dienstleistungsbereich eine gute Vorlaufeigenschaft. Das gilt ebenso für Umfragewerte aus dem WIFO Konjunkturtest. Unter den hochfrequenten Indikatoren sind die Fahrleistung, die Aktivitätsindikatoren der Deutschen Bundesbank (DB) und der Federal Reserve Bank of New York (FedNY) besonders relevant.

Die Dynamik in der **Industrie** wird in hohem Maße durch die wöchentlichen Aktivitätsindikatoren der Handelspartner Deutschland (DB) und den USA (FedNY), sowie die Erwartungen und die offenen Stellen in diesem Sektor und der LKW-Fahrleistung laut ASFINAG vorweggenommen.

In Bezug auf den **Bausektor** stellen sich zusätzlich zu den monatlichen Aktivitätsindikatoren und Arbeitsmarktdaten hochfrequente Zahlungsverkehrsdaten als besonders informativ heraus.

Die Entwicklung im **Tourismus** wird durch die Lagewahrnehmung und Erwartungen in diesem Sektor und im Dienstleistungssektor insgesamt gut vorausgeschätzt. Die Anzahl

der Flüge von und nach Österreich zeigt sich ebenfalls als verlässlicher Frühindikator für die Wertschöpfung im Tourismus. Unter den hochfrequenten Daten stellen sich Zahlungsverkehrsgrößen aus nationalen und grenzüberschreitenden Interbankzahlungen als belastbare Vorlaufindikatoren heraus. Um die Nachfrage aus dem Ausland abzubilden, kommt dem BIP-Wachstum in der EU, insbesondere in den MOEL5, eine wichtige Rolle zu.

Für das Wachstum im restlichen **Dienstleistungssektor** sind vor allem die Entwicklung im Außenhandel, die Stimmungslage in der Industrie sowie die Erwartungen im Dienstleistungssektor indikativ.

Um die Entwicklung des **Konsums der privaten Haushalte** vorausschätzen zu können erweisen sich vor allem die hochfrequenten Zahlungsverkehrsdaten als hilfreich. Weiters wird eine vorlaufende Eigenschaft von Schadstoffemissionen festgestellt, wobei diese ökonomisch schwer zu erklären ist. Hingegen liefern Umfragewerte zum Konsumentenvertrauen sowie Arbeitsmarktzahlen, für welche man auf der Basis wirtschaftstheoretischer Überlegungen einen Zusammengang erwarten würde, kaum passende Erklärungswerte.

Offenen Stellen (aus Industrie und Dienstleistungen) sowie internationale Vertrauensindikatoren aus der Industrie weisen einen hohen Informationsgehalt für die **Investitionsnachfrage** (Bruttoanlageinvestitionen) auf. Darüber hinaus zeigen die wöchentlichen Werte der LKW Fahrleistung sowie der Index der Federal Bank of New York einen guten Zusammenhang. Erwartungen hinsichtlich der zukünftigen Entwicklung (aus der Industrie sowie speziell zur Herstellung von Investitionsgütern) sind ebenfalls von Bedeutung.

Um die **Exporte** abzubilden, kommt ausländischen BIP-Wachstumsraten, insbesondere in Italien, Deutschland und dem Euro-Raum, eine wichtige Rolle zu. Darüber hinaus haben auch die LKW-Fahrleistung, der Containerumschlag und der gewichtete Vertrauensindikator der Industrie der Exportmärkte gute Eigenschaften um die Entwicklung der Exporte zeitnah zu erkennen.

Die Entwicklung der **Importe** von Waren und Dienstleistungen korreliert sehr stark mit jener der LKW Fahrleistung, den Warenexporten sowie dem Produktionsindex der Industrie. Unter den hochfrequenten Daten sind auch der wöchentliche Index der Federal Bank of New York sowie der Baltic Dry Index relevant.

2.3 Direkter Ansatz zur Echtzeitschätzung und Prognose des BIP auf wöchentlicher Basis

Dieser Abschnitt beschreibt den Wöchentlichen-WIFO-Wirtschaftsindex (WWWI), der entwickelt wurde, um die rasche wirtschaftliche Entwicklung im Zusammenhang mit der COVID-19-Pandemie in Österreich zu verfolgen. Der WWWI basiert auf einem Modell gemischter Frequenzen (wöchentliche, monatliche und vierteljährliche Daten) und ist normiert auf die

jährlichen Zuwachsraten des österreichischen Bruttoinlandsproduktes (BIP). Dies erlaubt es, die Indexwerte als Zuwachsraten des BIP gegenüber der Vorjahresperiode auf vierteljährlicher Basis zu interpretieren. Die Konstruktion, sowie technische und datenspezifische Details dazu finden sich in Abschnitt 2.3.1. Die Verwendung des WWWI im Rahmen einer Gesamtjahresprognose wird in der Folge in Abschnitt 2.3.2 beschrieben und im Vergleich zu alternativen Ansätzen diskutiert.

2.3.1 Wöchentlicher-WIFO-Wirtschaftsindex (WWWI)

Die Schätzung des aktuellen Zustands der Wirtschaft und die Vorhersage zukünftiger Werte makroökonomischer Variablen sind wichtige Aufgaben im Kontext der Konjunkturanalyse. Zahlen zum BIP, dem wichtigsten Indikator für wirtschaftliche Aktivität, werden in der Regel vierteljährlich mit einer Verzögerung von mindestens einem Monat gemeldet. In Zeiten eines rasanten Einbruchs der Wirtschaftsleistung sind genaue und zeitnahe Einschätzungen des BIP notwendig, um sich ein aufschlussreiches Bild von der gegenwärtigen und zukünftigen Wirtschaftslage machen zu können.

Der WWWI wird in einer Form spezifiziert, dass er die reale wirtschaftliche Aktivität in wöchentlichen Abständen misst. Hierfür werden hochfrequente Daten verwendet, die bereits in Kapitel 2.2.2 beschrieben wurden. Im Folgenden werden spezifische für die Konstruktion des WWWI relevante Details dazu erläutert.

Herausforderungen im Rahmen der Konstruktion des WWWI. Durch die zunehmende Verfügbarkeit großer Datensätze (big-data) sowie hochfrequenter Zeitreihen werden zusätzliche Informationen über den Konjunkturzyklus zugänglich. Sie können sowohl für makroökonomische Echtzeiteinschätzungen (d.h. Schätzung der aktuellen Position einer Volkswirtschaft im Konjunkturzyklus) als auch für Prognosen hilfreich sein. Die Herausforderung bei der Verwendung solcher Daten besteht allerdings darin, dass sie in der Regel in unterschiedlichen Frequenzen und am aktuellen Rand in unvollständiger Form vorliegen. Dies erfordert den Einsatz von Modellen, die in der Lage sind, diese Heterogenität in Bezug auf die Frequenz, Anzahl der Variablen und Länge der Zeitreihen zu berücksichtigen. Insbesondere die Nutzung von in Echtzeit verfügbaren Indikatoren erfordert ein effizientes Werkzeug, um zwei Hauptherausforderungen zu bewältigen: Erstens, wie kann mit der Besonderheit der unterschiedlichen Datenfrequenz der verfügbaren Zeitreihen umgegangen werden, indem beispielsweise tägliche Finanzdaten mit monatlichen Variablen und vierteljährlichen Indikatoren abgeglichen werden. Zweitens, wie können nützliche Informationen extrahiert werden, d.h. wie sollen die wichtigsten gemeinsamen Komponenten aus dem Querschnitt der verfügbaren Indikatoren identifiziert werden.

Die Verwendung von Modellen, die sich zum Einsatz bei Datensätzen mit unterschiedlichen

Frequenzen eignen hat zwei Vorteile. Einerseits erlaubt es uns, mehr Informationen zu nutzen, um einen unbeobachteten Zustand der Wirtschaft zu identifizieren. Zum anderen erlauben diese Modelle zeitnahe Aktualisierungen der wichtigsten makroökonomischen Variablen und liefern genaue Prognosen und Echtzeiteinschätzungen (Nowcasting) der wirtschaftlichen Aktivität.

Nur wenige der Datenveröffentlichungen von Behörden, öffentlichen Einrichtungen, etc., mit denen Volkswirte häufig arbeiten, sind in wöchentlicher oder höherer Frequenz verfügbar. Unsere wöchentlichen Reihen stammen stattdessen meist aus privaten Quellen wie in Kapitel 2.2 beschrieben. Finanzmarktdaten, wie Börsenkurse und Zinssätze, sind ebenfalls in hoher Frequenz verfügbar. Letztere verwenden wir beim Aufbau des WWWI hingegen nicht, da es unser Ziel ist, ein direktes Maß für die realwirtschaftliche Aktivität und nicht für die finanziellen Bedingungen zu erhalten.⁷

Die makroökonomische Literatur zur Prognose mit Modellen mit gemischten Frequenzfaktoren konzentriert sich hauptsächlich auf Daten mit einer monatlichen und vierteljährlichen Frequenz. Der EUROMIND-Indikator von Frale et al. (2010, 2011) oder das dynamische Faktormodell mit stochastischer Volatilität von Marcellino et al. (2016) sind u.a. empirische Illustrationen dazu, wie das BIP monatlich, möglicherweise in Echtzeit, verfolgt und prognostiziert werden kann. Kürzlich schlugen Andreou et al. (2016) eine neuartige, für große Panels gültige gruppierte Faktorenanalyse vor und identifizierten die Industrieproduktion als den dominierenden Faktor für die US-Wirtschaft.

Datenaufbereitung. Für den Beobachtungszeitraum ab Jänner 2000 wird zur Berechnung des WWWI eine nicht beobachtete Komponente aus wöchentlichen, monatlichen und vierteljährlichen Zeitreihen extrahiert. Die wöchentlichen Daten umfassen derzeit 14 Zeitreihen wie die LKW-Fahrleistung (ASFINAG), Stromverbrauch, Kreditkartentransaktionsvolumina (inländisch, international, E-commerce), Arbeitslosigkeit, Stickstoffdioxid-Ausstoß (NO₂), SEPA-EDIFACT-TN Zahlungsverkehr (Anzahl sowie Volumina von Transaktionen), Google-Daten zur Mobilität (Einzelhandel und Freizeit, Lebensmittelhandel und Apotheken, Bahnhöfe und Haltestellen, Arbeitsplätze), Daten zu Passagier- und Frachtflügen sowie Daten aus den Wochenauswertungen ausgewählter Indikatoren aus dem WIFO-Konjunkturtest (Lageindex der Gesamtwirtschaft). Die monatlichen Daten umfassen Stimmungsindikatoren aus dem WIFO-Konjunkturtest und harte Indikatoren wie Industrieproduktions- und Arbeitsmarktkennzahlen (Beschäftigung und offene Stellen). Die Selektion der Variablen basiert neben der in Abschnitt 2.2.3 diskutierten Korrelationsanalyse auch auf einem kombinatorischen Algorithmus (siehe Glocker und Wegmüller, 2020). Hierbei ist das BIP die einzige Reihe auf Basis einer Quartalsfrequenz im Modell. Details zu den jeweiligen Reihen, vor allem zu jenen,

⁷Diese Daten werden im Rahmen der Erstellung von Prognosen auf Basis des WWWI berücksichtigt (siehe Abschnitt 2.3.2).

die auf einer wöchentlichen Frequenz vorliegen, sowie zur Auswahl der Indikatoren finden sich in Abschnitt 2.2.

Wir transformieren alle Reihen so, dass sie prozentuale 52-Wochen-Änderungen darstellen,⁸ wodurch auch die meisten saisonalen Schwankungen in den Daten eliminiert werden. Wie in Abschnitt 2.2 zu sehen ist, weisen einige der wöchentlichen Reihen von Woche zu Woche ein beträchtliches Rauschen auf, so dass es schwierig sein kann, umfassendere Trends aus einer einzelnen Reihe zu ermitteln. Die Reihen weisen jedoch auch ein deutliches zyklisches Muster auf, was darauf hindeutet, dass sie sinnvollerweise zu einem einzigen Index zusammengefasst werden könnten.

Zur Konstruktion des WWWI. Ein ökonometrischer Rahmen für die Konstruktion eines Wirtschaftsindex wie dem WWWI aus mehreren Zeitreihen ist das sogenannte dynamische Faktormodell, das von Geweke (1976) und Sargent und Sims (1977) entwickelt wurde. Das Modell der dynamischen Faktoren postuliert die Existenz einer kleinen Anzahl unbeobachteter oder latenter Reihen, genannt Faktoren, die die gemeinsamen Bewegungen der beobachteten wirtschaftlichen Zeitreihen antreiben. Die Anwendung von Modellen mit dynamischen Faktoren zur Schätzung von Wirtschaftsindizes reicht von der Konstruktion von Indizes der wirtschaftlichen Aktivität auf bundesstaatlicher Ebene (Clayton-Matthews und Crone, 2004) bis hin zu groß angelegten Indizes der gesamtwirtschaftlichen Aktivität (siehe Camacho und Pérez-Quirós, 2011; Camacho und García-Serrador, 2014; Stock und Watson, 2016, für einen Überblick).

Wir verwenden zur Konstruktion des WWWI ein Ein-Faktor-Modell auf Basis von drei Frequenzen (wöchentlich, monatlich und vierteljährlich), indem wir Indikatoren auswählen, die signifikante übereinstimmende und vorlaufende Eigenschaften bei der Vorhersage der österreichischen Wirtschaftstätigkeit haben und gleichzeitig sowohl für die Nachfrage als auch für das Angebot repräsentativ sind. Wir übernehmen den kleinräumigen Ansatz von Mariano und Murasawa (2003) im Hinblick auf die Ergebnisse von Boivin und Ng (2006). Wir stellen das Modell in einer Zustandsraumform (state-space representation) dar. Insbesondere verallgemeinern wir die von Frale et al. (2010, 2011) vorgeschlagene Zustandsraumform, um jene Aspekte zu berücksichtigen, die sich aus der zeitlichen Aggregation von drei verschiedenen Frequenzen ergeben. Die modulierte Zustandsraumform wird in Form von teilweise kumulierten hochfrequenten Reihen mit fehlenden Beobachtungen vereint. Im Rahmen der Schätzung wird der Kalman-Filter angewendet; dies erlaubt nicht bloß die Schätzung der Modellparameter, sondern auch der fehlenden Werte der Datenreihen am aktuellen Rand. Damit wird eine Echtzeiteinschätzung der aktuellen wirtschaftlichen Aktivität sowie die Erstellung von Prognosen ermöglicht.

⁸Die Daten wurden um spezifische Besonderheiten wie fixe und bewegliche Feiertage, saisonale Effekte, etc. im Vorfeld ihrer Verwendung für den WWWI bereinigt (siehe auch Abschnitt 2.2).

Aus methodologischer Sicht steht unsere Arbeit Aruoba et al. (2009), Schumacher und Breitung (2008), Barhoumi et al. (2008), Marcellino und Schumacher (2010), Angelini et al. (2011) und Banbura und Rünstler (2011) nahe, die einen Rahmen vorschlagen, um wirtschaftliche Aktivitäten in Echtzeit zu verfolgen, wobei Daten verwendet werden, die mit einer Vielzahl von unterschiedlichen Frequenzen verfügbar sind. Die Hauptidee dieser Studien besteht darin, die Prognosegüte für die Gegenwart (Nowcasting) durch den Einsatz hochfrequenter Daten zu verbessern, die entweder den Prognosehorizont teilweise abdecken oder einen robusten Frühindikator für die zu prognostizierenden Variablen bilden. Dabei greifen sie methodisch in der einen oder anderen Form auf das von Giannone et al. (2008) vorgeschlagene approximative dynamische Faktormodell zurück. Konzeptuell wird in allen obengenannten Studien auf die Verwendung von Brückengleichungen verzichtet, die üblicherweise zur Integration von Hochfrequenzdaten in OLS-Modellen mit gemischten Frequenzen zum Einsatz kommen, z.B. in Rünstler und Sedillot (2003) oder Diron (2006). Diese Studien befassen sich somit mit dem Problem der Erstellung laufender BIP-Prognosen auf Basis von Daten unterschiedlicher Frequenzen. Während sich ihr Ansatz jedoch hauptsächlich auf die Extraktion und Prognose latenter realwirtschaftlicher Aktivitäten konzentriert, wird in diesem Abschnitt dieser Ansatz genutzt um mit Hilfe hochfrequenter Indikatoren die vierteljährlichen Werte des BIP auf eine wöchentliche Frequenz zu disaggregieren. Auf diese Weise erhalten wir zeitnahe Echtzeiteinschätzungen der realwirtschaftlichen Entwicklung, approximativ dargestellt durch die BIP-Wachstumsraten, die auf die offiziellen Veröffentlichungen der Quartalsdaten aus der Volkswirtschaftlichen Gesamtrechnung der Bundesanstalt Statistik Österreich aufbauen.

Die Prämisse eines dynamischen Faktormodells ist, dass eine kleine Zahl - in unserer Anwendung ein einziger - latenter Faktoren, f_t die gemeinsamen Bewegungen eines Vektors von N Zeitreihen, \mathbf{x}_t antreibt. Das Modell des dynamischen Faktors postuliert, dass die beobachteten Reihen die Summe der dynamischen Wirkung der gemeinsamen Faktoren und einer idiosynkratischen Komponente, \mathbf{e}_t ist, die sich aus Messfehlern und aus diversen anderen besonderen Merkmalen ergeben, die spezifisch für eine einzelne Datenreihe sind. Die ökonometrische Spezifikation ist wie folgt

$$\mathbf{x}_t = \boldsymbol{\lambda} f_t + \mathbf{e}_t \tag{1}$$

$$(1 - \varphi(L)) f_t = \nu_t \quad \text{mit} \quad \nu_t \sim N(0, \sigma_\nu^2) \tag{2}$$

$$(I - \Phi(L)) \mathbf{e}_t = \mathbf{u}_t \quad \text{mit} \quad \mathbf{u}_t \sim N(\mathbf{0}, \Sigma_{\mathbf{u}}) \tag{3}$$

wobei L der Verzögerungsoperator ist, ν_t und \mathbf{u}_t sind Fehlerterme und $\Sigma_{\mathbf{u}} = \text{diag}(\sigma_1^2, \dots, \sigma_N^2)$ ist die Varianz-Kovarianzmatrix. $\varphi(L)$ und $\Phi(L)$ sind univariate und multivariate Verzögerungspolynome und der Parameter σ_ν^2 wird aus Gründen der Identifikation gleich eins gesetzt. Die Elemente des $N \times 1$ Vektors $\boldsymbol{\lambda}$ sind die Faktorladungen und $\lambda_i f_t$ mit $\lambda_i \in \boldsymbol{\lambda}$ erfasst die gemeinsame Komponente der i -ten Datenreihe.

Beim Umgang mit gemischten Frequenzen muss das Modell modifiziert werden. Sobald die Basisfrequenz festgelegt ist, kann das Modell in Form von teilweise beobachteten Reihen definiert werden. Das Problem der gemischten Frequenzen wird hierbei in ein Problem fehlender Werte umgewandelt, das sich mit Hilfe des Kalman-Filters leicht beheben lässt.

Formal wird der Vektor \mathbf{x}_t in drei Gruppen aufgeteilt:

$$\mathbf{x}_t = \begin{bmatrix} \mathbf{x}_t^W \\ \mathbf{x}_t^M \\ \mathbf{x}_t^Q \end{bmatrix} \quad (4)$$

wobei die erste Gruppe (der Dimension N_1) jene Variablen enthält, die in der höchsten Frequenz (d.h. die wöchentliche Frequenz) vorliegen, während die restlichen zwei Blöcke (mit den Dimensionen N_2 und N_3) den Satz an Variablen enthalten, die monatlich und vierteljährlich verfügbar sind. Es gilt: $N = \sum_{i=1}^3 N_i$. Da die Basisfrequenz des Modells eine wöchentliche ist, werden alle Variablen in \mathbf{x}_t auch in dieser Frequenz ins Modell aufgenommen, allerdings mit fehlenden Werten.

Im Vorfeld der Schätzung werden die Zeitreihen in \mathbf{x}_t standardisiert. Dies vereinfacht den Prozess der Schätzung, weil zum einen weniger Parameter geschätzt werden müssen und sich zum anderen die Bestimmung von Anfangswerten für das Schätzverfahren sich deutlich einfacher gestaltet. Letzteres spielt in diesem Kontext vor allem deswegen eine Rolle, da das Modell, gegeben durch die Gleichungen (1)–(3) in ein Zustandsraummodell verpackt und im Anschluss mit dem Kalman-Filter geschätzt wird.

Die beiden primären Methoden zur Schätzung des unbeobachteten Faktors f_t sowie der Modellparameter sind die Hauptkomponentenanalyse und die Zustandsraummethode. Wir haben ursprünglich beide Methoden bei der Bestimmung des WWWI verwendet. Allerdings reagierten die Ergebnisse, die mit der Hauptkomponentenanalyse erzielt werden, empfindlich auf Spezifikationsdetails (Verzögerungen, Stichprobenlänge usw.), weshalb die Zustandsraummethode in der vorliegenden Analyse verwendet wird.

Der Wöchentliche-WIFO-Wirtschaftsindex (WWWI) ist sodann durch den latenten Faktor f_t gegeben. Da der Faktor, der sich aus dieser Modellschätzung ergibt, bloß ein Index ist, kann er in der Regel lediglich in Bezug auf seinen zeitlichen Verlauf interpretiert werden, nicht jedoch seine konkreten Indexwerte. Um dennoch neben dem Verlauf auch die Werte des Index interpretierbar zu gestalten, wird folgende Transformation vorgenommen: Der WWWI wird auf die Werte der Veränderungsraten des BIP zum entsprechenden Vorjahresquartal (year-on-year-Wachstumsraten, y-o-y) skaliert, sodass der Mittelwert und die Standardabweichung des WWWI mit jenen der vierteljährlichen Vorjahreswachstumsraten des BIP vom ersten Quartal 2000 bis zum vierten Quartal 2019 übereinstimmen. Ein Wert von 2 Prozent in einer bestimmten Woche bedeutet daher, dass wir ein durchschnittliches Wachstum von 2 Prozent

im Vergleich zum Vorjahresquartal erwarten würden, sofern die Bedingungen dieser Woche ein ganzes Quartal lang anhalten würden.

Robustheit. Der WWWI wurde umfangreich bezüglich seiner Robustheit gegenüber Änderungen in den Details seiner Konstruktion geprüft. Das Wegnehmen oder Hinzufügen einzelner Zeitreihen hat nur geringe Auswirkungen auf seinen Gesamtpfad; dasselbe gilt für die Schätzung der Faktorladungen (λ_i) für jede Zeitreihe in \mathbf{x}_t . Das obere Panel in Abbildung 11 vergleicht unsere Basisversion des WWWI (blaue Linie) mit einem modifizierten Index (grüne Linie) auf Basis einer Untergruppe von lediglich sieben Variablen (ohne Autobahnverkehr, Kreditkartendaten und Stromverbrauch). Das mittlere Panel stellt eine Version dar, in der wir die Google-Mobilitätsdaten nicht verwenden. Beide Abbildungen veranschaulichen, dass das gemeinsame Signal nicht durch die spezifische Wahl der Reihen bestimmt wird. Das untere Panel von Abbildung 11 stellt den WWWI-Basisverlauf einer Reihe gegenüber, die mit Gewichten berechnet wurde, die nur anhand von Daten ab 2015 geschätzt wurden. Der ähnliche Verlauf beider Indizes weist darauf hin, dass die Beziehung zwischen den Zeitreihen während und nach der Finanzmarktkrise vergleichsweise konstant war.

Echtzeitaktualisierung. Der WWWI wird in der Woche nach der Veröffentlichung der zugrunde liegenden wöchentlichen Daten neu berechnet und aktualisiert. Jede WWWI-Aktualisierung enthält eine vorläufige Schätzung all jener Wochenwerte, die zum Zeitpunkt der Aktualisierung noch nicht verfügbar waren.

Unser Verfahren zur Erstellung der Werte am aktuellen Rand basiert auf vorläufigen Werten, weil diverse dem WWWI zugrundeliegende Zeitreihen eine Publikationsverzögerung aufweisen. Dies betrifft nicht bloß die wöchentlichen Zeitreihen, sondern insbesondere die monatlichen. Letztere werden immer am Monatsende aktualisiert, woraus sich bei einer Berechnung des WWWI am Monatsende Revisionen sowohl aufgrund der wöchentlichen als auch der monatlichen Zeitreihen ergeben. Zur Bewertung der Sensibilität des WWWI bezüglich der Revisionen im Rahmen einer Echtzeitaktualisierung werden mehrere historische Aktualisierungen zu diversen Zeitpunkten miteinander verglichen. Beginnend mit der letzten Aprilwoche 2020 stellen wir in Abbildung 12 für alle Wochen des Zeitraumes (Ende) April bis (Ende) August die Werte der jeweiligen Wochen dar, die sich im Rahmen der wöchentlichen Aktualisierungen ergaben. In Abbildung 12 beschreibt die blaue Linie jene Werte, die für jede Woche erstmalig geschätzt worden sind (Echtzeitaktualisierung zum Zeitpunkt t). Die hellgrüne Linie beschreibt für jede Woche den zweiten Wert, d.h. aus einer Schätzung, die eine Woche später vorgenommen wurde (Backcast zum Zeitpunkt $t + 1$). Die dunkelblaue Linie beschreibt jene Werte, die sich im Zuge einer dritten Schätzung, d.h. mit zwei Wochen Verzögerung ergeben (Backcast mit $t + 2$). Die Differenz der Linien zueinander gibt Aufschluss bezüglich der Ungenauigkeit des WWWI am aktuellen Rand. Es zeigt sich, dass sich im Rahmen der Backcasts (hellgrüne und dunkelblaue Linien) keine nennenswerten Unterschiede

Abbildung 11: Robustheit

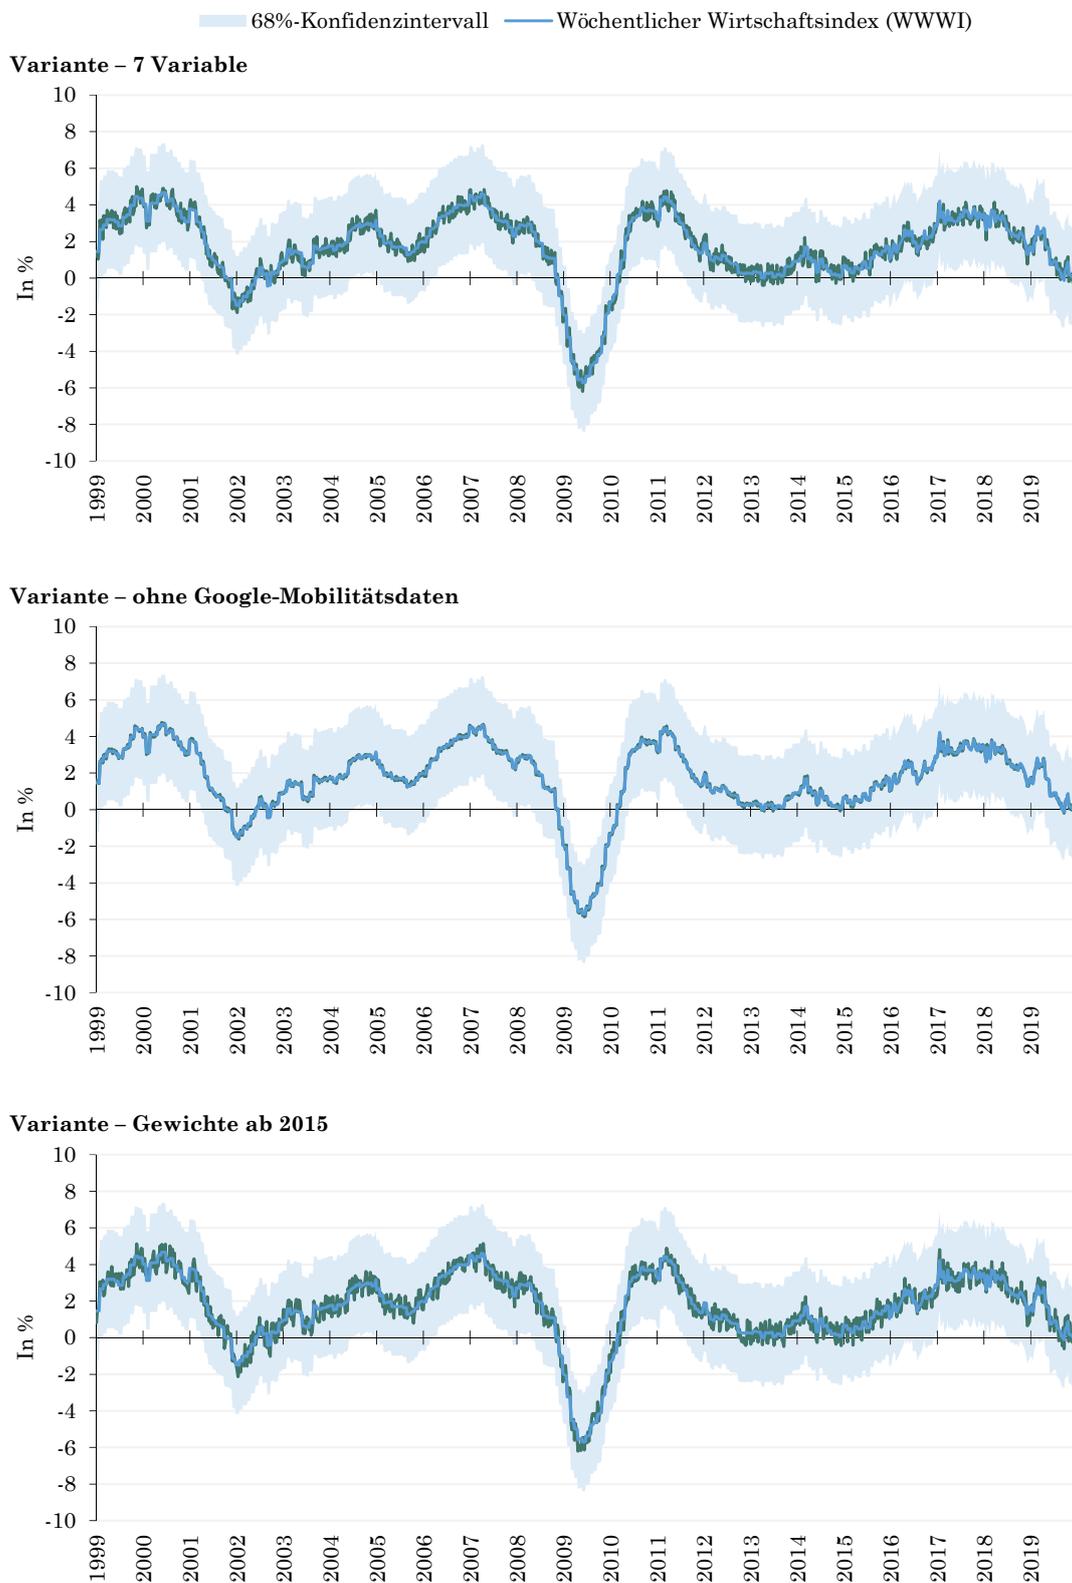
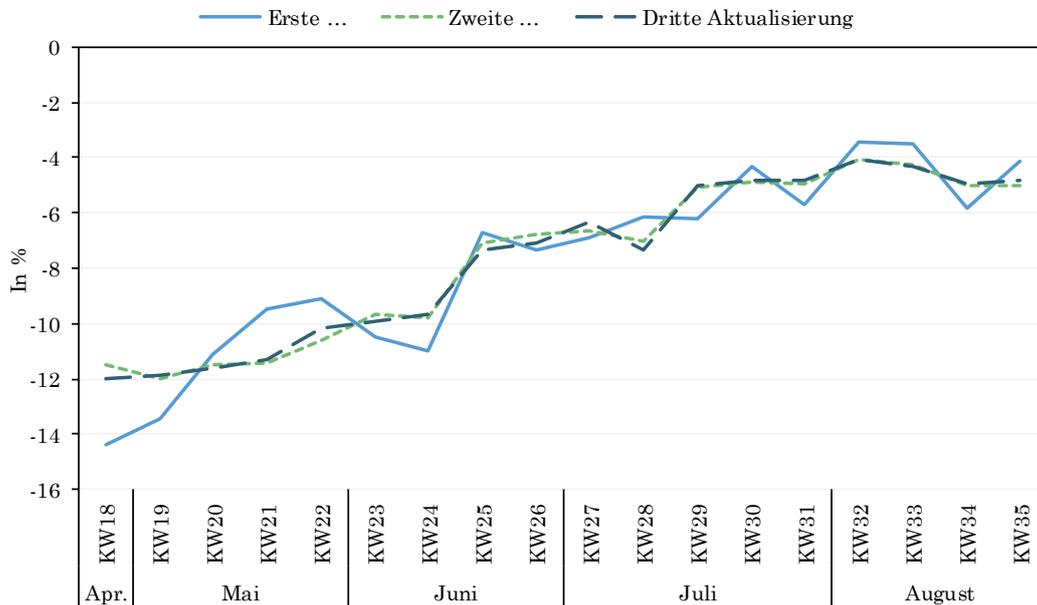


Abbildung 12: Echtzeitaktualisierung



ergeben. Unsicherheiten im Rahmen der wiederholten Aktualisierung ergeben sich in erster Linie zwischen den ersten und zweiten Werten der jeweiligen Wochen. Bei genauerer Betrachtung zeigt sich, dass diese Diskrepanz keine Systematik aufweist, d.h. keine serielle Korrelation, sowie einen Mittelwert von Null hat. Die Revisionen zwischen erster und zweiter Schätzung entsprechen somit, technisch gesehen, einem weißen Rauschen und beinhalten keine Informationen, die zu einer Verbesserung der Schätzung beitragen könnten.

Der WWWI im Vergleich. Das obere Panel in Abbildung 13 stellt den WWWI zusammen mit der Vorjahreswachstumsrate des realen BIP dar (Wachstumsraten auf Basis der Vorjahresquartale, y-o-y). Die vierteljährlichen BIP-Wachstumsraten werden, wie bereits zuvor beschrieben, zur Skalierung des WWWI verwendet. Das Panel zeigt die Entwicklung des WWWI von Jänner 2000 bis zu seinem aktuellsten Wert im Vergleich zum realisierten BIP-Wachstum bis einschließlich zweites Quartal 2020 (letzter Wert gemäß Quartalsrechnung der Bundesanstalt Statistik Österreich laut Eurostat-Vorgabe). Es zeigt sich ein starker Gleichlauf des WWWI mit dem BIP. Die Entwicklungen im Zusammenhang mit der COVID-19-Rezession führten dazu, dass der WWWI in den Wochen ab Mitte März 2020 deutlich unter jene Werte von 2008/09 fiel. Konkret verzeichnete der WWWI einen plötzlichen und starken Rückgang der wirtschaftlichen Aktivität. Ein Tiefpunkt von rund -22 Prozent wird in Kalenderwoche 14 (30. März bis 05. April) erreicht. In der Kalenderwoche 39 (letzte Septemberwoche) liegt der Index bei -2,9 Prozent, womit er sich im Vergleich zum Zeitraum Ende März bis Mitte April deutlich verbesserte, jedoch immer noch einen deutlichen Abstand zur entsprechenden Woche des Vorjahres aufweist. Die rasante Entwicklung in den Monaten März bis Mai ist im WWWI

adäquat abgebildet. Somit leistet der WWWI vor allem in diesen Wochen einen Mehrwert zur Konjunkturanalyse. Außerhalb dieser drei Monate beschreibt der WWWI einen ähnlich persistenten Pfad wie die jährlichen Zuwachsraten des BIP.

Im mittleren Panel in Abbildung 13 wird der WWWI mit einem vergleichbaren Index für die USA (WEI; siehe Lewis et al., 2020) seit Beginn des laufenden Jahres dargestellt. Es zeigt sich, dass der Tiefpunkt der wirtschaftlichen Aktivität in Österreich vergleichsweise stark ausfällt. Vor allem Ende März / Anfang April ist die Lücke sehr große. Die erklärt sich unter anderem durch den stärkeren Einbruch bei den Marktdienstleistungen in Österreich, was wiederum sehr von der Entwicklung im Tourismus geprägt ist. In beiden Ländern hat im April / Mai ein Erholungsprozess eingesetzt. Am aktuellen Rand verläuft die konjunkturelle Entwicklung in beiden Ländern ähnlich.

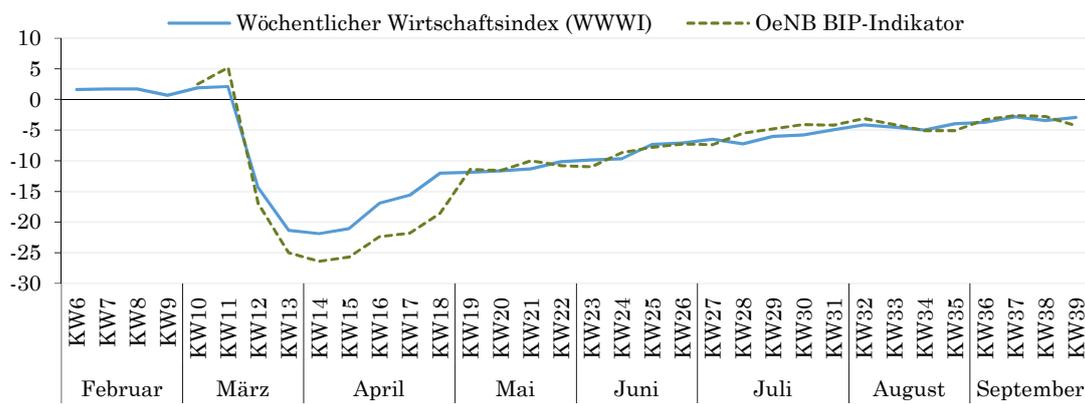
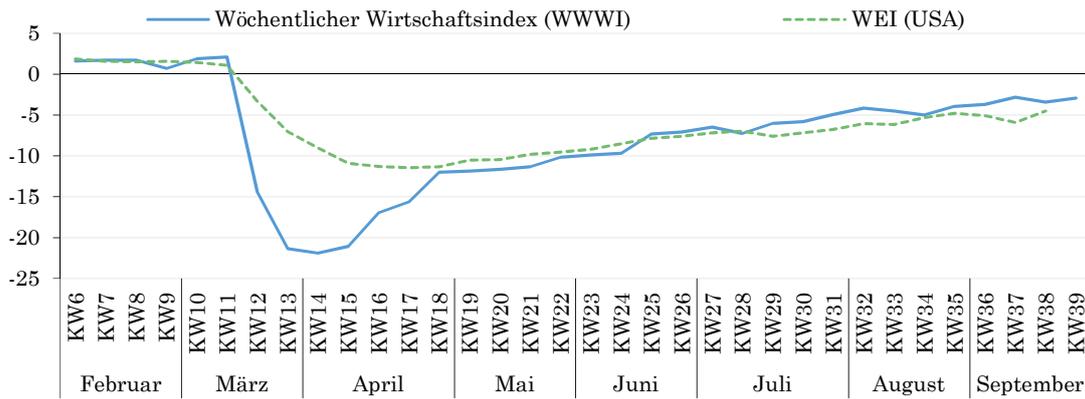
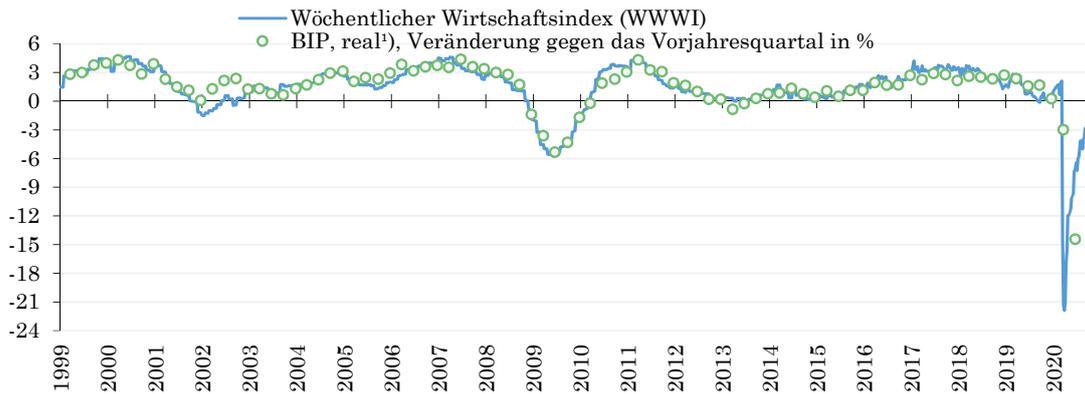
Im unteren Panel in Abbildung 13 wird der WWWI mit dem wöchentlichen Indikator der österreichischen Nationalbank (OeNB) verglichen. Es zeigt sich auf der einen Seite ein starker Gleichlauf. Unterschiede auf der anderen ergeben sich in erster Linie hinsichtlich der quantitativen Einschätzung einzelner Wochen, jedoch nicht in Bezug auf den konjunkturellen Verlauf. Die Unterschiede lassen sich hierbei auf Basis von zwei Elementen erklären. Zum einen gibt es beim Aufbau der wöchentlichen Indikatoren stärkere konzeptionelle Unterschiede (dies betrifft in erster Linie die Frequenzumrechnung von Wochendaten zu Quartalsdaten, aber auch die dynamische Ausgestaltung der Fehlerterme in Form von moving-average (MA) Komponenten, etc.), zum anderen basiert der WWWI auf einem deutlich größeren Indikatorenansatz: der WWWI basiert im Gegensatz zum OeNB-Indikator neben Wochendaten auch auf Monats- und Quartalsdaten; überdies ist der Umfang der wöchentlichen Indikatoren im WWWI größer als dies beim OeNB-Indikator der Fall ist.

Schlussfolgerung. In Nicht-Krisenzeiten liefern bislang häufig verwendete makroökonomische Aggregate mit einer nur kurzen zeitlichen Verzögerung genaue Beschreibungen der wirtschaftlichen Bedingungen. Wenn sich allerdings die Bedingungen von Tag zu Tag und von Woche zu Woche rasch ändern, wie es im Umfeld der COVID-19-Pandemie der Fall war/ist, geben hochfrequente Indikatoren eine valide und zeitnahe Information über den Zustand der Wirtschaft. Der WWWI bietet hierfür eine adäquate Einschätzung des aktuellen Zustandes der österreichischen Volkswirtschaft.

2.3.2 Gesamtjahresprognose auf Basis des WWWI

Das oben vorgestellte Ein-Faktor-Modell lässt eine Dynamik lediglich in der Gleichung des Faktors f_t und in den Fehlertermen e_t zu, was insbesondere im Zusammenhang mit Prognosen zu restriktiv sein kann. Aus diesem Grund betrachten wir ein Faktor-augmentiertes vektorautoregressives Modell (mixed-frequency factor-augmented vector-autoregressive model

Abbildung 13: Wöchentliche Indizes im Vergleich



– MF-FAVAR) auf Basis unterschiedlicher Frequenzen als ein zusätzliches Wochenmodell, das zu Prognosezwecken verwendet wird. Das MF-FAVAR-Modell ermöglicht eine dynamische Interaktion zwischen einem oder mehreren Faktoren \mathbf{f}_t und einem Satz an beobachteten Variablen. Diese Erweiterung erhöht das dynamische Gesamtpotential des Modells. Das Ein-Faktor-Modell kann zu einem MF-FAVAR-Modell erweitert werden, indem lediglich marginale Anpassungen vorgenommen werden. Insbesondere ändert sich Gleichung (1) wie folgt

$$\begin{bmatrix} \mathbf{x}_t^W \\ \mathbf{x}_t^M \end{bmatrix} = \boldsymbol{\lambda} \mathbf{f}_t^* + \mathbf{e}_t^* \quad (5)$$

$$\mathbf{x}_t^Q = \boldsymbol{\lambda}^*(L) \tilde{\mathbf{f}}_t \quad (6)$$

wobei $\tilde{\mathbf{f}}_t$ die wöchentliche BIP-Wachstumsrate darstellt, die aus den vierteljährlichen Wachstumsraten extrapoliert wird. $\boldsymbol{\lambda} \mathbf{f}_t^*$ ist ein latenter Faktor und vergleichbar mit \mathbf{f}_t aus dem Abschnitt 2.3.1 und \mathbf{e}_t^* ein Fehlerterm. Gleichung (6) kann somit als Brückengleichung verstanden werden die im Rahmen einer Frequenzanpassung mittels $\boldsymbol{\lambda}^*(L)$ die Quartalsdaten des BIP in wöchentliche Werte umrechnet. Daher kann $\tilde{\mathbf{f}}_t$ als eine beobachtete Variable behandelt werden. Schließlich ändert sich Gleichung (2) zu

$$(I - \Phi^f(L)) \begin{bmatrix} \mathbf{f}_t \\ \mathbf{y}_t^* \end{bmatrix} = \boldsymbol{\nu}_t^f \quad \text{mit} \quad \boldsymbol{\nu}_t^f \sim N(\mathbf{0}, \Sigma_f) \quad (7)$$

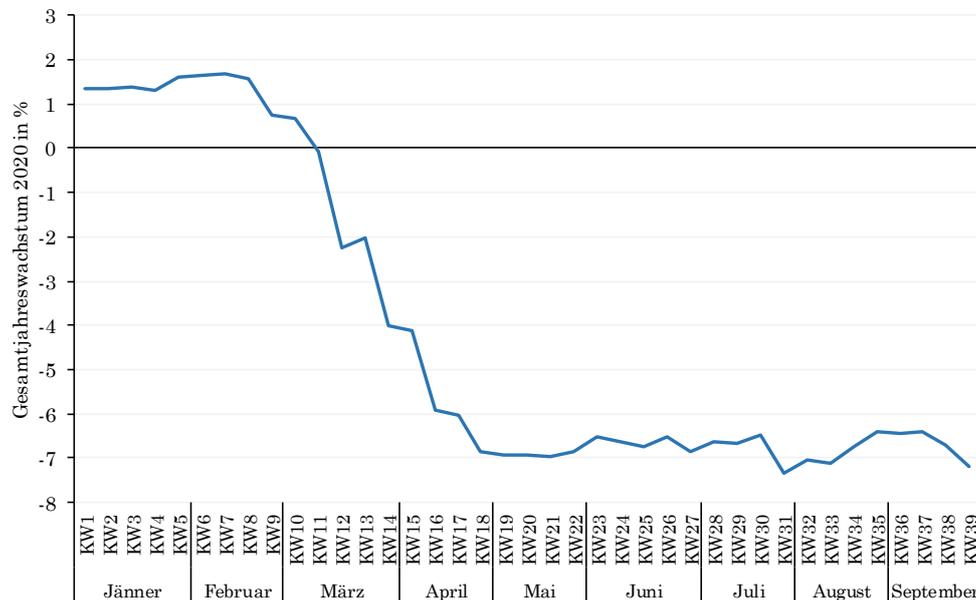
wobei $\mathbf{f}_t = [f_t^*, \tilde{\mathbf{f}}_t]'$ und der Vektor \mathbf{y}_t^* zusätzliche (vor allem internationale) Zeitreihen beinhaltet, die sich vor allem im Kontext von Prognosen als hilfreich erweisen (internationale und nationale Finanzmarktindikatoren (beschrieben in den Kapiteln 2.2, sowie der in Abschnitt 2.5 dargestellte Finanzmarktstressindex), wöchentliche BIP-Indikatoren für die USA und Deutschland, sowie ein Reihe ausländischer Vorlaufindikatoren). Das Matrix-Polynom $\Phi^f(L)$ wird in Form einer Block-diagonalen Struktur hinsichtlich der Faktoren \mathbf{f}_t und den Variablen in \mathbf{y}_t^* aufgesetzt:

$$\Phi^f(L) = \begin{bmatrix} \varphi_{1,1}^f(L) & \varphi_{1,2}^f(L) \\ \mathbf{0} & \varphi_{2,2}^f(L) \end{bmatrix} \quad (8)$$

wobei $\varphi_{1,1}^f(L)$, $\varphi_{1,2}^f(L)$, $\varphi_{2,2}^f(L)$ Teil-Matrix-Polynome darstellen. Diese Struktur ermöglicht die Schätzung einer Block-exogenen Abhängigkeitsstruktur und trägt damit dem Umstand Rechnung, dass die österreichische Volkswirtschaft zwar von den Variablen in \mathbf{y}_t^* beeinflusst wird, jedoch selber keinen Einfluss auf eben diese Variablen ausübt. Überdies vereinfacht dieser Ansatz die Schätzung, da deutlich weniger Parameter geschätzt werden müssen als in einem unrestringierten Modell.

Die Hauptunterschiede zwischen dem in Abschnitt 2.3.1 vorgestellten Ein-Faktor-Modell und der MF-FAVAR-Spezifikation bestehen darin, dass (i) der Faktor des MF-FAVAR-Modells

Abbildung 14: Wöchentlicher Verlauf der Gesamtjahresprognose 2020



ohne die Informationen in \mathbf{x}_t^Q konstruiert wird; und (ii) sich die stochastischen Eigenschaften der beiden Modelle unterscheiden; insbesondere, da $\Phi^f(L)$ ein Matrix-Verzögerungs-Polynom der Ordnung vier ist, erlaubt das MF-FAVAR viel reichhaltigere dynamische Eigenschaften als das Ein-Faktor-Modell.

Wöchentliche Gesamtjahresprognose. Abbildung 14 stellt den Verlauf von wöchentlich erstellten Gesamtjahresprognosen für das Jahr 2020 im Rahmen einer *Echtzeitprognose* dar. Der Begriff der Echtzeitprognose deutet an, dass der in einer konkreten Woche prognostizierte Wert für das Gesamtjahreswachstum 2020 auf der zu diesem Zeitpunkt verfügbaren Informationen basiert. Der Pfad der Gesamtjahresprognosen erlaubt die Bewertung des Ausmaßes der Prognoserevisionen aufgrund neu verfügbarer Informationen gegenüber der Vorwoche. In den ersten beiden Monaten 2020 ergab die Modellprognose Werte zwischen 1,5 Prozent und knapp 2,0 Prozent mit einem vergleichsweise stabilen Verlauf. Nach einem deutlichen Rückgang im März und April 2020 haben sich die prognostizierten Jahreswachstumsraten der Modellschätzung ab Ende April bei rund $-7,0$ Prozent stabilisiert. Dieser Verlauf der prognostizierten Jahresrate für 2020 impliziert einen deutlichen Anstieg der Quartalsveränderungsraten (d. h. stark positive Zuwächse) im dritten und vierten Quartal.

Wöchentliche Gesamtjahresprognose auf Basis eines monatlichen Modells – ein Vergleich. Die Erstellung einer Gesamtjahresprognose auf Basis einer wöchentlichen Frequenz umfasst eine vergleichsweise große Anzahl an zu prognostizierenden Zeitpunkten (bis zu 52 Wochen). In der Regel wird versucht dieses Problem zu vermeiden. Der einfachste und damit bei weitem häufigere Ansatz ist die Verwendung von Daten auf Basis einer niedrigeren

2.4 Indirekter Ansatz zur Echtzeitschätzung und Prognose des BIP: Modellierung der Teilaggregate

Der zuvor beschriebene Modellierungsansatz erstellt wöchentliche Prognosen des realen BIP-Wachstums auf Basis eines direkten Ansatzes. Dieses Kapitel beschreibt einen indirekten Ansatz, in dem die BIP-Prognose aus den Prognosen folgender Komponenten – im Weiteren als *Referenzreihen* bezeichnet – der Verwendungs- und Entstehungsseite der Volkswirtschaftlichen Gesamtrechnung (VGR) gewonnen wird:

- Konsum der privaten Haushalte,
- Bruttoanlageinvestitionen (Ausrüstungsinvestitionen, Bauinvestitionen und Investitionen in geistiges Eigentum),
- Exporte (Warenexporte, Dienstleistungsexporte),
- Importe,
- Wertschöpfung in der Industrie (inkl. Bergbau, Energie- und Wasserversorgung),
- Wertschöpfung im Bau,
- Wertschöpfung in den Marktdienstleistungen,
- Wertschöpfung im Tourismus.

Im Vordergrund steht die Erstellung detaillierter Echtzeiteinschätzungen und Prognosen, die intern konsistent und konzeptionell mit den vierteljährlichen VGR-Konten verbunden sind. Die vierteljährlichen VGR-Daten bilden die höchste Frequenz ab, mit der das Wirtschaftswachstum einer Volkswirtschaft in den offiziellen Statistiken ausgewiesen wird. Höherfrequente Daten, wie z.B. monatliche Zeitreihen, werden als Indikatoren für die Dynamik der vierteljährlichen Zeitreihen verwendet. Eine detaillierte Darstellung und Analyse der in diesem Abschnitt verwendeten Methoden finden sich in Glocker und Kaniovski (2020). Die wöchentlichen Daten bieten sich für eine wöchentliche Auswertung des Modells an.

2.4.1 Das CDFM im Überblick

Makroökonomische Modelle lassen sich grob in Zeitreihenmodelle und strukturelle Modelle unterteilen. Umfassende strukturelle Modelle bestehen aus einer Vielzahl stochastischer Verhaltensgleichungen und Definitionen. Die Verhaltensgleichungen modellieren das Verhalten von Wirtschaftsakteuren wie Haushalten und Unternehmen, während Definitionen die definitorischen und institutionellen Beziehungen widerspiegeln. Da sich die Verhaltensgleichungen

stark an die makroökonomische Theorie anlehnen, hilft die Modellstruktur zwar bei der Interpretation der Prognosen, doch können große strukturelle Modelle durch ihren theoretischen Unterbau nur schwer die Informationen weicher Indikatoren (z.B. Stimmungsindikatoren) und hochfrequenter Daten berücksichtigen. Somit sind solche Modelle für die Erstellung von unkonditionierten Prognosen, die nicht auf externen Inputvariablen aufsetzen, nur eingeschränkt geeignet.

Reine Zeitreihenmodelle versuchen die dynamische Korrelationsstruktur zwischen Zeitreihen zu nutzen, ohne sich dabei zu stark auf die makroökonomische Theorie zu stützen. Solche Modelle werden oft für die Erstellung von unkonditionierten Prognosen herangezogen. Die Anwendungsbereiche kleiner Zeitreihenmodelle sind vielfältig; sie reichen von Geschäftsprognosen auf Unternehmensebene bis hin zu Prognosen einer Volkswirtschaft. Obwohl kleine Zeitreihenmodelle in Bezug auf die Treffsicherheit von Kurzfristprognosen Strukturmodellen tendenziell überlegen sind, sind sie nicht in der Lage, eine Vielzahl exogener Vorgaben zu berücksichtigen. Das macht sie für die Erstellung bedingter Prognosen und die Entwicklung von Szenarien weniger nützlich. Eine bedingte Prognose nimmt zukünftige Pfade einer Reihe von Variablen als gegeben an. Prognosen einer kleinen offenen Volkswirtschaft wie Österreich können beispielsweise die globalen wirtschaftlichen Rahmenbedingungen (z.B. Wirtschaftswachstum der Handelspartner, Wechselkurse, Ölpreis) als gegeben voraussetzen. Daraus entstehen bedingte Prognosen, die auf Annahmen über das externe Umfeld beruhen.

Der in diesem Projekt verwendete Ansatz kombiniert die Vorteile der beiden oben beschriebenen Modelltypen und kompensiert gleichzeitig deren Schwächen. Das zugrundeliegende Konzept – genannt *Cluster of Dynamic Factor Models* (CDFM) – wurde in Glocker und Kaniovski (2020) entwickelt und am Beispiel der österreichischen Volkswirtschaft umgesetzt. Die ursprüngliche Modellspezifikation wurde im Rahmen dieses Projekts evaluiert, erweitert und verbessert. Zu den wichtigsten Modellerweiterungen gehören die Integration eines Tourismussektors und die Berücksichtigung hochfrequenter Indikatoren. Im Folgenden werden die wichtigsten konzeptionellen Eigenschaften des CDFM beschrieben.

Das Grundelement des CDFM ist ein dynamisches Faktormodell (DFM). Das DFM ermöglicht eine kompakte Darstellung der multivariaten Dynamik einer Vielzahl von Zeitreihen durch einige wenige Faktoren. Die DFM sind besonders nützlich bei Kurzfristprognosen, weil sie unvollständige Zeitreihen gemischter Frequenzen zulassen (vgl. Abschnitt 2.3). Das Hauptmerkmal des vorgeschlagenen Modellierungsansatzes besteht aus einer Reihe von DFM, die zu einem Cluster (CDFM) verbunden werden. Die Verbindungen zwischen einzelnen DFM beruhen auf theoretischen Überlegungen und den Ergebnissen des Granger-Kausalitätstests.

Im CDFM wird jede Komponente des BIP durch ein eigenes DFM abgebildet, welches individuell spezifiziert, geschätzt und hinsichtlich seiner Prognosegüte bewertet wird. Die Bewertung der Güte basiert auf In-Sample- und Out-of-Sample-Prognosen. Die Verbindungen

zwischen den DFM vervollständigen das makroökonomische Prognosemodell, wobei nach deren Zusammenfügung die Prognosegüte des ganzen Modells nochmals überprüft und einzelne DFM sowie deren Verbindungen gegebenenfalls überarbeitet werden. Die Auswertung der Prognosegüte baut auf allen vierteljährlichen Modellprognosen von 2007 bis 2018 und getrennt für die Periode von 2014 bis 2018 auf. Der besondere Fokus auf die jüngere Vergangenheit ist angesichts der Strukturbrüche in den Zeitreihen, die vor allem durch die globale Finanz- und Wirtschaftskrise 2008/09 und die darauffolgende europäische Schuldenkrise entstanden sind, gerechtfertigt.

Die Zusammensetzung des CDFM in Form einer Vielzahl von kleineren DFM erlaubt ein hohes Maß an Flexibilität. Die Schnittstellen des Clusters bieten die Möglichkeit, eine modellkonsistente Prognose für alle im Modell enthaltenen Variablen zu erstellen. Das CDFM ermöglicht die Erstellung von BIP-Prognosen über die Entstehungs-, Verwendungs- und Verteilungsseite der VGR. Der Ansatz vereint somit die Vorteile großer struktureller Modelle und kleiner dynamischer Faktormodelle. Zusätzlich ermöglicht das CDFM, Annahmen über einzelne Zeitreihen zu berücksichtigen und dadurch bedingte Prognosen zu erstellen. Szenarien als Beispiel für bedingte Prognosen werden in Zeiten erhöhter Unsicherheit besonders gefragt.

Die Auswertungen von Glocker und Kaniovski (2020) zeigen, dass stark disaggregierte Modelle nicht nur besser interpretierbare Ergebnisse liefern, sondern auch tendenziell genauere Prognosen. Die empirische Evidenz zum Zusammenhang zwischen Aggregation und Prognosegüte ist nicht eindeutig und hängt entscheidend von der Art und der Qualität der betrachteten Modelle ab. Die Beiträge von Esteves (2013), Higgins (2014), Foroni und Marcellino (2014), Pareja et al. (2020), Cobb (2020) und Giovannelli et al. (2020) bestätigen, dass disaggregierte Modelle, die das BIP-Wachstum indirekt über die BIP-Komponenten vorhersagen tendenziell besser abschneiden als jene Modelle, die das BIP-Wachstum direkt erklären. In Übereinstimmung mit den Ergebnissen von Glocker und Kaniovski (2020) stellen z.B. Pareja et al. (2020) eine Steigerung der Genauigkeit von BIP-Prognosen durch den Einsatz eines disaggregierten Ansatzes fest. Giovannelli et al. (2020) prognostizieren sechzehn BIP-Komponenten auf der Entstehungs- und Verwendungsseite auf Monatsbasis durch die Verwendung monatlicher Daten und stellen fest, dass der disaggregierte Ansatz die Güte der BIP-Prognosen erhöht.

Obwohl die oben erwähnten Studien disaggregierte Modelle befürworten, unterscheiden sich die zugrundeliegenden ökonometrischen Ansätze erheblich. Während Pareja et al. (2020) und Giovannelli et al. (2020) sich auf rein statistische Verfahren verlassen, greift der Ansatz von Glocker und Kaniovski (2020) auf die ökonomische Theorie zurück. Die empirische Evidenz unterstützt somit den disaggregierten Ansatz des CDFM, was neben der Prognosegüte zusätzliche Vorteile bietet. Dazu gehören die bessere Interpretierbarkeit der Ergebnisse und die Möglichkeit, Szenarien auf der Grundlage detaillierter Annahmen über die BIP-Komponenten zu entwerfen. Der wohl entscheidende Vorteil des CDFM-Ansatzes im Vergleich zu Pareja et

al. (2020) und Giovannelli et al. (2020) liegt in seiner Einfachheit und Transparenz.

2.4.2 Datengrundlage und Spezifikation des CDFM

Die für die Schätzung des Modells verwendeten Zeitreihen decken den Zeitraum 1996 bis 2019 ab. Die aktuellsten Beobachtungen aus dem Jahr 2020 wurden aufgrund der außerordentlichen Entwicklungen infolge der COVID-19-Krise für die Schätzung nicht verwendet.

Es werden saisonbereinigte VGR-Quartalsdaten verwendet, um vorhersehbare saisonale Schwankungen zu eliminieren. Die hochfrequenten Indikatoren stammen aus unterschiedlichen Quellen und liegen auf täglicher, wöchentlicher und monatlicher Frequenz vor (siehe Details in Kapitel 2.2.2). Zu den monatlichen Daten zählen Einschätzungen der aktuellen Situation und den Erwartungen nach Sektoren aus Unternehmensumfragen (WIFO-Konjunkturtest) sowie sektorale Arbeitsmarktdaten zur Beschäftigung und zu offenen Stellen.

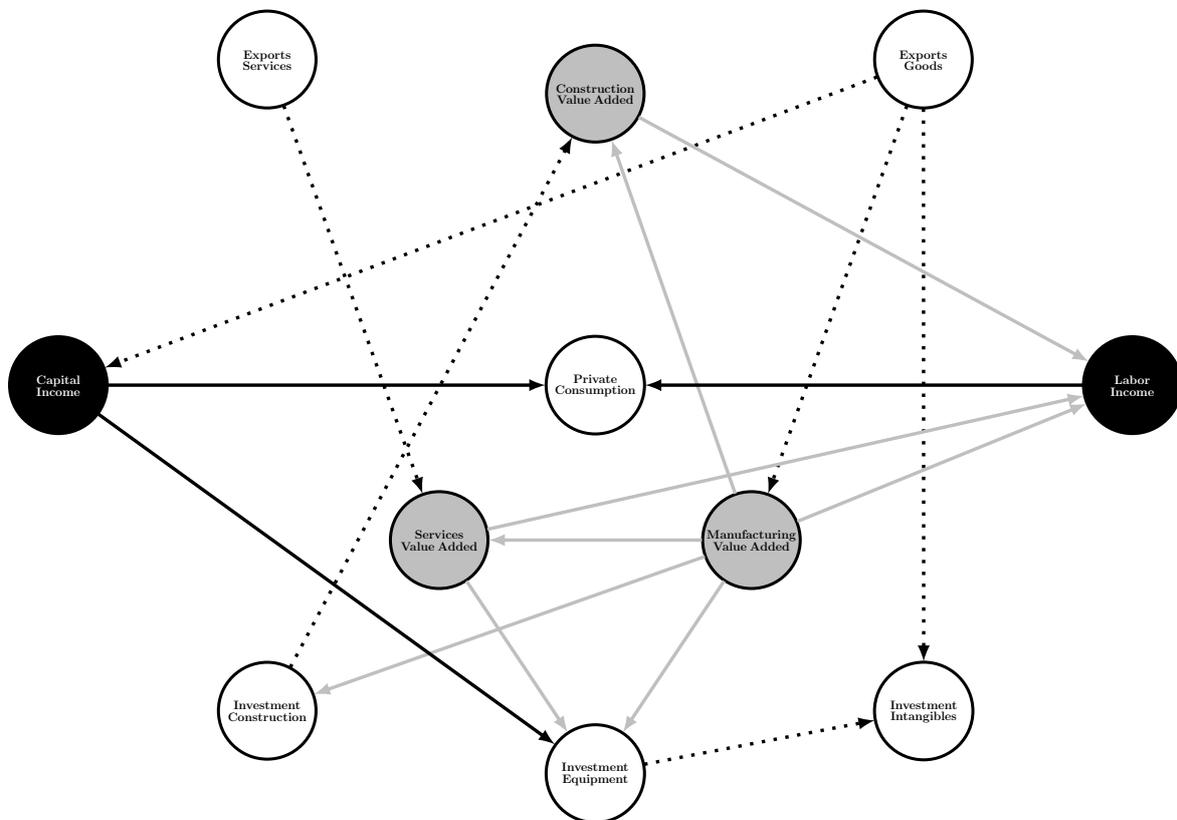
Für jedes einzelne DFM beginnt die Spezifikationssuche mit einer Vorauswahl von Indikatoren auf Basis der Ergebnisse der in Abschnitt 2.2.3 dargestellten Korrelationsanalyse. Zuerst werden alle Zeitreihen standardisiert. In einem zweiten Schritt werden die einzelnen DFM mit Hilfe eines Kalman-Filters geschätzt. Die Standardisierung verringert die Anzahl der geschätzten Parameter und homogenisiert die Varianzen der idiosynkratischen Komponenten, was die Schätzung vereinfacht und beschleunigt.

Bei der Spezifikationssuche wird die Vorauswahl auf Basis der Korrelationsanalyse im Hinblick auf die Fehlerauswertung durch die normalisierte Wurzel der mittleren Fehlerquadratsumme (NRMSE, normalised root-mean-squared-error) weiter eingeschränkt. Durch die Normalisierung können Modelle von volatilen Zeitreihen wie den Exporten oder Investitionen mit jenen Modellen von weniger volatilen Zeitreihen wie dem privaten Konsum verglichen werden.

Insgesamt werden 18 einzelne DFM geschätzt. Übersichten 1 und 2 fassen die Variablen in den einzelnen DFM nach Referenzreihen zusammen. Die linke Spalte der Übersichten mit der Bezeichnung *Referenzreihe* listet die Referenzreihen auf, für die DFM spezifiziert wurden. Die zweite (*Verbindungsvariablen*) und dritte (*andere Variablen*) Spalten beschreiben die Variablen in den DFM. Entscheidend für das CDFM sind die Verbindungsvariablen. Jedes DFM enthält Verbindungsvariablen wodurch die einzelnen DFM miteinander verbunden werden. Dadurch ergibt sich ein Cluster, in das die einzelnen DFM der Referenzreihen eingebunden sind. Jedes einzelne DFM kann somit einerseits in eigenständiger Form verwendet werden, jedoch auch im Rahmen des CDFM.

Zusätzlich zu den DFM wird eine Reihe an Aggregationsmodellen geschätzt (diese sind in den Übersichten nicht dargestellt). Aggregationsmodelle stellen ebenfalls dynamische Faktormodelle dar und werden mit dem Kalman-Filter geschätzt. Sie dienen dem Zweck Teilkomponenten zu aggregieren um saldenspezifische VGR-Definitionen zu erfüllen (siehe

Abbildung 16: Granger-kausaliätsbasierte Modellstruktur



Quelle: Glocker und Kaniovski (2020).

Glocker und Kaniovski, 2020, für weitere Details). Das CDFM beinhaltet somit in Summe 30 eigenständige Modelle.

Die in diesem Projektbericht erläuterte Version des CDFM ist auf monatlicher Basis als höchste modellinhärente Frequenz spezifiziert, wobei allerdings auch vierteljährliche Daten einbezogen werden. Das CDFM besteht also aus einer gemischten Frequenzstruktur. Die Tatsache, dass diese Version des Modells einen Satz an Variablen enthält, der auf wöchentlicher und sogar täglicher Basis verfügbar ist, erlaubt eine Erweiterung der Modellfrequenz auf eine wöchentliche oder sogar tägliche Frequenz. Wir beschränken uns in diesem Bericht auf eine Version des CDFM mit monatlicher Frequenz, da die monatliche Version des CDFM mit alternativen Ansätzen aus der Literatur verglichen werden kann, und in Bezug auf die Prognosegüte bessere Eigenschaften als eine wöchentliche Version hat (vgl. dazu auch die Diskussion in Abschnitt 2.3.2). Nicht zuletzt kann die monatliche Version des CDFM für wöchentliche Auswertungen in einer gleichwertigen Form wie in Abschnitt 2.3.2 beschrieben, verwendet werden.

Granger-kausaliätsbasierte Modellstruktur. Eine empirisch fundierte Verbindung der

einzelnen DFM stellt das zentrale Element des Gesamtkonzeptes des CDFM dar. Es ist daher unerlässlich, für die Begründung dieser Verbindungen auf ein objektives Verfahren zurückzugreifen. Wir verwenden den Granger-Kausalitätstest, um diese Verbindungen zu identifizieren und statistisch zu belegen. Der zusätzliche Vorteil, der sich beim Aufbau des CDFM durch diesen Test ergibt, besteht darin, dass das Konzept des Granger-Kausalitätstests zur Steigerung der Prognosegüte beiträgt – der Granger-Kausalitätstest ist ein statistischer Hypothesentest zur Klärung der Frage, ob eine Zeitreihe für die Vorhersage einer anderen geeignet ist.

Die bivariaten Granger-Kausalitätstests werden paarweise unter den Wachstumsraten aller vierteljährlichen VGR-Variablen (Referenzreihen) durchgeführt. Eine directionale Verbindung von Variable X zur Variable Y wird hergestellt, wenn die erste Variable einen *Granger-kausalen Effekt* auf die zweite Variable hat – anders ausgedrückt: wenn die zweite Variable unter Berücksichtigung der ersten Variable *besser prognostiziert* werden kann – aber nicht umgekehrt. Die resultierende unidirektionale Verbindung erlaubt es, eine Abfolge der einzelnen DFM im übergeordneten Cluster zu bestimmen. Die Verbindungen werden in Abbildung 16 dargestellt.

Die Ergebnisse der Granger-Kausalitätstests entsprechen der volkswirtschaftlichen Theorie über die Ausbreitung makroökonomischer Schocks in einer kleinen offenen Volkswirtschaft. Die Exporte sind die Schlüsselvariablen, deren Schocks direkte Auswirkungen auf den Produktions- und Dienstleistungssektor haben. Eine Änderung des Produktionswachstums verursacht eine Anpassung der Produktionskapazitäten durch eine Änderung von Ausrüstungs- und Bauinvestitionen. Die zunehmende Komplementarität zwischen materiellen und immateriellen Investitionsgütern führt zu einer Änderung der Investitionen für immaterielle Anlagen wie Software als Folge einer Änderung der Ausrüstungsinvestitionen. In weiterer Folge übertragen sich Entwicklungen von der Entstehungsseite auf die Verteilungsseite, z.B. durch die Veränderungen der Beschäftigung, die wiederum die Konsumausgaben der Haushalte auf der Verwendungsseite prägen. Diese Verflechtungen zeigen eine enge Abhängigkeit zwischen den Variablen der Entstehungs-, Verwendungs- und Verteilungsseite und bilden die Dynamik der Zyklen dieser Variablen und damit die der Gesamtwirtschaft ab.

2.4.3 Die Funktionsweise eines CDFM

Der kaskadenartige Aufbau des CDFM stellt sicher, dass die Prognosen der nachgereihten DFM auf die Prognosen der vorgereihten DFM abgestimmt sind und damit die interne Konsistenz der Modellprognose sichergestellt ist. Diese Wirkungsweise baut auf dem Konzept einer bedingten Prognose auf. Die bedingte Prognose betrifft Vorhersagen von endogenen Variablen, die von einem bestimmten Pfad und einer bestimmten Pfadlänge einiger anderer endogener Variablen abhängig sind. Konkret wird in unserem Kontext davon ausgegangen,

dass die bedingte Information harte Bedingungen (einen bestimmten Pfad) und nicht weiche Bedingungen (einen Bereich oder eine statistische Verteilung für den Pfad) erfüllt. Dies steht im Gegensatz zu bedingungslosen Prognosen, bei denen keine Kenntnis des zukünftigen Pfades vorausgesetzt wird.

Somit können mit dem CDFM sowohl unkonditionierte als auch bedingte Prognosen erstellt werden. Ein Beispiel: Eine bedingte Prognose für Warenexporte könnte sich aus der Annahme eines zukünftigen Pfades für das BIP der Handelspartner ergeben. Falls kein zukünftiger Pfad für das BIP der Handelspartner angenommen wird, erstellt das DFM für Warenexporte eine unkonditionierte Prognose für alle enthaltenen Variablen. Die unkonditionierte Prognose dieser Variablen wird wiederum in weiteren DFM verwendet. Die Weitergabe findet mit Hilfe der Verbindungen statt. Diese gewährleisten die Konsistenz bezüglich des äußeren Umfelds der DFM für den Export von Waren und Dienstleistungen. Dies betrifft u.a. die Verwendung von ausländischen Vorlaufindikatoren (weichen Indikatoren, wie z.B. Einkaufsmanagerindizes (PMI), etc.) für die Bestimmung von Dienstleistungsexporten. Darüber hinaus wird die unkonditionierte Prognose der Warenexporte im DFM für die Wertschöpfung im produzierenden Bereich, die Kapitaleinkommen und die immateriellen Investitionen verwendet. Sobald die Prognose der Warenexporte in diesen Modellen verwendet wird, werden bedingte Prognosen für die Wertschöpfung im produzierenden Bereich und für die Kapitaleinkommen erstellt. Diese bedingten Prognosen werden wiederum in weiteren DFM verwendet.

Die gleichzeitige Verwendung von unkonditionierten und bedingten Prognosen erschwert die Beurteilung der Prognosegüte des CDFM. Beispielsweise erkennt man sofort, warum der Fehler unkonditionierter Prognosen sehr wenig darüber aussagt, wie gut ein Modell bei bedingten Prognosen ist. Ein makroökonomisches Modell mag gut abbilden können, wie sich eine Änderung z.B. des Ölpreises auf die Produktion auswirkt, aber es kann immer noch ungenau bei der Prognose des Produktionswachstums im nächsten Jahr sein, weil es von vornherein schlecht bei der Prognose des Ölpreises ist. In diesem Zusammenhang können ungenaue unkonditionierte Prognosen im CDFM durch externe Vorgaben ersetzt werden. Das CDFM erstellt dafür Prognosen für alle Variablen, abhängig von dem angenommenen zukünftigen Pfad. Das CDFM bietet somit eine flexible Umgebung, in der Prognosen bei Bedarf schnell angepasst werden können. Dies wiederum ermöglicht auch eine Szenarioanalyse, mit der die Sensitivität zukünftiger Pfade auf Änderungen von Variablen einiger vorangegangener DFM beurteilt werden kann.

Tabelle 1: Anordnung der Verhaltensmodelle im CDFM (A)

DFM	Referenzreihe	Verbindungsvariablen	Andere Variablen
(1)	Importdeflator		Ölpreis in Euro (Brent) • EU PPI Sachgüterzeugung
(2)	Konsumdeflator	Importdeflator (1)	VPI • Kerninflation (HVPI) • TLI
(3)	Warenexport		EU PMI • US BIP • EU BIP • Lkw-Fahrleistung • Warenexport laut AH-Statistik
(4)	Dienstleistungsexport	EU PMI (3) • EU BIP (3) • US BIP (3)	Flugpassagiere
(5)	BWS Industrie	Warenexport (3) • LKW-Fahrleistung (3)	DE Vertrauensindikator Sachgüterzeugung • Auftragsbestände Sachgüterzeugung • Industrieproduktion • Beschäftigung Sachgüterzeugung • Offene Stellen Sachgüterzeugung
(6)	Bauinvestitionen	LKW-Fahrleistung (3) • BWS Industrie (5)	Erwartungen Bau
(7)	BWS Bau	LKW-Fahrleistung (3) • BWS Industrie (5) • Bauinvestitionen (6)	Beschäftigung Bau
(8)	BWS Tourismus	Flugpassagiere (4)	Beschäftigung Tourismus • Offene Stellen Tourismus • Lageeinschätzung Tourismus • Erwartungen Tourismus • Nächtingungen • Einnahmen Tourismus
(9)	BWS restliche Dienstleistungen	LKW-Fahrleistung (3) • Dienstleistungsexport (4) • BWS Industrie (5)	Beschäftigung restliche Dienstleistungen • Lageeinschätzung Dienstleistungen • Erwartungen Dienstleistungen

Tabelle 2: Anordnung der Verhaltensmodelle im CDFM (B)

DFM	Referenzreihe	Verbindungsvariablen	Andere Variablen
(10)	Löhne Industrie	Beschäftigung Industrie (5)	TLI Industrie • Exportauftragsbestände Sachgütererzeugung
(11)	Exportdeflator	Importdeflator (1) • EU BIP (3) • TLI Industrie (10) • Exportauftragsbestände Sachgütererzeugung (10)	
(12)	Kapitaleinkommen	Warenexport (3) • Dienstleistungsexport (4)	Zinsstrukturkurve (2-10y) • Unsicherheitsindex Sachgütererzeugung
(13)	Löhne Bau	Erwartungen Bau (6) • Beschäftigung Bau (7) • TLI Industrie (10)	
(14)	Löhne Tourismus	Beschäftigung Tourismus (8) • Lageinschätzung Tourismus (8)	
(15)	Löhne restliche Dienstleistungen	Beschäftigung restliche Dienstleistungen (9) • Lageinschätzung Dienstleistungen (9)	
(16)	Privater Konsum	Löhne Industrie (10) • Kapitaleinkommen (12) • Löhne Dienstleistungen (agg.)	Umsätze Handel • Umsätze Kfz-Handel • Treibstoffmarktverbrauch • Erwartungen zur Arbeitslosigkeit
(17)	Ausrüstungsinvestitionen	BWS Industrie (5) • Auftragsbestände Sachgütererzeugung (5) • Offene Stellen Industrie (5) • BWS Dienstleistungen (agg.) • Kapitaleinkommen (12)	Lageinschätzung Sachgütererzeugung
(18)	Investitionen geistiges Eigentum	Warenexport (3) • Ausrüstungsinvestitionen (17)	

Konsistenz zwischen der Entstehungs- und der Verwendungsseite der VGR. Die wichtigsten Quartalsvariablen des Modells sind über die Kausalstruktur verknüpft, die in den Granger-Kausalitätstests impliziert ist. Dennoch erzeugt das CDFM Prognosen für die Wachstumsrate des realen BIP getrennt nach der Entstehungs-, Verwendungs- und Verteilungsseite der VGR, wobei die in diesem Bericht vorgestellten Prognosen nur die Entstehungs- und die Verwendungsseite behandeln. Dieser scheinbar unabhängige dreidimensionale Ansatz könnte Zweifel an den vorhergesagten Werten aufkommen lassen, wenn sie voneinander abweichen.

Vor diesem Hintergrund bewerten Glocker und Kaniovski (2020) die Übereinstimmung der drei BIP-Prognosen, indem sie die Muster der Abweichungen in den Out-of-Sample-Prognosen von 2007 bis 2018 vergleichen. Die Analyse zeigt keine systematischen Abweichungen zwischen den Prognosen der drei Konten der VGR. Es wird darüber hinaus festgestellt, dass die Schwankungen in den meisten Fällen geringer als die Größenordnung der Revisionen der vierteljährlichen VGR-Daten sind.

2.4.4 Ergebnisse des CDFM

Das CDFM kann für unterschiedlicher Zwecke angewandt werden. Im Folgenden beschreiben wir – im Einklang mit Kapitel 2.3 – die Verwendung davon für Echtzeiteinschätzungen und die Erstellung von Prognosen.

Echtzeitschätzung der Referenzreihen mit Hilfe des CDFM. Das CDFM ermöglicht die Erstellung von monatlichen Echtzeitschätzungen (Nowcasts) der Referenzreihen. Der zugrundeliegende Ansatz auf Basis gemischter Frequenzen ermöglicht in diesem Zusammenhang eine monatliche Interpolation der Quartalsdaten ex-post. Ex-ante erlaubt dieser Ansatz die Verwendung monatlicher Zeitreihen für eine Echtzeiteinschätzung der Wachstumsrate der Referenzreihen. Die Echtzeiteinschätzungen für verschiedene Referenzreihen sind in Abbildung 17 dargestellt. Die Abbildung stellt Wachstumsraten gegenüber der Vorjahresperiode dar. Die blaue Linie zeigt die Echtzeiteinschätzung des CDFM für die vierteljährlichen Beobachtungen (blaue Punkte). Die Schätzung berücksichtigt vierteljährliche Beobachtungen der Referenzreihen, sobald sie verfügbar werden. Der Verlauf des Indikators baut auf diesen Beobachtungen auf.

Abbildung 18 stellt den vom CDFM geschätzten monatlichen Verlauf der Referenzgrößen für das Jahr 2020 dar (Echtzeiteinschätzung für das dritte und Prognose für das vierte Quartal 2020). Wie in der vorangehenden Abbildung bezeichnen die blauen Linien die monatlichen Pfade der Echtzeiteinschätzungen und die leeren Punkte die Beobachtungen aus der aktuellen Quartals-VGR der Bundesanstalt Statistik Österreich. Diese sind derzeit einschließlich bis zum zweiten Quartal 2020 verfügbar. Dunkelblau gefüllte Punkte zeigen die vom CDFM ermittelten Wachstumsraten für das dritte und vierte Quartal 2020. Der Wert für das dritte

Quartal stellt eine Echtzeiteinschätzung dar, jener für das vierte eine tatsächliche Prognose.

Der monatliche Verlauf der Echtzeiteinschätzung weist bereits für die ersten beiden Monate 2020 für einen Großteil der Referenzreihen negative Zuwachsraten aus. Die unmittelbaren Auswirkungen der Verhängung behördlicher Einschränkungen aufgrund der COVID-19-Pandemie hatten einen deutlichen stärkeren Rückgang zur Folge. Dies zeigt sich zum Beispiel in Form eines starken Rückgangs der Wertschöpfung auf der Entstehungsseite. Gleichzeitig sind auch die Exporte, der Konsum sowie die Investitionen auf der Verwendungsseite eingebrochen. Das CDFM weist in diesem Kontext im Rahmen der Echtzeiteinschätzung auf einen starken und schnellen Einbruch im Frühjahr hin, gefolgt von einer allmählichen Erholung. Hervorzuheben ist der Pfad der Investitionen in geistiges Eigentum. Dieser unterscheidet sich grundlegend von jenem der anderen Referenzreihen. Das CDFM weist auf einen vergleichsweise günstigen Verlauf über das gesamte Jahr 2020 hin. Diese Art von Investitionsausgaben hat auch die globale Finanz- und Wirtschaftskrise von 2008/09 gut überstanden (keine negativen Quartalszuwachsraten).

Prognosen der Referenzreihen mit Hilfe des CDFM. Neben Echtzeitschätzungen bildet die Erstellung von Prognosen eine weitere Anwendungsmöglichkeit des CDFM. Mit Blick auf Abbildung 18 stellt der Verlauf der monatlichen Modelleinschätzung für das vierte Quartal eine tatsächliche Prognose dar. Das CDFM weist für alle Referenzgrößen auf einen günstigen Verlauf im vierten Quartal hin. Die Darstellung der Ergebnisse in Form von Wachstumsraten im Jahresvergleich lässt in diesem Zusammenhang schnell erkennen, ob oder wann das Aktivitätsniveau des Vorjahres erreicht wird. Das Vorjahresniveau wird wieder erreicht, wenn die Wachstumsraten die Null-Line überschreiten. Diese Entwicklung könnte sich laut dieser Modellprognose von Ende September 2020 im Fall der Exporte von Waren und der Industrieproduktion gegen Jahresende einstellen.

Ein wichtiger Aspekt im Rahmen der Verwendung des CDFM zur Erstellung von Prognose ist die Prognosegüte. Glocker und Kaniovski (2020) haben sowohl individuelle DFM als auch das CDFM als eine Abfolge verbundener Modelle getestet. Die Prognosehorizonte erstrecken sich über einen Zeitraum von vier Quartalen. Die Ergebnisse ihrer Prognoseauswertungen zeigen, dass die CDFM-Prognosen im Durchschnitt genauer sind als Prognosen von einfacheren, rein statistischen Modellen, wie der Random Walk, AR(1) oder das ARMA-Modell. Die statistische Signifikanz der Differenzen in den Prognosefehlern wurde mit einem Diebold-Mariano-Test belegt. Zusätzlich weisen Glocker und Kaniovski (2020) auf eine signifikante Erhöhung der Prognosegüte durch die Einbeziehung der Verbindungen zwischen den einzelnen DFM hin. Die Verbindungen gewährleisten nicht nur die Konsistenz der CDFM-Prognose, sondern erhöhen auch ihre Genauigkeit über alle Prognosehorizonte hinweg erheblich.

Ein weiterer Test der Prognosegüte ist vor dem Hintergrund der aktuellen schweren wirtschaftlichen Krise besonders relevant, weil er die Eignung des CDFM überprüft, tiefe

Abbildung 17: Monatliche Indikatoren für Teilaggregate 1997Q1-2020Q2

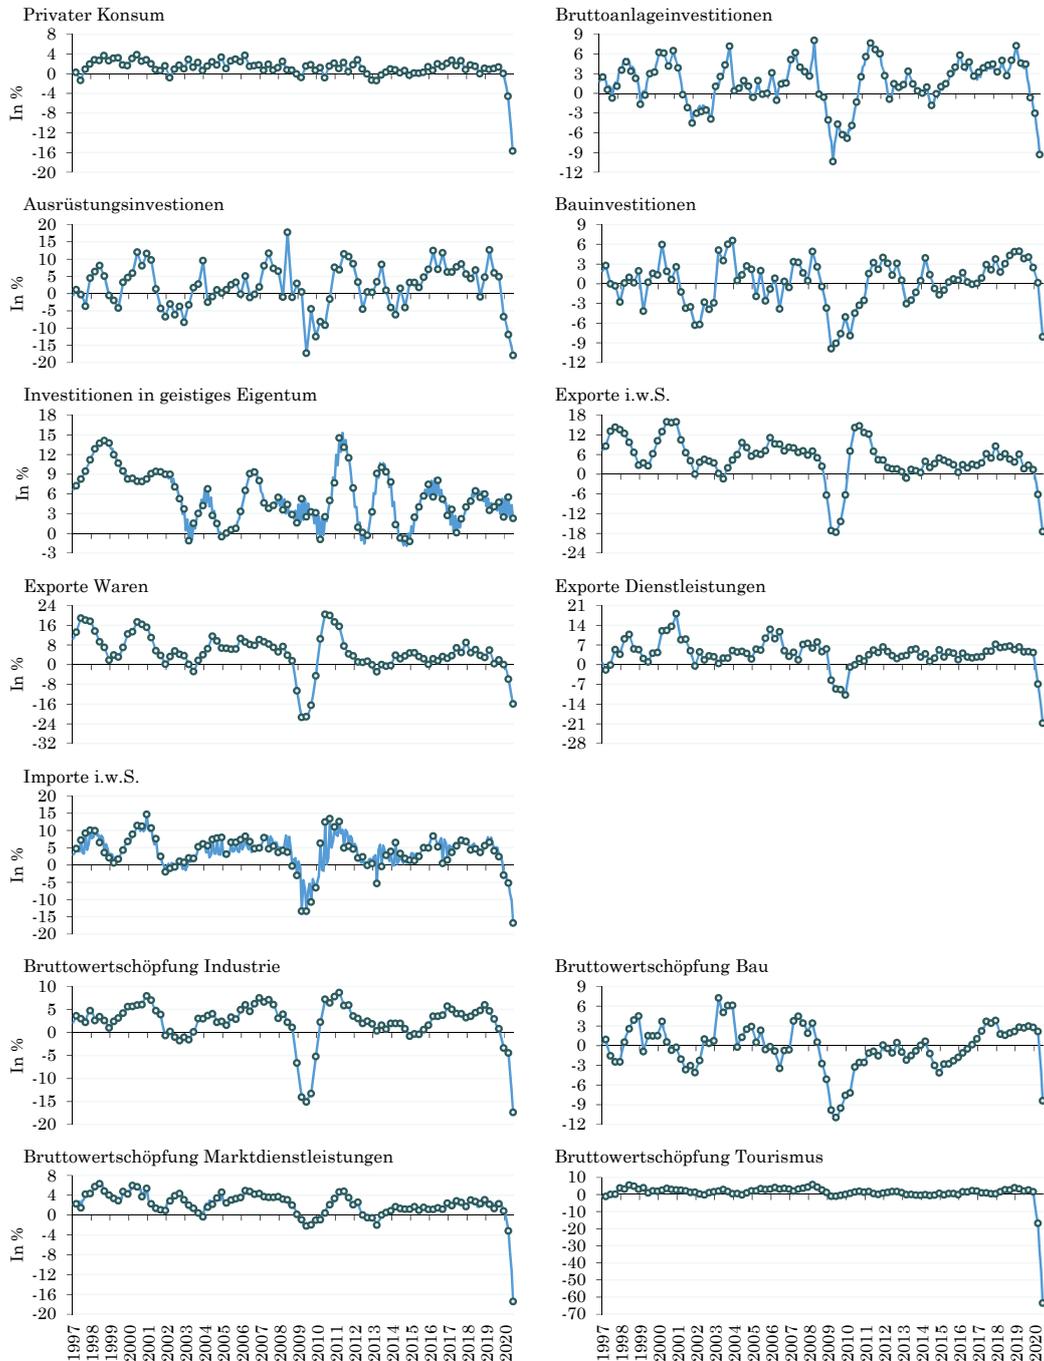


Abbildung 18: Monatliche Indikatoren für Teilaggregate 2020Q1-2020Q2

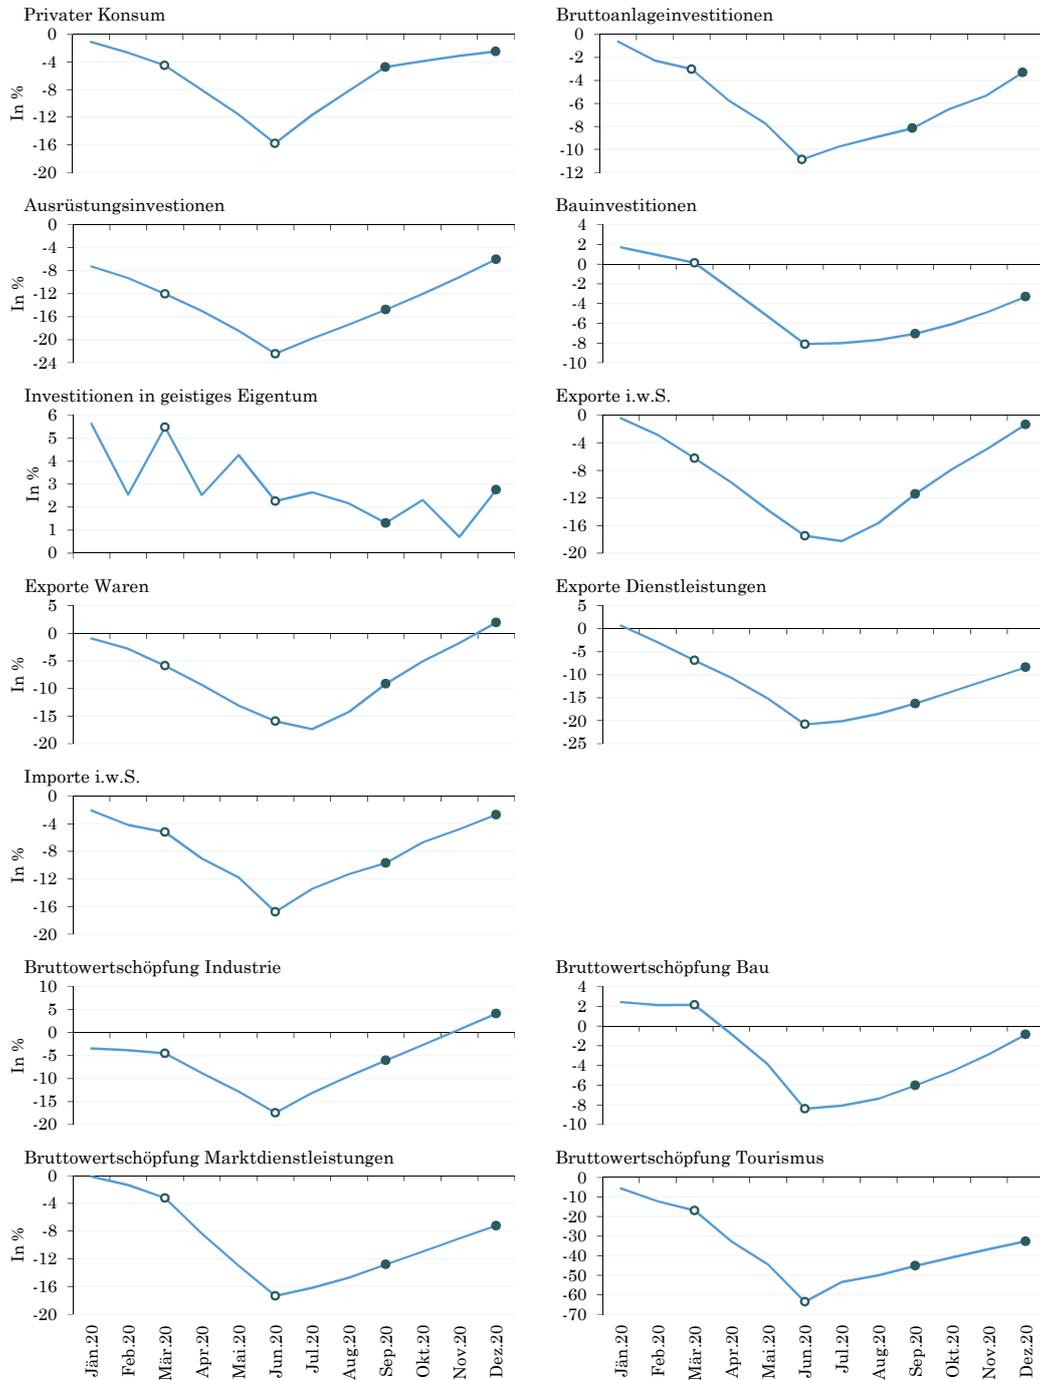
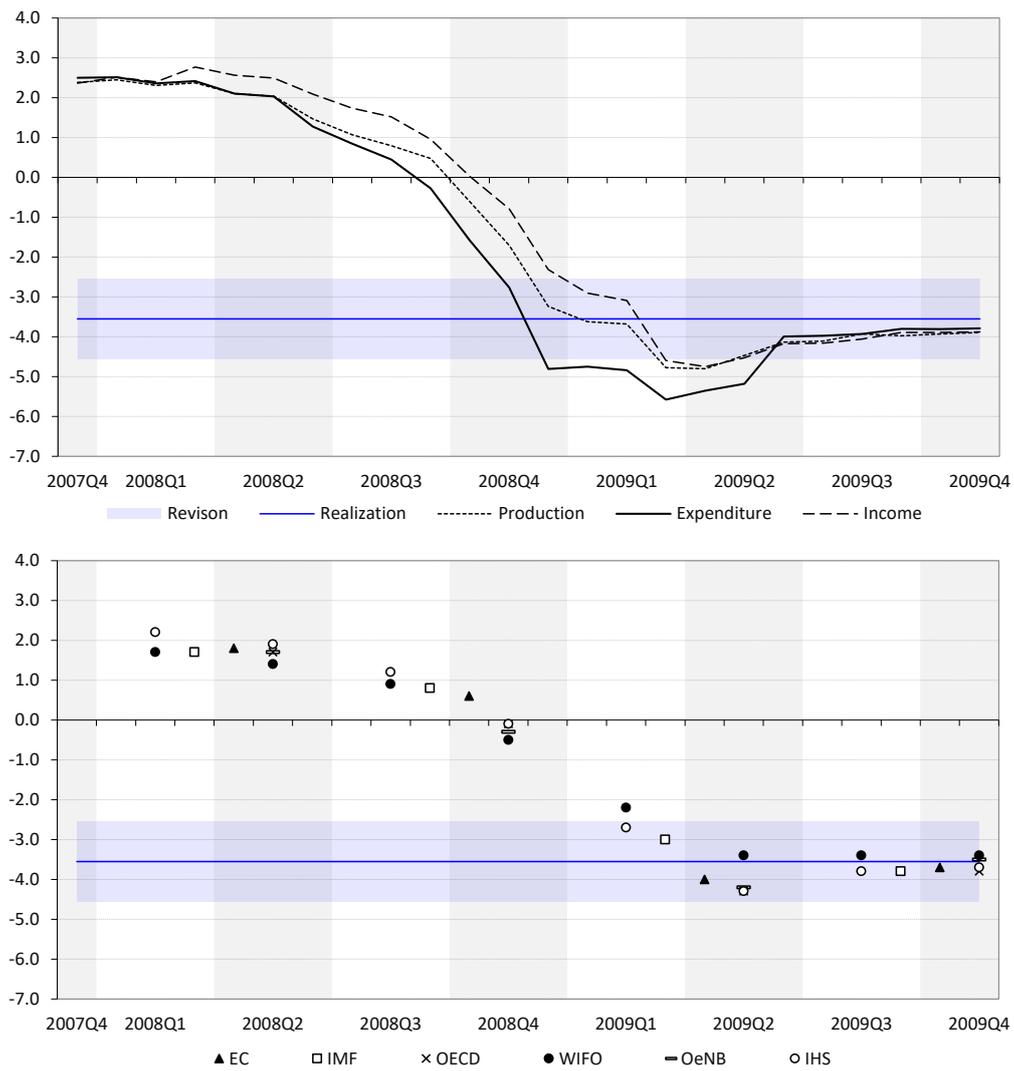


Abbildung 19: Vergleich mit den Expertenprognosen für 2009



Quelle: Glocker und Kaniovski (2020).

Krisen adäquat vorhersagen zu können. Vor dem Hintergrund, dass die aktuellen Daten für 2020 noch vorläufig sind (sie unterliegen somit einer hohen Revisionsanfälligkeit) und die aktuelle Krise überdies noch nicht vorbei ist, wenden wir unseren Blick auf die globale Finanz- und Wirtschaftskrise, die 2007 begann und 2009 ihren Höhepunkt erreichte. Diese Krise hatte 2009 eine tiefe Rezession der österreichischen Volkswirtschaft zur Folge. Weil die Bewertung von ökonomischen Modellen in Krisenzeiten besonders wichtig ist, werden in Glocker und Kaniovski (2020) nicht nur die Prognosegüte des CDFM über eine lange Periode, sondern auch die Eignung des Modells, während einer bestimmten historischen Krisenepisode adäquate Prognosen zu liefern, untersucht.

Es wurden die Prognosen der rein statistischen Modelle aber auch Expertenprognosen (IMF, OECD, EC, WIFO, IHS und OeNB) in den Vergleich einbezogen. Glocker und Kaniovski (2020) zeigen, dass die CDFM-Prognose den Abschwung früher antizipiert hat als die einfacheren statistischen Modelle, aber auch früher als die Experten. Die CDFM-Prognosen zeigen die schnellste Anpassung nach unten, indem sie bereits im August 2008 negative Wachstumsraten für 2009 vorhersagen, während die Expertenprognosen dies erst ab Ende 2008 taten. Die Ergebnisse des Vergleiches sind in Abbildung 19 veranschaulicht.

2.5 Anhang: Finanzmarktstressindikator

Dieser Abschnitt beschreibt die Indikatoren, die zur Identifizierung von Finanzmarktstress entlang einer breiten Dimension (Aktien-, Anleihemärkte, etc.) verwendet werden. Die hier dargestellten Variablen werden üblicherweise für die Erstellung von Finanzmarktstressindizes verwendet.

Der hier skizzierte Satz von Indikatoren erfasst die typischen Elemente von Finanzstress in verschiedenen repräsentativen Marktsegmenten. Diese individuellen “Roh-Stress-Indikatoren” werden durch Transformation in eine Ordnungsstatistik standardisiert, und die arithmetischen Mittel der transformierten “Stressfaktoren” in jedem Teilmarkt stellen unterschiedliche Elemente von finanziellem Stress (Hakkio und Keeton, 2009) dar. Diese Teilindizes werden schließlich zu einem “zusammengesetzten Indikator für systemischen Stress” (*Finanzmarktstress*) aggregiert.

Zinssatzdifferenziale. Wir quantifizieren Spannungen an den Anleihemärkten, indem wir uns nur auf das Länderrisiko konzentrieren. Dies ist durch ihren Benchmark-Status und ihre Größe motiviert, die dazu führt, dass der Stress auf Staatsanleihen schnell auf andere Marktsegmente übergreift und dadurch Risiken für das Finanzsystem als Ganzes schafft. Wir messen den Stress an den Märkten für Staatsanleihen an der Renditedifferenz zwischen dem Zinssatz für zehnjährige Anleihen eines Landes und dem deutschen Pendant, wobei letzteres als sicheres Referenzpapier angesehen wird. Unsere Zinsdifferenzmessungen erfassen das gesamte Länderrisiko und werden als Teilkomponente des Gesamtindex verwendet, um das Gesamtniveau des finanziellen Stresses zu identifizieren.

Volatilität der Zinssatzdifferenziale. Intuitiv sollte die Volatilität Informationen aufdecken können, die allein aus dem Niveau der Zinssatzdifferenziale schwer zu extrahieren sind. In diesem Zusammenhang zeigen Cieslak und Povala (2016), dass in dem Maße, in dem die erwarteten kurzfristigen Zinssätze die Markterwartungen über den Pfad der Geldpolitik widerspiegeln, ihre Volatilität das Ausmaß der Unsicherheit über diesen Pfad offenbaren kann. Daher ergänzen die Spread-Volatilitäten die Informationen der Zinssatzdifferenziale in Bezug auf ihre Informationen über das Ausmaß der Notlage an den Finanzmärkten. Wir betrachten drei Messgrößen der Spread-Volatilitäten, von denen zwei länderübergreifend und eine im Inland erhoben werden. Die beiden länderübergreifenden Spread-Volatilitäten berücksichtigen die Volatilität der Differenz zwischen den Zinssätzen inländischer langfristiger (10 Jahre) und kurzfristiger (1 Jahr) Staatsanleihen und ihren deutschen lang- und kurzfristigen Pendants. Die inländische Spread-Volatilität ist die Volatilität der Differenz der Renditekurve, gemessen als Differenz zwischen den langfristigen (10 Jahre) und kurzfristigen (1 Jahr) Zinssätzen von Staatsanleihen. Die Volatilität ist als die quadratische Änderung des Zinssatzdifferenziale definiert.

Idiosynkratische Volatilität der Aktienrenditen von Finanzinstitutionen. Wir berücksichti-

gen sowohl Banken als auch Versicherungen in unserer Einschätzung, da beide eine Schlüsselrolle im Finanzsystem haben. Als Beitrag zur Messung des finanziellen Stresses verwenden wir die Volatilität der Aktienkurse von Finanzinstituten relativ zur Volatilität der Aktienkurse insgesamt. Die sich daraus ergebende idiosynkratische Volatilität der Aktienpreise ist jene Volatilität, die nicht durch Bewegungen auf dem gesamten Aktienmarkt erklärt werden kann. Dieses Maß wird als Varianz der unerwarteten täglichen Erträge ausgedrückt und wird aus dem Aktienindex eines Finanzinstituts und dem allgemeinen Aktienmarktindex berechnet. Das Maß soll dieselben Merkmale des finanziellen Stresses erfassen wie die impliziten Volatilitätsindizes, jedoch eher für den Finanzsektor als für den Unternehmenssektor insgesamt. Die idiosynkratische Volatilität von Aktienpreisen wird in drei Schritten abgeleitet. Der erste Schritt besteht in der Schätzung von Capital Asset Pricing Modellen (CAPM) auf Basis der täglichen Rendite der Aktienindizes der Finanzinstitute (Banken und Versicherungsgesellschaften). Hierbei wird die Rendite eines Finanzinstitutes zur Rendite des gesamten Aktienmarktindex ins Verhältnis gesetzt. Renditen werden als logarithmierte Differenzen gemessen. Der zweite Schritt besteht darin, die geschätzten Koeffizienten aus der CAPM-Regression und die Tagesrenditen auf den Gesamtbörsenindex zu verwenden, um die Restrendite auf den Aktienindex der Finanzinstitute für jeden Tag zu berechnen. Der letzte Schritt ist die Berechnung der Volatilität dieser täglichen Restrenditen, die durch die Berechnung der quadrierten täglichen Überschussrenditen erfolgt. Dies ergibt dann ein Maß für die idiosynkratische Volatilität der Aktienkurse von Finanzinstitutionen.

Querschnittsstreuung der Aktienrenditen von Finanzinstitutionen. Die Querschnittsstreuung der Aktienpreise wird wiederum anhand von Tagesdaten für Finanzinstitute berechnet. Das Streuungsmaß wird in drei Schritten berechnet, wobei der erste und zweite gleich jenen der Berechnung der idiosynkratischen Volatilität der Aktienrenditen von Finanzinstitutionen sind. Im dritten Schritt wird die Varianz für die restlichen Renditen der Finanzinstitute für jeden Tag berechnet. Dies ergibt ein Maß für die Querschnittsstreuung der Aktienrenditen von Finanzinstitutionen.

Länderübergreifende Streuung der Aktienrenditen. Die länderübergreifende Streuung der Aktienkurse wird anhand täglicher Daten für den gesamten Aktienmarktindex eines bestimmten Landes und den Eurostoxx50 als internationales Pendant berechnet. Das Maß für die länderübergreifende Streuung wird auf die gleiche Weise berechnet wie die idiosynkratische Volatilität der Aktienrenditen von Finanzinstituten, allerdings bezieht die betrachtete Volatilität der Überrendite nun den gesamten Aktienmarktindex eines Landes im Verhältnis zum Eurostoxx50 ein. Die entsprechende Überschussrenditevolatilität ist ein Maß für das Länderrisiko insgesamt.

Geldmarkt. Wir erfassen Stress auf dem Geldmarkt durch ein Länderäquivalent des US-TED-Spreads, d.h. durch die Renditedifferenz zwischen einem kurzfristigen unbesicherten

Interbankenmarktsatz und einem vergleichbaren, im Wesentlichen risikofreien, Satz kurzfristiger Staatsanleihen (wir betrachten hier durchgehend eine einjährige Staatsanleihe). Dieser Spread spiegelt das Liquiditäts- und Gegenparteirisiko auf dem Interbankenmarkt (wie in Heider et al., 2010; Acharya und Skeie, 2011).

2.5.1 Die ökonometrische Methodologie

Wie in Connor et al. (2006) hervorgehoben wurde, gibt es eine starke Gemeinsamkeit im Heteroskedastizitätsmuster der Überschussrenditevolatilitäten und Risikodifferentiale. Dies führt dazu, dass der Durchschnitt der Überschussrenditevolatilitäten über N Vermögenswerte im Laufe der Zeit variiert. Wir erfassen die darin enthaltene Gemeinsamkeit mit einem Zeitreihenmodell, in dem wir den Satz von Teilindikatoren $\varsigma_{i,t}$ zu einer gemeinsamen Komponente μ_t über die Querschnittsdimension hinweg in Beziehung setzen. Wir tun dies mit Hilfe eines *local-level* Modells. Hierbei erhält man die gemeinsame Komponente μ_t aus dem folgenden Gleichungssystem

$$\varsigma_t = \bar{\varsigma} + H\mu_t + \Theta(L)e_t \quad \text{with } e_t \sim N(0, \Sigma) \quad (9)$$

$$\mu_t = \mu_{t-1} + u_t \quad \text{with } u_t \sim N(0, 1) \quad (10)$$

wobei wir annehmen, dass $\Sigma = \text{diag}(\sigma_1^2, \dots, \sigma_N^2)$ und $H = [\eta_1, \dots, \eta_N]'$ die $N \times 1$ Exposure-Matrix (Vektor) der Überschussrendite-Volatilitäten gegenüber der gemeinsamen Komponente μ_t ist.

In dieser Form geschrieben, wird die gemeinsame, wenn auch latente Komponente auf der Grundlage sowohl der historischen Kreuzkorrelationen des Vektors der Variablen ς_t , als auch ihrer eigenen historischen Autokorrelationen, die in die Zustandsgleichung (10) eingebettet sind, identifiziert. Im Gegensatz dazu gehen die Kreuzkorrelationen der Variablen über die Beobachtungsgleichung (9) des Modells ein, wobei jede der Variablen N über die Faktorladungen η_1, \dots, η_N , die in der Systemmatrix H enthalten sind, auf die gemeinsame Komponente bezogen wird. Wir bewerten die Sensitivität unserer Ergebnisse in Bezug auf die Spezifikation der Zustandsgleichung (10). Zu diesem Zweck setzen wir eine nichtlineare Erweiterung mittels einer Markov-Kette mit zwei Zuständen um.

Klassische Modelle sind in diesem Zusammenhang durch (multivariate) bedingte (Volatilitäts-) Modelle gegeben. Unser Kontext erlaubt jedoch deren Verwendung nicht, da das Problem der fehlenden Beobachtungen an verschiedenen Stellen auftritt. Die Aussetzung des Handels mit einzelnen Vermögenswertpapieren, der Zusammenbruch von Banken, die Liquidation und Umstrukturierung von Banken oder Teilen davon, usw., bringen die Möglichkeit mit sich, dass Beobachtungen in der Zeitreihe der Vermögenspreise fehlen. Ein Merkmal von ς_t in unserem Kontext ist, dass es Reihen enthält, die zu unterschiedlichen Zeitpunkten innerhalb der Stichprobe beginnen und enden. Aus diesem Grund verwenden wir einen Modellierungsansatz, der

zeitvariable Volatilitäten und Spreads innerhalb einer multivariaten Umgebung erfasst, in der fehlende Beobachtungen kein Hindernis für die Schätzung darstellen. Wir transferieren die Gleichungen (9) und (10) in ein Zustandsraumformat und schätzen seine Parameter durch Ausführen des Kalman-Filters unter Verwendung Bayes'scher Kalman-Filtermethoden.

2.6 Anhang: Korrelationsanalyse

Abbildung 20: Bruttoinlandsprodukt

	Freq.	N	Korrelationskoeff.			DRC	QCD			
			t0	t1	t2		t3	1	2	3
BIP real (ER19)	q	(92)	0,92	0,87	0,70	0,47	71%	0,9	0,7	0,8
BIP real (IT)	q	(92)	0,86	0,83	0,69	0,48	69%	0,9	0,7	0,7
Offene Stellen Dienstleistungssektor ohne Tourismus (AT)	m	(60)	0,84	0,79	0,66	0,52	71%	1,1	0,8	0,8
LKW-Fahrleistung (AT)	m/w*	(60)	0,88	0,84	0,65	0,41	63%	1,3	0,9	0,7
Offene Stellen Industrie (AT)	m	(60)	0,83	0,80	0,67	0,48	63%	0,9	0,8	0,9
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,76	0,80	0,68	0,47	57%	0,8	0,7	0,6
Produktionsindex Industrie (AT)	m	(92)	0,91	0,79	0,59	0,36	70%	1,2	0,8	0,7
Vertrauensindikator Industrie (IT)	m	(92)	0,86	0,80	0,61	0,37	64%	0,9	0,7	0,7
Warenexporte (AT)	m	(92)	0,84	0,77	0,60	0,37	66%	0,9	0,7	0,6
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,76	0,78	0,64	0,40	60%	1,3	1,0	0,8
Warenexporte real (AT)	m	(92)	0,77	0,76	0,62	0,42	60%	1,3	0,8	0,6
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,86	0,76	0,57	0,33	67%	1,4	1,0	0,8
Erwartungsindex Industrie (AT)	m	(92)	0,78	0,76	0,59	0,34	66%	1,3	1,0	0,8
BIP real (MOEL5)	q	(88)	0,81	0,74	0,56	0,34	62%	1,3	0,9	0,8
Vertrauensindikator Industrie (ER19)	m	(92)	0,85	0,77	0,55	0,28	67%	0,9	0,8	0,7
BIP real (DE)	q	(92)	0,82	0,75	0,56	0,30	66%	1,2	0,8	0,8
Offene Stellen Tourismus (AT)	m	(60)	0,73	0,69	0,59	0,41	69%	1,8	1,1	0,9
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,83	0,77	0,54	0,28	67%	1,6	1,1	0,8
Wöchentlicher Aktivitätsindex (DE)	w*	(62)	0,60	0,67	0,63	0,49	56%	2,2	1,6	0,9
Gewichteter Vertrauensindikator Industrie (Exportmärkte)	m	(92)	0,80	0,74	0,54	0,27	68%	0,9	0,8	0,7
Konsumentenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(92)	0,63	0,69	0,60	0,43	62%	1,6	1,2	0,8
Lageindex Dienstleistungssektor (AT)	m	(92)	0,81	0,69	0,50	0,29	60%	1,6	1,1	1,0
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,81	0,71	0,50	0,27	67%	1,1	0,9	0,8
Containerumschlag (global)	m	(48)	0,76	0,70	0,50	0,23	66%	0,5	0,5	0,5
Konsumentenvertrauen (AT)	m	(92)	0,50	0,60	0,59	0,49	58%	1,5	1,2	1,0

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – Korrelationen werden entsprechend der Korrelationsstärke und Vorzeichen des Korrelationskoeffizienten von +1 (grün) bis -1 (blau) dargestellt. – DRC ... directional change; je höher der Prozentsatz der korrekt angezeigten Richtungsänderungen, desto dunkler die blaue Schattierung. – QCD ... quarters-for-cyclical-dominance; das jeweils erste Unterschreiten von 1 ist fett markiert.

Abbildung 21: Bruttowertschöpfung Industrie

	Freq.	N	Korrelationskoeffizient			DRC	QCD			
			t0	t1	t2		t3	1	2	3
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,86	0,83	0,65	0,37	60%	0,8	0,7	0,6
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,81	0,79	0,60	0,32	67%	1,3	1,0	0,8
Offene Stellen Industrie (AT)	m	(60)	0,84	0,75	0,56	0,32	69%	0,9	0,8	0,9
Wöchentlicher Aktivitätsindex (DE)	w*	(62)	0,67	0,71	0,62	0,42	57%	2,2	1,6	0,9
LKW-Fahrleistung (AT)	m/w*	(60)	0,88	0,79	0,53	0,23	59%	1,3	0,9	0,7
Erwartungsindex Industrie (AT)	m	(92)	0,83	0,77	0,55	0,26	62%	1,3	1,0	0,8
BIP real (ER19)	q	(92)	0,85	0,74	0,54	0,27	67%	0,9	0,7	0,8
BIP real (IT)	q	(92)	0,81	0,73	0,55	0,31	65%	0,9	0,7	0,7
BIP real (DE)	q	(92)	0,88	0,74	0,51	0,20	62%	1,2	0,8	0,8
Offene Stellen Dienstleistungssektor ohne Tourismus (AT)	m	(60)	0,79	0,68	0,49	0,31	68%	1,1	0,8	0,8
Produktionsindex Industrie (AT)	m	(92)	0,89	0,70	0,48	0,20	73%	1,2	0,8	0,7
Warenexporte (AT)	m	(92)	0,86	0,72	0,48	0,20	66%	0,9	0,7	0,6
Gewichteter Vertrauensindikator Industrie (Exportmärkte)	m	(92)	0,83	0,73	0,49	0,18	64%	0,9	0,8	0,7
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,82	0,73	0,47	0,19	63%	1,6	1,1	0,8
Vertrauensindikator Industrie (ER19)	m	(92)	0,84	0,72	0,47	0,17	65%	0,9	0,8	0,7
Vertrauensindikator Industrie (IT)	m	(92)	0,77	0,69	0,48	0,22	62%	0,9	0,7	0,7
Konsumentenvertrauen (AT)	m	(92)	0,51	0,59	0,57	0,46	56%	1,5	1,2	1,0
Konsumentenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(92)	0,62	0,64	0,52	0,32	64%	1,6	1,2	0,8
Containerumschlag (global)	m	(48)	0,81	0,70	0,43	0,11	68%	0,5	0,5	0,5
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,80	0,66	0,41	0,15	63%	1,1	0,9	0,8
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,78	0,64	0,42	0,15	63%	1,4	1,0	0,8
Warenexporte real (AT)	m	(92)	0,72	0,64	0,43	0,18	58%	1,3	0,8	0,6
Offene Stellen Tourismus (AT)	m	(60)	0,69	0,59	0,43	0,22	63%	1,8	1,1	0,9
Vertrauensindikator Industrie (DE)	m	(92)	0,77	0,63	0,38	0,08	66%	0,9	0,8	0,7
BIP real (MOEL5)	q	(88)	0,70	0,59	0,39	0,14	56%	1,3	0,9	0,8

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance.

Abbildung 22: Bruttowertschöpfung Bau

	Freq.	N	Korrelationskoeffizient				DRC			QCD			
			t0	t1	t2	t3	t3	1	2	3	1	2	3
Anzahl Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,82	0,78	0,71	0,61	58%	1,1	0,8	0,7	1,1	0,8	0,7
Offene Stellen Bausektor (AT)	m	(60)	0,61	0,69	0,71	0,71	63%	1,7	1,1	0,9	1,7	1,1	0,9
Wert Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,68	0,70	0,68	0,63	53%	1,2	1,1	1,2	1,2	1,1	1,2
Offene Stellen Industrie (AT)	m	(60)	0,63	0,67	0,66	0,60	68%	0,9	0,8	0,9	0,9	0,8	0,9
Offene Stellen Dienstleistungssektor ohne Tourismus (AT)	m	(60)	0,66	0,66	0,59	0,57	63%	1,1	0,8	0,8	1,1	0,8	0,8
Anzahl Zahlungsverkehr SCT / B2B / ATIP (AT/global) ²⁾	t*	(20)	-0,79	-0,66	-0,49	-0,37	58%	1,4	1,0	1,2	1,4	1,0	1,2
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,62	0,64	0,56	0,45	60%	0,8	0,7	0,6	0,8	0,7	0,6
LKW-Fahrleistung (AT)	m/w*	(60)	0,65	0,63	0,52	0,39	58%	1,3	0,9	0,7	1,3	0,9	0,7
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,66	0,63	0,50	0,37	58%	1,4	1,0	0,8	1,4	1,0	0,8
Produktionsindex Bau (AT)	m	(92)	0,68	0,47	0,45	0,46	79%	2,7	1,6	1,2	2,7	1,6	1,2
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,61	0,60	0,48	0,34	60%	1,6	1,1	0,8	1,6	1,1	0,8
Offene Stellen Tourismus (AT)	m	(60)	0,50	0,51	0,52	0,50	64%	1,8	1,1	0,9	1,8	1,1	0,9
Erwartungsindex Tourismus (AT)	m	(75)	0,59	0,60	0,46	0,37	50%	2,4	1,6	1,2	2,4	1,6	1,2
Erwartungsindex Industrie (AT)	m	(92)	0,57	0,58	0,49	0,37	62%	1,3	1,0	0,8	1,3	1,0	0,8
Lageindex Dienstleistungssektor (AT)	m	(92)	0,65	0,57	0,42	0,32	60%	1,6	1,1	1,0	1,6	1,1	1,0
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,52	0,55	0,50	0,37	58%	1,3	1,0	0,8	1,3	1,0	0,8
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,57	0,55	0,46	0,33	60%	1,1	0,9	0,8	1,1	0,9	0,8
Baltic Dry Index (global)	t*	(92)	0,57	0,58	0,47	0,28	63%	1,3	0,8	0,6	1,3	0,8	0,6
Vertrauensindikator Industrie (ER19)	m	(92)	0,56	0,55	0,46	0,33	67%	0,9	0,8	0,7	0,9	0,8	0,7
Konsumentenvertrauen (AT)	m	(92)	0,41	0,51	0,51	0,47	56%	1,5	1,2	1,0	1,5	1,2	1,0
Konsumentenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(92)	0,46	0,54	0,48	0,39	62%	1,6	1,2	0,8	1,6	1,2	0,8
Vertrauensindikator Industrie (IT)	m	(92)	0,51	0,53	0,46	0,37	59%	0,9	0,7	0,7	0,9	0,7	0,7
Wert Zahlungsverkehr SCT / B2B / ATIP (AT/global) ²⁾	t*	(20)	-0,44	-0,42	-0,45	-0,53	42%	2,4	1,6	1,1	2,4	1,6	1,1
BIP real (EU27)	q	(92)	0,52	0,51	0,44	0,34	54%	0,9	0,7	0,8	0,9	0,7	0,8
Gewichteter Vertrauensindikator Industrie (Exportmärkte)	m	(92)	0,53	0,53	0,43	0,31	64%	0,9	0,8	0,7	0,9	0,8	0,7

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance. – 1) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Lastschriften) und nationalen Interbankzahlungen (FINPAY Last- und Gutschriften). – 2) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Gutschriften) und nationalen Interbankzahlungen (SEPA Gut- und Edifact-Lastschriften), sowie nur zwischen Firmen nutzbare grenzüberschreitende und nationale Interbankzahlungen (SEPA Lastschriften).

Abbildung 23: Bruttowertschöpfung Marktdienstleistungen

	Freq.	N	Korrelationskoeffizient				DRC	QCD		
			t0	t1	t2	t3		1	2	3
BIP real (ER19)	q	(92)	0,78	0,78	0,69	0,53	70%	0,9	0,7	0,8
BIP real (IT)	q	(92)	0,74	0,75	0,68	0,53	66%	0,9	0,7	0,7
Offene Stellen Dienstleistungssektor ohne Tourismus (AT)	m	(60)	0,70	0,72	0,68	0,59	68%	1,1	0,8	0,8
Warenexporte real (AT)	m	(92)	0,65	0,72	0,68	0,54	51%	1,3	0,8	0,6
LKW-Fahrleistung (AT)	m/w*	(60)	0,70	0,73	0,66	0,50	56%	1,3	0,9	0,7
Warenexporte (AT)	m	(92)	0,67	0,70	0,61	0,46	58%	0,9	0,7	0,6
Vertrauensindikator Industrie (IT)	m	(92)	0,76	0,72	0,57	0,38	67%	0,9	0,7	0,7
Produktionsindex Industrie (AT)	m	(92)	0,73	0,70	0,57	0,42	58%	1,2	0,8	0,7
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,52	0,66	0,65	0,56	53%	0,8	0,7	0,6
Offene Stellen Industrie (AT)	m	(60)	0,62	0,65	0,61	0,50	56%	0,9	0,8	0,9
Anzahl Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,56	0,58	0,67	0,56	68%	1,1	0,8	0,7
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,72	0,65	0,54	0,38	59%	1,4	1,0	0,8
Offene Stellen Tourismus (AT)	m	(60)	0,60	0,62	0,59	0,46	59%	1,8	1,1	0,9
BIP real (MOEL5)	q	(88)	0,68	0,66	0,54	0,38	61%	1,3	0,9	0,8
Containerumschlag (global)	m	(48)	0,59	0,63	0,58	0,42	66%	0,5	0,5	0,5
Anzahl Zahlungsverkehr SCT / B2B / ATIP (AT/global) ²⁾	t*	(20)	-0,59	-0,58	-0,51	-0,48	68%	1,4	1,0	1,2
BIP real (DE)	q	(92)	0,60	0,60	0,49	0,32	71%	1,2	0,8	0,8
Lageindex Dienstleistungssektor (AT)	m	(92)	0,65	0,58	0,45	0,31	62%	1,6	1,1	1,0
Wert Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,38	0,44	0,57	0,57	42%	1,2	1,1	1,2
Vertrauensindikator Industrie (ER19)	m	(92)	0,65	0,60	0,45	0,25	62%	0,9	0,8	0,7
Wöchentlicher Aktivitätsindex (DE)	w*	(62)	0,43	0,52	0,51	0,49	61%	2,2	1,6	0,9
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,53	0,58	0,50	0,34	59%	1,3	1,0	0,8
Konsumtenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(92)	0,48	0,54	0,50	0,39	58%	1,6	1,2	0,8
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,62	0,58	0,43	0,25	62%	1,6	1,1	0,8
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,62	0,56	0,41	0,26	68%	1,1	0,9	0,8

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance. – 1) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Lastschriften) und nationalen Interbankzahlungen (FINPAY Last- und Gutschriften). – 2) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Gutschriften) und nationalen Interbankzahlungen (SEPA Gut- und Edifact-Lastschriften), sowie nur zwischen Firmen nutzbare grenzüberschreitende und nationale Interbankzahlungen (SEPA Lastschriften).

Abbildung 24: Bruttowertschöpfung Tourismus

	Freq.	N	Korrelationskoeffizient				DRC	QCD		
			t0	t1	t2	t3		1	2	3
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,58	0,59	0,57	0,47	55%	1,4	1,0	0,8
BIP real (MOEL5)	q	(88)	0,51	0,59	0,57	0,50	47%	1,3	0,9	0,8
Lageindex Tourismus (AT)	m	(75)	0,59	0,60	0,52	0,39	51%	2,8	1,8	1,3
Lageindex Dienstleistungssektor (AT)	m	(92)	0,55	0,55	0,51	0,41	51%	1,6	1,1	1,0
BIP real (EU27)	q	(92)	0,47	0,53	0,53	0,48	55%	0,9	0,7	0,8
Vertrauensindikator Industrie (IT)	m	(92)	0,46	0,55	0,53	0,45	45%	0,9	0,7	0,7
Flugbewegungen (AT)	m	(76)	0,57	0,58	0,50	0,35	60%	1,1	0,8	0,6
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,47	0,53	0,52	0,46	57%	1,1	0,9	0,8
Erwartungsindex Tourismus (AT)	m	(75)	0,57	0,55	0,47	0,36	57%	2,4	1,6	1,2
BIP real (IT)	q	(92)	0,45	0,50	0,53	0,46	57%	0,9	0,7	0,7
Produktionsindex Industrie (AT)	m	(92)	0,51	0,53	0,49	0,40	63%	1,2	0,8	0,7
LKW-Fahrleistung (AT)	m/w*	(60)	0,48	0,54	0,50	0,41	64%	1,3	0,9	0,7
Flugpassagiere (AT)	m	(76)	0,51	0,55	0,51	0,34	52%	1,4	0,9	0,6
Unsicherheitsindex (AT)	q	(92)	-0,59	-0,54	-0,46	-0,31	42%	1,8	1,3	1,1
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,49	0,53	0,47	0,39	51%	1,6	1,1	0,8
Arbeitslose (AT)	w*	(92)	-0,58	-0,53	-0,44	-0,33	43%	1,0	0,8	0,8
Vertrauensindikator Industrie (EU27)	m	(92)	0,44	0,52	0,50	0,40	48%	0,9	0,8	0,7
Vertrauensindikator Industrie (MOEL5)	m	(88)	0,45	0,52	0,50	0,39	59%	1,2	0,8	0,8
Anzahl Zahlungsverkehr SCT / B2B / ATIP (AT/global)*	t*	(20)	-0,41	-0,34	-0,43	-0,51	68%	1,4	1,0	1,2
Lageindex Herstellung von Investitionsgütern (AT)	m	(92)	0,53	0,50	0,39	0,27	53%	1,2	1,0	1,0
Beschäftigte Dienstleistungssektor ohne Tourismus (AT)	m	(92)	0,60	0,49	0,35	0,22	56%	0,9	0,8	0,8
Beschäftigte Dienstleistungssektor (AT)	m	(92)	0,60	0,47	0,31	0,17	52%	1,1	0,8	0,8
Preise für Benzin Euro-Super 95 (AT)	w*	(68)	0,49	0,51	0,36	0,16	55%	1,1	0,6	0,5
Preise für schweres Heizöl (AT)	w*	(68)	0,56	0,49	0,31	0,12	57%	0,9	0,6	0,5
Preise für Automobil-Kraftstoffe (AT)	w*	(68)	0,52	0,48	0,30	0,11	51%	0,9	0,5	0,4

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance. – 1) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Gutschriften) und nationalen Interbankzahlungen (SEPA Gut- und Edifact-Lastschriften), sowie nur zwischen Firmen nutzbare grenzüberschreitende und nationale Interbankzahlungen (SEPA Lastschriften).

Abbildung 25: Bruttowertschöpfung Marktdienstleistungen ohne Tourismus

	Freq.	N	Korrelationskoeff.			DRC	QCD			
			t0	t1	t2		t3	1	2	3
Offene Stellen Dienstleistungssektor ohne Tourismus (AT)	m	(60)	0,70	0,72	0,68	0,58	69%	1,1	0,8	0,8
BIP real (ER19)	q	(88)	0,77	0,76	0,64	0,48	72%	0,9	0,8	0,8
Offene Stellen Dienstleistungssektor (AT)	m	(60)	0,69	0,71	0,67	0,57	69%	1,1	0,8	0,8
BIP real (IT)	q	(88)	0,74	0,72	0,63	0,48	69%	0,9	0,8	0,8
LKW-Fahrleistung (AT)	m/w*	(60)	0,70	0,73	0,65	0,49	58%	1,3	0,9	0,7
Warenexporte real (AT)	m	(88)	0,65	0,70	0,61	0,46	51%	1,3	0,8	0,6
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,53	0,66	0,66	0,57	55%	0,8	0,7	0,6
Offene Stellen Industrie (AT)	m	(60)	0,63	0,66	0,61	0,49	58%	0,9	0,8	0,9
Vertrauensindikator Industrie (IT)	m	(88)	0,75	0,70	0,55	0,36	69%	1,0	0,8	0,7
Produktionsindex Industrie (AT)	m	(88)	0,72	0,68	0,52	0,37	57%	1,2	0,8	0,7
Offene Stellen Tourismus (AT)	m	(60)	0,59	0,62	0,59	0,45	58%	1,8	1,1	0,9
Warenexporte (AT)	m	(88)	0,68	0,67	0,54	0,37	62%	1,0	0,7	0,6
Anzahl Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,53	0,57	0,64	0,50	74%	1,1	0,8	0,7
Containerumschlag (global)	m	(48)	0,58	0,62	0,59	0,43	68%	0,5	0,5	0,5
BIP real (MOEL5)	q	(88)	0,68	0,65	0,52	0,35	63%	1,3	0,9	0,8
Erwartungsindex Dienstleistungssektor (AT)	m	(88)	0,70	0,62	0,48	0,32	62%	1,4	1,0	0,8
Konsumentenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(88)	0,50	0,57	0,55	0,44	57%	1,6	1,3	0,8
BIP real (DE)	q	(88)	0,61	0,60	0,48	0,30	72%	1,2	0,8	0,8
Wöchentlicher Aktivitätsindex (DE)	w*	(62)	0,43	0,52	0,51	0,50	64%	2,2	1,6	0,9
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(88)	0,63	0,59	0,45	0,27	61%	1,6	1,2	0,9
Lageindex Dienstleistungssektor (AT)	m	(88)	0,64	0,56	0,42	0,27	64%	1,6	1,1	1,0
Vertrauensindikator Industrie (ER19)	m	(88)	0,65	0,59	0,42	0,23	63%	0,9	0,8	0,8
Anzahl Zahlungsverkehr SCT / B2B / ATIP (AT/global) ²⁾	t*	(20)	-0,52	-0,53	-0,43	-0,38	63%	1,4	1,0	1,2
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(88)	0,53	0,56	0,47	0,30	62%	1,4	1,0	0,8
Erwartungsindex Industrie (AT)	m	(88)	0,54	0,55	0,44	0,28	64%	1,4	1,1	0,8

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance. – 1) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Lastschriften) und nationalen Interbankzahlungen (FINPAY Last- und Gutschriften). – 2) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Gutschriften) und nationalen Interbankzahlungen (SEPA Gut- und Edifact-Lastschriften), sowie nur zwischen Firmen nutzbare grenzüberschreitende und nationale Interbankzahlungen (SEPA Lastschriften).

Abbildung 26: Privater Konsum

	Freq.	N	Korrelationskoeff.			DRC	QCD			
			t0	t1	t2		t3	1	2	3
Wert Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,60	0,58	0,50	0,15	63%	1,2	1,1	1,2
Wert Zahlungsverkehr SCT / B2B / ATIP (AT/global) ²⁾	t*	(20)	-0,40	-0,52	-0,48	-0,26	53%	2,4	1,6	1,1
Anzahl Zahlungsverkehr CORE / FINPAY (AT/global) ¹⁾	t*	(20)	0,55	0,41	0,34	-0,05	58%	1,1	0,8	0,7
PM10 – 6 Messstellen (AT)	t*	(16)	-0,42	0,10	0,57	0,23	20%	2,7	2,0	0,7
NO ₂ – 6 Messstellen (AT)	t*	(16)	-0,38	0,08	0,51	0,28	20%	2,1	1,5	0,7
NO ₂ – Industriennahe Messstellen NO ₂ (AT)	t*	(12)	-0,19	0,16	0,70	-0,19	18%	2,7	1,8	0,1
NO ₂ – Verkehrsnahe Messstellen NO ₂ (AT)	t*	(16)	-0,41	0,06	0,51	0,25	20%	2,1	1,5	0,6
NO ₂ – Industrie- und verkehrsnaher Messstellen (AT)	t*	(16)	-0,38	0,07	0,53	0,23	27%	2,5	1,9	0,8

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance. – 1) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Lastschriften) und nationalen Interbankzahlungen mit Mehrfach-Interbanküberweisungen (FINPAY Last- und Gutschriften). – 2) Summe aus grenzüberschreitenden Interbankzahlungen über Clearingpartner bzw. Teilnehmerbanken (SEPA Gutschriften) und nationalen Interbankzahlungen (SEPA Gut- und Edifact-Lastschriften), sowie nur zwischen Firmen nutzbare grenzüberschreitende und nationale Interbankzahlungen (SEPA Lastschriften).

Abbildung 27: Bruttoanlageinvestitionen

	Freq.	N	Korrelationskoeff.			DRC	QCD			
			t0	t1	t2		t3	1	2	3
Offene Stellen Industrie (AT)	m	(60)	0,67	0,79	0,81	0,75	54%	0,9	0,8	0,9
Vertrauensindikator Industrie (ER19)	m	(92)	0,72	0,77	0,68	0,49	63%	0,9	0,8	0,7
LKW-Fahrleistung (AT)	m/w*	(60)	0,69	0,69	0,67	0,59	71%	1,3	0,9	0,7
Offene Stellen Dienstleistungssektor (AT)	m	(60)	0,64	0,69	0,67	0,62	56%	1,1	0,8	0,8
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,51	0,65	0,72	0,72	45%	0,8	0,7	0,6
Gewichteter Vertrauensindikator Industrie (Exportmärkte)	m	(92)	0,67	0,74	0,67	0,50	57%	0,9	0,8	0,7
Offene Stellen Bausektor (AT)	m	(60)	0,62	0,66	0,65	0,59	63%	1,7	1,1	0,9
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,65	0,72	0,63	0,48	63%	1,6	1,1	0,8
Erwartungsindex Industrie (AT)	m	(92)	0,61	0,69	0,65	0,52	59%	1,3	1,0	0,8
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,68	0,69	0,62	0,44	58%	1,1	0,9	0,8
Vertrauensindikator Industrie (DE)	m	(92)	0,68	0,71	0,62	0,44	59%	0,9	0,8	0,7
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,56	0,67	0,67	0,54	60%	1,3	1,0	0,8
Lageindex Industrie (AT)	m	(92)	0,71	0,69	0,59	0,40	63%	1,1	0,9	0,9
BIP real (EU27)	q	(92)	0,60	0,65	0,61	0,52	63%	0,9	0,7	0,8
Offene Stellen Tourismus (AT)	m	(60)	0,51	0,60	0,64	0,61	58%	1,8	1,1	0,9
Lageindex Dienstleistungssektor (AT)	m	(92)	0,73	0,68	0,55	0,39	60%	1,6	1,1	1,0
Vertrauensindikator Industrie (IT)	m	(92)	0,60	0,67	0,61	0,46	59%	0,9	0,7	0,7
Produktionsindex Industrie (AT)	m	(92)	0,62	0,64	0,58	0,47	66%	1,2	0,8	0,7
BIP real (DE)	q	(92)	0,57	0,63	0,59	0,52	59%	1,2	0,8	0,8
Lageindex Herstellung von Investitionsgütern (AT)	m	(92)	0,76	0,69	0,54	0,32	60%	1,2	1,0	1,0
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,68	0,67	0,55	0,38	56%	1,4	1,0	0,8
Auslandsauftragsbestände Industrie (AT)	m	(92)	0,71	0,66	0,55	0,35	64%	1,3	1,0	0,9
Auftragsbestände Industrie (AT)	m	(92)	0,71	0,66	0,53	0,34	65%	1,2	1,0	0,9
Vertrauensindikator Industrie (MOEL5)	m	(88)	0,63	0,66	0,55	0,37	59%	1,2	0,8	0,8
BIP real (MOEL5)	q	(88)	0,58	0,59	0,55	0,41	63%	1,3	0,9	0,8

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directionaler change. – QCD ... quarters-for-cyclical-dominance.

Abbildung 28: Exporte i.w.S.

	Freq.	N	Korrelationskoeff.			DRC	QCD			
			t0	t1	t2		t3	1	2	3
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,89	0,90	0,69	0,37	60%	0,8	0,7	0,6
BIP real (IT)	q	(92)	0,88	0,81	0,62	0,36	66%	0,9	0,7	0,7
BIP real (ER19)	q	(92)	0,90	0,82	0,61	0,33	73%	0,9	0,7	0,8
Warenexporte (AT)	m	(92)	0,95	0,84	0,58	0,27	76%	0,9	0,7	0,6
Warenexporte real (AT)	m	(92)	0,83	0,77	0,57	0,30	59%	1,3	0,8	0,6
LKW-Fahrleistung (AT)	m/w*	(60)	0,88	0,80	0,56	0,21	63%	1,3	0,9	0,7
Wöchentlicher Aktivitätsindex (DE)	w*	(62)	0,63	0,70	0,65	0,47	61%	2,2	1,6	0,9
Produktionsindex Industrie (AT)	m	(92)	0,92	0,77	0,51	0,21	63%	1,2	0,8	0,7
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,74	0,74	0,59	0,32	64%	1,3	1,0	0,8
Containerumschlag (global)	m	(48)	0,89	0,82	0,53	0,13	68%	0,5	0,5	0,5
Offene Stellen Industrie (AT)	m	(60)	0,81	0,73	0,52	0,25	63%	0,9	0,8	0,9
Vertrauensindikator Industrie (IT)	m	(92)	0,81	0,71	0,51	0,25	65%	0,9	0,7	0,7
BIP real (DE)	q	(92)	0,84	0,72	0,48	0,18	69%	1,2	0,8	0,8
Erwartungsindex Industrie (AT)	m	(92)	0,73	0,69	0,51	0,24	65%	1,3	1,0	0,8
Offene Stellen Dienstleistungssektor ohne Tourismus (AT)	m	(60)	0,77	0,66	0,46	0,24	68%	1,1	0,8	0,8
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,77	0,67	0,46	0,21	62%	1,4	1,0	0,8
Vertrauensindikator Industrie (ER19)	m	(92)	0,79	0,67	0,43	0,14	68%	0,9	0,8	0,7
Konsumentenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(92)	0,56	0,60	0,51	0,35	60%	1,6	1,2	0,8
Gewichteter Vertrauensindikator Industrie (Exportmärkte)	m	(92)	0,76	0,66	0,44	0,14	67%	0,9	0,8	0,7
BIP real (MOEL5)	q	(88)	0,73	0,64	0,44	0,18	70%	1,3	0,9	0,8
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,73	0,65	0,43	0,15	57%	1,6	1,1	0,8
Preise für Benzin Euro-Super 95 ohne Steuern (AT)	w*	(68)	0,64	0,63	0,47	0,19	57%	1,1	0,7	0,5
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,74	0,61	0,39	0,12	62%	1,1	0,9	0,8
Lageindex Dienstleistungssektor (AT)	m	(92)	0,70	0,58	0,37	0,15	55%	1,6	1,1	1,0
Offene Stellen Tourismus (AT)	m	(60)	0,65	0,58	0,40	0,16	63%	1,8	1,1	0,9

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance.

Abbildung 29: Importe i.w.S.

	Freq.	N	Korrelationskoeff.			DRC	QCD			
			t0	t1	t2		t3	1	2	3
Wöchentlicher Aktivitätsindex (USA)	w*	(48)	0,85	0,86	0,65	0,32	51%	0,8	0,7	0,6
BIP real (IT)	q	(92)	0,85	0,79	0,58	0,31	66%	0,9	0,7	0,7
Warenexporte (AT)	m	(92)	0,92	0,81	0,53	0,19	65%	0,9	0,7	0,6
Wöchentlicher Aktivitätsindex (DE)	w*	(62)	0,63	0,69	0,67	0,46	54%	2,2	1,6	0,9
BIP real (ER19)	q	(92)	0,86	0,77	0,54	0,25	64%	0,9	0,7	0,8
Erwartungsindex Herstellung von Vorprodukten (AT)	m	(92)	0,74	0,75	0,60	0,32	64%	1,3	1,0	0,8
LKW-Fahrleistung (AT)	m/w*	(60)	0,88	0,76	0,53	0,16	76%	1,3	0,9	0,7
Produktionsindex Industrie (AT)	m	(92)	0,90	0,75	0,46	0,15	65%	1,2	0,8	0,7
Warenexporte real (AT)	m	(92)	0,78	0,73	0,50	0,23	62%	1,3	0,8	0,6
Offene Stellen Industrie (AT)	m	(60)	0,80	0,71	0,49	0,22	66%	0,9	0,8	0,9
Containerumschlag (global)	m	(48)	0,86	0,79	0,47	0,08	55%	0,5	0,5	0,5
Erwartungsindex Industrie (AT)	m	(92)	0,72	0,70	0,52	0,23	63%	1,3	1,0	0,8
Vertrauensindikator Industrie (IT)	m	(92)	0,76	0,69	0,49	0,22	67%	0,9	0,7	0,7
BIP real (DE)	q	(92)	0,83	0,70	0,43	0,12	58%	1,2	0,8	0,8
Gewichteter Vertrauensindikator Industrie (Exportmärkte)	m	(92)	0,75	0,68	0,45	0,13	63%	0,9	0,8	0,7
Konsumentenerwartungen zur wirtschaftlichen Entwicklung (AT)	m	(92)	0,52	0,58	0,52	0,35	56%	1,6	1,2	0,8
Vertrauensindikator Industrie (EU27)	m	(92)	0,77	0,67	0,43	0,11	65%	0,9	0,8	0,7
Offene Stellen Dienstleistungssektor (AT)	m	(60)	0,76	0,63	0,40	0,16	61%	1,1	0,8	0,8
Erwartungsindex Dienstleistungssektor (AT)	m	(92)	0,71	0,64	0,41	0,13	62%	1,4	1,0	0,8
Erwartungsindex Herstellung von Investitionsgütern (AT)	m	(92)	0,70	0,64	0,42	0,12	55%	1,6	1,1	0,8
BIP real (MOEL5)	q	(88)	0,70	0,62	0,42	0,13	68%	1,3	0,9	0,8
Baltic Dry Index (global)	t*	(92)	0,37	0,57	0,54	0,35	55%	1,3	0,8	0,6
Lageindex Herstellung von Vorprodukten (AT)	m	(92)	0,73	0,60	0,37	0,08	59%	1,1	0,9	0,8
Offene Stellen Tourismus (AT)	m	(60)	0,65	0,58	0,38	0,16	63%	1,8	1,1	0,9
Vertrauensindikator Industrie (MOEL5)	m	(88)	0,70	0,62	0,38	0,06	59%	1,2	0,8	0,8

Frequenz: m ... monatlich, q ... quartalsweise, t* ... täglich, w* ... wöchentlich. – DRC ... directional change. – QCD ... quarters-for-cyclical-dominance.

3 IHS-Teil zum Projektbericht

3.1 Economic High-Frequency Monitor

Das Ziel des *Economic High-Frequency Monitor* (<https://monitor.ihs.ac.at/>) ist die Bereitstellung zeitnaher und hochfrequenter Indikatoren zur Beurteilung ökonomischer Aktivitäten in Österreich. Diese Daten können in weiterer Folge auch zur Schätzung eines gleichlaufenden oder vorlaufenden Indikators für das Bruttoinlandsprodukt verwendet werden, sofern sie die dafür notwendigen Eigenschaften besitzen. Hierzu zählen: Die Indikatoren sollten regelmäßig - mindestens wöchentlich - und zeitnah verfügbar sein. Um mittels statistischer Modelle einen robusten Zusammenhang mit der wirtschaftlichen Aktivität schätzen zu können, sollten die Indikatoren über einen möglichst langen Zeitraum vorliegen. Der Fokus wurde auf „harte“ Indikatoren gelegt. Aktuell werden drei Zeitreihen auf diesem Tool abgebildet: die Schienengüterverkehrsleistung, der Stromverbrauch und die Arbeitslosenquote. Sie stehen zeitnah zur Verfügung - am Dienstag liegen die Werte der Vorwoche vor - und werden nicht oder nur geringfügig revidiert. Das IHS steht im Austausch mit anderen Institutionen und Datenanbietern, um den *Economic High Frequency Monitor* laufend zu erweitern.

3.1.1 Schienengüterverkehrsleistung

Die Daten zur Schienengüterverkehrsleistung (SGVL) liegen ab Januar 2008 und auf täglicher Basis vor. Die ÖBB Infrastruktur AG liefert jeden Dienstag aktuelle Daten zur vorangehenden Woche. Die Daten stellen die verrechneten Gesamtbruttotonnenkilometer (GBTKM) auf dem österreichischen Schienennetz dar. Unter dem Begriff der Gesamtbruttotonnen versteht man das Gewicht der Güter inklusive Verpackung, ggf. Container, Wagon und Triebfahrzeug.

Zunächst werden die Daten auf täglicher Frequenz saisonal und um Sondereffekte (Outlier) bereinigt. Hierfür wurde die DSA-Routine⁹ (daily calendar and seasonal adjustment) aus Ollech (2018) herangezogen. Diese basiert auf einer iterativen Anwendung von Saison-Trend Zerlegungen (siehe Cleveland et al., 1990), ARIMA-Modellierung und Sondereffektbereinigungen (siehe Chen und Liu, 1993). Bei der täglichen saisonalen Bereinigung werden 3 Saisonalitäten (Wochentag-, Monatstag- und Jahrestageeffekte) sowie bewegliche Feiertage (Ostern, Pfingsten, Fronleichnam und Christi Himmelfahrt) berücksichtigt.

Je nach betrachteter Zeitreihe treten Saisonalitäten unterschiedlich auf. Ein typischer Wochentageeffekt (saisonales Muster in einer Woche), innerhalb der SGVL wäre bspw. ein geringeres Transportaufkommen an Sonntagen. Monatstageeffekte (saisonales Muster innerhalb eines Monats) konnten für die SGVL nicht identifiziert werden. Jahrestageeffekte bilden die saisonalen Muster innerhalb eines Jahres ab. Als Beispiel hierfür können geringere Aufkommen

⁹Dabei wurde eine seitens des IHS modifizierte (und debugged) Version R-package dsa verwendet.

an nicht-beweglichen Feiertagen (Weihnachten) bzw. kurz vor oder nach diesen gebracht werden. Überdies können Jahrestageeffekte die monatlichen Saisonalitäten abbilden. Um Verzerrungen in der Schätzung der Saisonalität vorzubeugen, wurde die Stichprobe auf Ende Februar 2020 eingeschränkt und die Prognose der Saisonalität für die Bereinigung der Daten nach Februar 2020 verwendet. Da sich in den saisonal bereinigten täglichen Daten noch Tage mit unerwartet starken oder schwachen täglichen Aufkommen zeigten, wurden Sondereffekte mittels der Routine von Chen und Liu (1993) entfernt. Danach erfolgte eine Aggregation der täglichen Daten auf ISO 8601 Kalenderwochen, wobei der erste Donnerstag des Jahres die erste Kalenderwoche bestimmt. Die 53. Kalenderwoche, sofern vorhanden, wurde entfernt, um die Bildung von Jahresdifferenzen als 52ste Differenz zu erleichtern. Im High-Frequency Monitor sind die wöchentlichen Niveaus auf den Jahresdurchschnitt 2019 indexiert und die Wachstumsraten beschreiben den Vorjahresvergleich.

3.1.2 Arbeitslosenquote

Zur Berechnung der wöchentlichen Arbeitslosenquote wurden tägliche Daten zur Zahl der Arbeitslosen (ohne Schulungsteilnehmer) und monatliche Daten zum Beschäftigungspotential (Arbeitslose + unselbständig Beschäftigte) herangezogen. Die Daten zu den gemeldeten Arbeitslosen werden jeden Dienstag vom AMS für die vorangegangene Woche zur Verfügung gestellt. Daten zum Beschäftigungspotential werden der BALI Datenbank entnommen. Die Daten zu den Arbeitslosen wurden wie bereits oben beschrieben um Saison- und bewegliche Feiertageeffekte bereinigt. Die monatlichen Daten zum Beschäftigungspotential wurden mittels dem von Eurostat empfohlenen TRAMO-SEATS RSA FULL Verfahren (JDemetra+), saisonal- und Feiertagsbereinigt. Das bereinigte monatliche Beschäftigungspotential dem jeweiligen 15. eines Monats zugewiesen und linear auf die tägliche Frequenz interpoliert. Danach wurden beide tägliche Zeitreihen auf ISO 8601 Kalenderwochen über Durchschnittsbildung aggregiert. Die wöchentliche Arbeitslosenquote¹⁰ ergibt sich aus Arbeitslose geteilt durch Beschäftigungspotential und ist im High-Frequency Monitor ab 2008 dargestellt.

3.1.3 Stromverbrauch

Aktuelle Daten zum Stromverbrauch werden der Website des Verband Europäischer Übertragungsnetzbetreiber unter <https://www.entsoe.eu/> entnommen, auf welcher der durchschnittliche Stundenverbrauch je Viertelstunde in Megawatt für Österreich ausgewiesen wird. Die Daten liegen ab Januar 2010 bis zur aktuell vergangenen Stunde vor. Da jedoch die Tiroler Netze erst mit 2011 in den Daten erfasst sind, startet die für den Monitor verwendete Stichprobe mit 2011. Zur Bereinigung des Stromverbrauchs durch Schwankungen in

¹⁰Da Daten zum Beschäftigungspotential derzeit noch in monatlicher Frequenz verwendet werden, handelt es sich bei der dargestellten Arbeitslosenquote um eine Annäherung.

den Durchschnittstemperaturen (Heizung, Kühlung) wurde als eine weitere Datenquelle die täglichen durchschnittlichen Temperaturen der Messstation¹¹ Hohe Warte in Wien über die Website <https://api.meteostat.net/> bezogen. Um zeitgerechte Updates zu gewährleisten werden beide Daten über API-caller automatisiert aktualisiert.

Die viertelstündlichen Daten zum Stromverbrauch nach koordinierter Weltzeit (Coordinated Universal Time, UTC) wurden über Durchschnittsbildung in den stündlichen Verbrauch aggregiert. Danach erfolgt eine Übertragung in die Mitteleuropäische Zeit (Central European Time, CET) und eine Einschränkung auf den Verbrauch zwischen 08:00 bis 18:00, um auf den Verbrauch während der Kernarbeitszeiten zu fokussieren und um den zumeist nächtlichen Verbrauch von Pumpspeicherkraftwerken nicht zu berücksichtigen. Die täglichen Daten wurden dann wie oben beschrieben um Saison- und bewegliche Feiertageeffekte bereinigt. Zusätzlich wurde dabei die Tagesdurchschnittstemperatur als Polynom zweiten Grades berücksichtigt, um Stromspitzen für besonders kalte (Heizung) als auch heiße Tage (Kühlung) zu ermöglichen. Wie schon bei der Schienengüterverkehrsleistung zeigten sich beim saisonal bereinigten Stromverbrauch noch deutliche Sondereffekte, welche wie oben beschrieben entfernt wurden.

Abschließend erfolgt die Aggregation auf ISO 8601 Kalenderwochen über die Summen der täglichen Werte. Der Stromverbrauch ist im *Economic High-Frequency Monitor* normiert (Jahresdurchschnitt 2009 als Basis) und Wachstumsraten beschreiben den Vorjahresvergleich.

3.1.4 Tool

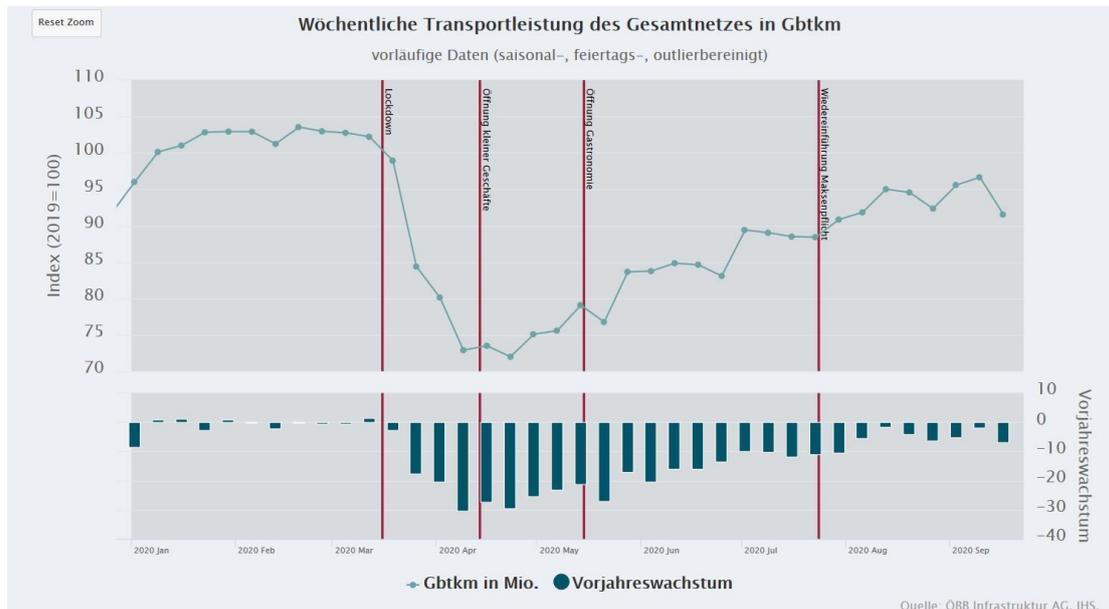
Der *Economic High-Frequency Monitor* ist unter der Internetadresse <https://monitor.ihs.ac.at/> zugänglich. Aktualisierungen werden wöchentlich vorgenommen, meist dienstags, da dann die Daten (ÖBB Infrastruktur und AMS) aus der Vorwoche vorliegen. Aufgrund der verwendeten Bereinigungsverfahren können sich Werte, insbesondere am aktuellen Rand, mit jeder Aktualisierung ändern. Da es noch keine offiziellen Empfehlungen zur Verwendung von Saisonbereinigungsverfahren mit täglichen Daten gibt¹², sollten die Ergebnisse noch als vorläufig aufgefasst werden (siehe auch Bundesbank, 2020b).

Abbildung 30 zeigt als einen Ausschnitt des Monitors die Verkehrsleistung auf dem österreichischen Schienennetz. Im oberen Abschnitt werden die wöchentlichen Werte in Form eines Index (2019=100) dargestellt, im unteren Bereich sind die Veränderungsraten zur Vorjahreswoche aufgetragen. Zusätzlich wurden die Zeitpunkte des Inkrafttretens wesentlicher COVID-19-Maßnahmenpakete markiert. Nähere Informationen zur Nutzung des Monitors sind unter <https://monitor.ihs.ac.at/> verfügbar.

¹¹Die in den österreichischen Wetterstationen gemessenen Temperaturen weisen eine hohe Korrelation auf. Zur Vereinfachung der Wartung und aufgrund der längsten Zeitreihe mit der geringsten Anzahl an fehlenden Werten wurde die Durchschnittstemperatur der Hohen Warte in Wien herangezogen.

¹²Die *Guidelines on seasonal adjustment* beinhalten derzeit noch keine Ausführungen über Bereinigungen von täglichen Daten (Eurostat, 2015).

Abbildung 30: Bildausschnitt High-Frequency Monitor



Quelle: <https://monitor.ihs.ac.at/>

3.1.5 Ausblick

Im Zuge des laufenden Projekts sollen Aktualisierungen des Monitors zunächst bis Ende Dezember 2020 erfolgen. Dabei sollen, sofern weitere Institutionen als Datenprovider gewonnen werden können, auch weitere Datenquellen einbezogen werden und laufend Verbesserungen hinsichtlich der Methodik erfolgen.

Literatur

- Acharya, Viral, and David Skeie (2011) 'A model of liquidity hoarding and term premia in inter-bank markets.' *Journal of Monetary Economics* 58(5), 436–447
- Andreou, Elena, Patrick Gagliardini, Eric Ghysels, and Mirco Rubin (2016) 'Is Industrial Production Still the Dominant Factor for the US Economy?' Swiss Finance Institute Research Paper Series 16-11, Swiss Finance Institute, February
- Angelini, Elena, Gonzalo Camba-Mendez, Domenico Giannone, Lucrezia Reichlin, and Gerhard Rünstler (2011) 'Short-term forecasts of euro area GDP growth.' *Econometrics Journal* 14(1), 25–44
- Aruoba, S. Boragan, Francis Diebold, and Chiara Scotti (2009) 'Real-time measurement of business conditions.' *Journal of Business & Economic Statistics* 27(4), 417–427
- Banbura, Marta, and Gerhard Rünstler (2011) 'A look into the factor model black box: Publication lags and the role of hard and soft data in forecasting GDP.' *International Journal of Forecasting* 27(2), 333–346
- Barhoumi, Karim, Gerhard Rünstler, Riccardo Cristadoro, Ard Den Reijer, Audrone Jakaitiene, Piotr Jelonek, António Rua, Karsten Ruth, Szilard Benk, and Christophe Van Nieuwenhuyze (2008) 'Short-term forecasting of GDP using large monthly datasets: A pseudo real-time forecast evaluation exercise.' Working papers 215, Banque de France, July

- Baumgartner, Josef, Serguei Kaniovski, Jürgen Bierbaumer-Polly, Christian Glocker, Ulrike Huemer, Simon Loretz, Helmut Mahringer, and Hans Pitlik (2020) ‘Die Wirtschaftsentwicklung in Österreich im Zeichen der COVID-19-Pandemie Mittelfristige Prognose 2020 bis 2024.’ *WIFO Monatsberichte* 93(4), 239–265
- Bock-Schappelwein, Julia, Rainer Eppel, Ulrike Huemer, Walter Hyll, and Helmut Mahringer (2020) ‘COVID-19-Pandemie: Rückgang der Beschäftigung und Anstieg der Arbeitslosigkeit halten im April an.’ WIFO Research Briefs 5/2020, WIFO, May
- Boivin, Jean, and Serena Ng (2006) ‘Are more data always better for factor analysis?’ *Journal of Econometrics* 132(1), 169–194
- Bundesbank, Deutsche (2020a) ‘Konjunktur in Deutschland.’ *Monatsbericht* 72(5), 62–75
- (2020b) ‘Saisonbereinigung des täglichen Lkw-Maut-Fahrleistungsindex.’ <https://www.bundesbank.de/>
- Camacho, Maximo, and Agustín García-Serrador (2014) ‘The Euro-Sting revisited: The usefulness of financial indicators to obtain Euro Area GDP forecasts.’ *Journal of Forecasting* 33(3), 186–197
- Camacho, Maximo, and Gabriel Pérez-Quirós (2011) ‘Spain-sting: Spain short-term indicator of growth.’ *Manchester School* 79(s1), 594–616
- Chen, Chung, and Lon-Mu Liu (1993) ‘Forecasting time series with outliers.’ *Journal of Forecasting* 12(1), 13–35
- Cieslak, Anna, and Pavol Povala (2016) ‘Information in the term structure of yield curve volatility.’ *Journal of Finance* 71(3), 1393–1436
- Clayton-Matthews, Alan, and Theodore M. Crone (2004) ‘Consistent economic indexes for the 50 states.’ Working Papers 04-9, Federal Reserve Bank of Philadelphia
- Cleveland, Robert B., William S. Cleveland, Jean E. McRae, and Irma Terpenning (1990) ‘Stl: A seasonal-trend decomposition procedure based on loess.’ *Journal of Official Statistics* 6(1), 3–73
- Cobb, Marcus P. A. (2020) ‘Aggregate density forecasting from disaggregate components using Bayesian VARs.’ *Empirical Economics* 58(1), 287–312
- Connor, Gregory, Robert Korajczyk, and Oliver Linton (2006) ‘The common and specific components of dynamic volatility.’ *Journal of Econometrics* 132(1), 231–255
- Diebold, Francis X., and Glenn D. Rudebusch (1989) ‘Scoring the Leading Indicators.’ *The Journal of Business* 62(3), 369–391
- Diron, Marie (2006) ‘Short-term forecasts of euro area real GDP growth: An assessment of real-time performance based on vintage data.’ Working Paper Series 622, European Central Bank, May
- Esteves, Paulo Soares (2013) ‘Direct vs bottom-up approach when forecasting GDP: Reconciling literature results with institutional practice.’ *Economic Modelling* 33, 416–420
- Eurostat (2015) ‘ESS guidelines on seasonal adjustment, Eurostat Manuals and guidelines.’ <https://www.bundesbank.de/resource/blob/831064/25d02c60b2df31825c0661b215735fc5/mL/lkw-maut-fahrleistungsindex-data.pdf>
- Froni, Claudia, and Massimiliano Marcellino (2014) ‘A comparison of mixed frequency approaches for nowcasting Euro area macroeconomic aggregates.’ *International Journal of Forecasting* 30(3), 554–568
- Frale, Cecilia, Massimiliano Marcellino, Gian Luigi Mazzi, and Tommaso Proietti (2010) ‘Survey data as coincident or leading indicators.’ *Journal of Forecasting* 29(1-2), 109–131
- (2011) ‘EUROMIND: a monthly indicator of the euro area economic conditions.’ *Journal of the Royal Statistical Society Series A* 174(2), 439–470

- Geweke, J. (1976) *The Dynamic Factor Analysis of Economic Time Series Models* Workshop series / Social Systems Research Institute (University of Wisconsin)
- Giannone, Domenico, Lucrezia Reichlin, and David Small (2008) ‘Nowcasting: The real-time informational content of macroeconomic data.’ *Journal of Monetary Economics* 55(4), 665–676
- Giovannelli, Alessandro, Tommaso Proietti, Ambra Citton, Ottavio Ricchi, Cristian Tegami, and Cristina Tinti (2020) ‘Nowcasting GDP and its components in a data-rich environment: The merits of the indirect approach.’ CEIS Research Paper 489, Tor Vergata University, CEIS, May
- Glocker, Christian, and Philipp Wegmüller (2020) ‘Business cycle dating and forecasting with real-time Swiss GDP data.’ *Empirical Economics* 58(1), 73–105
- Glocker, Christian, and Serguei Kaniovski (2020) ‘Macroeconometric forecasting using a cluster of dynamic factor models.’ Working Paper *forthcoming*, WIFO
- Hakkio, Craig S., and William R. Keeton (2009) ‘Financial stress: What is it, how can it be measured, and why does it matter?’ *Economic Review* 94(Q II), 5–50
- Heider, Florian, Marie Hoerova, and Cornelia Holthausen (2010) ‘Liquidity hoarding and interbank market spreads: The role of counterparty risk.’ CEPR Discussion Papers 7762, Center for Economic Policy Research, March
- Higgins, Patrick C. (2014) ‘GDPNow: A model for GDP nowcasting.’ FRB Atlanta Working Paper 2014-7, Federal Reserve Bank of Atlanta, July
- Hirsh, Richard F., and Jonathan G. Koomey (2015) ‘Electricity Consumption and Economic Growth: A New Relationship with Significant Consequences?’ *The Electricity Journal* 28(9), 72–84
- Kramer, Helmut (1967) ‘Entwicklung der Beschäftigtenstruktur und der Arbeitsproduktivität in Österreich.’ *WIFO Monatsberichte* 40(5), 151–160
- Lewis, Daniel, Karel Mertens, and James H. Stock (2020) ‘U.S. Economic Activity During the Early Weeks of the SARS-Cov-2 Outbreak.’ Technical Report, NBER Working Papers 2695
- López-Prol, J., and O. Sungmin (2020) ‘Impact of COVID-19 measures on electricity consumption.’ MPRA Paper 101649, University Library of Munich, Germany
- Mahringer, Helmut (2009) ‘Der Arbeitsmarkt in der Finanzmarkt- und Wirtschaftskrise.’ *WIFO Monatsberichte* 82(12), 967–978
- Marcellino, Massimiliano, and Christian Schumacher (2010) ‘Factor MIDAS for nowcasting and forecasting with ragged-edge data: A model comparison for German GDP.’ *Oxford Bulletin of Economics and Statistics* 72(4), 518–550
- Marcellino, Massimiliano, Mario Porqueddu, and Fabrizio Venditti (2016) ‘Short-Term GDP Forecasting With a Mixed-Frequency Dynamic Factor Model With Stochastic Volatility.’ *Journal of Business & Economic Statistics* 34(1), 118–127
- Mariano, Roberto S., and Yasutomo Murasawa (2003) ‘A new coincident index of business cycles based on monthly and quarterly series.’ *Journal of Applied Econometrics* 18(4), 427–443
- McWilliams, Ben, and Georg Zachmann (2020) ‘Bruegel electricity tracker of COVID-19 lockdown effects.’ Bruegel Datasets, Bruegel, March
- OeNB (2020) ‘COVID-19-bedingte Rezession stellt größte wirtschaftspolitische Herausforderung in der zweiten Republik dar. Gesamtwirtschaftliche Prognose für Österreich 2020 bis 2022.’ *Konjunktur aktuell* Juni 2020, 15–18

- Ollech, Daniel (2018) ‘Seasonal adjustment of daily time series.’ Discussion Papers 41/2018, Deutsche Bundesbank
- Pareja, Ana Arencibia, Ana Gómez-Loscos, Mercedes de Luis López, and Gabriel Pérez-Quirós (2020) ‘A Short Term Forecasting Model for the Spanish GDP and its Demand Components.’ *Economía* 43(85), 1–30
- Rünstler, Gerhard, and Franck Sedillot (2003) ‘Short-term estimates of euro area real GDP by means of monthly data.’ ECB Working Paper 276, European Central Bank, September
- Sanders, Nada R., and Larry P. Ritzman (2001) ‘Judgmental Adjustment of Statistical Forecasts.’ In *Principles of Forecasting: A Handbook for Researchers and Practitioners*, ed. J. Scott Armstrong (Springer US) pp. 405–416
- Sargent, Thomas, and Christopher Sims (1977) ‘Business cycle modeling without pretending to have too much a priori economic theory.’ Working Paper 55, Federal Reserve Bank of Minneapolis
- Schneider, Martin, and Gerhard Fenz (2009) ‘Ein Exportfrühindikator für Österreich auf Basis der Lkw-Fahrleistung.’ *Geldpolitik und Wirtschaft* Q1/09, 47–56
- Schumacher, Christian, and Jörg Breitung (2008) ‘Real-time forecasting of German GDP based on a large factor model with monthly and quarterly data.’ *International Journal of Forecasting* 24(3), 386–398
- Stock, J.H., and M.W. Watson (2016) ‘Dynamic Factor Models, Factor-Augmented Vector Autoregressions, and Structural Vector Autoregressions in Macroeconomics.’ In *Handbook of Macroeconomics*, ed. John B. Taylor and Harald Uhlig, vol. 2 (Elsevier) chapter 8, pp. 415–525
- Veloce, William (1996) ‘An evaluation of the leading indicators for the Canadian economy using time series analysis.’ *International Journal of Forecasting* 12(3), 403–416