

Azarova, Valeriya et al.

Research Report

Wirtschafts-/Konjunkturanalyse mit Stromverbrauchsdaten

ifo Forschungsberichte, No. 129

Provided in Cooperation with:

Ifo Institute – Leibniz Institute for Economic Research at the University of Munich

Suggested Citation: Azarova, Valeriya et al. (2022) : Wirtschafts-/Konjunkturanalyse mit Stromverbrauchsdaten, ifo Forschungsberichte, No. 129, ISBN 978-3-95942-110-2, ifo Institut - Leibniz-Institut für Wirtschaftsforschung an der Universität München, München

This Version is available at:

<https://hdl.handle.net/10419/272940>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

Wirtschafts-/Konjunkturanalyse mit Stromverbrauchsdaten

*Valeriya Azarova, Robert Lehmann, Sascha Möhrle, Andreas Peichl,
Karen Pittel, Marie-Theres von Schickfus, Timo Wollmershäuser*



Wirtschafts-/Konjunkturanalyse mit Stromverbrauchsdaten

Endbericht zum Forschungsauftrag des Bayerischen Staatsministerium
für Wirtschaft, Landesentwicklung und Energie

Autoren

Dr. Valeriya Azarova

Dr. Robert Lehmann

Sascha Möhrle, MSc.

Prof. Dr. Andreas Peichl

Prof. Dr. Karen Pittel

Dr. Marie-Theres von Schickfus

Prof. Dr. Timo Wollmershäuser

Dr. Magnus Reif wirkte bis zu seinem Ausscheiden beim ifo Institut – Leibniz-Institut für Wirtschaftsforschung an der Universität München e. V. ebenfalls an der Bearbeitung des Endberichts mit.

März 2022

ifo INSTITUT

Leibniz-Institut für Wirtschaftsforschung
an der Universität München e.V.

ifo Zentrum für Makroökonomik und Befragungen | ifo Zentrum für Energie, Klima und Ressourcen

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

ISBN: 978-3-95942-110-2

Alle Rechte, insbesondere das der Übersetzung in fremde Sprachen, vorbehalten. Ohne ausdrückliche Genehmigung des Verlags ist es auch nicht gestattet, dieses Buch oder Teile daraus auf photomechanischem Wege (Photokopie, Mikrokopie) oder auf andere Art zu vervielfältigen.

© ifo Institut, München 2022

Druck: ifo Institut, München

ifo Institut im Internet:
<http://www.ifo.de>

Inhaltsverzeichnis

Abbildungsverzeichnis	III
Tabellenverzeichnis	V
Abkürzungsverzeichnis	VI
1 Einleitung	1
2 Datengrundlage	4
2.1 Stromverbrauchsdaten Bayern	4
2.2 Industrieproduktion Bayern	6
2.3 Auftragseingang Verarbeitendes Gewerbe Bayern.....	9
2.4 Konjunkturindikatoren des ifo Instituts.....	10
2.5 Weitere potentielle Konjunkturindikatoren.....	12
2.5.1 Stromverbrauchsdaten Deutschland	13
2.5.2 Lkw-Maut-Fahrleistungsindex.....	16
2.6 Datenaufbereitung für das Prognoseexperiment.....	17
2.7 Empirische Zusammenhänge für die Prognose.....	20
3 Energieverbrauch und Energieeffizienz	23
3.1 Energieeffizienz und Energieintensität	23
3.2 Lastmanagement: Möglichkeiten und Netzentgeltstruktur	29
3.3 Zusammenhang zwischen Stromverbrauch und Börsenstrompreisen.....	35
3.4 Zusammenhang zwischen Stromverbrauch und Luftverschmutzung	40
4 Stromverbrauch und Konjunktur	41
4.1 Grundzüge des Datierungsalgorithmus	41
4.2 Referenzzyklus der bayerischen Industrieproduktion	44
4.3 Zyklusdatierung Stromverbrauch Bayern.....	45
4.4 Konkordanz zwischen den Konjunkturzyklen	47
5 Prognosetauglichkeit	50
5.1 Unkonventionelle Konjunkturindikatoren in der akademischen Prognoseliteratur	50
5.2 Aufbau des Prognoseexperiments auf Monatsbasis.....	54

5.3	Ergebnisse des Prognoseexperiments auf Monatsbasis	57
5.3.1	Durchschnittliche Ergebnisse für den Zeitraum 2008 bis 2020.....	57
5.3.2	Durchschnittliche Ergebnisse für den Zeitraum 2015 bis 2020.....	59
5.3.3	Monatliche Prognosefehler im Zeitverlauf	62
5.4	Prognoseexperimente auf Wochenbasis	65
5.4.1	Notwendige Anpassungen bei der Datenaufbereitung.....	66
5.4.2	Unterschiedliche Informationsstände innerhalb eines Monats	68
5.4.3	Grundzüge des Mixed-data sampling (MIDAS) Ansatzes.....	69
5.4.4	Durchschnittliche Prognosefehler auf wöchentlicher Datenbasis.....	71
5.4.5	Wochenergebnisse im Zeitverlauf.....	73
5.4.6	Vergleich der Prognosegüte mit anderen hochfrequenten Indikatoren.....	75
5.5	Schlussfolgerungen für die angewandte Prognose.....	77
6	Fazit und Schlussfolgerungen	80
	Literaturverzeichnis.....	82
	Datenquellen.....	87
	Anhang.....	88
	Bry-Boschan-Algorithmus.....	88
	Maß der Phasenüberlappung	88
	Prognosemodelle	89
	MIDAS-Modelle	89
	Almon-Lag-Polynom dritter Ordnung	90
	Beurteilung der Prognosegüte	91

Abbildungsverzeichnis

Abbildung 1:	Stromverbrauch RLM-Kunden nach Verteilnetzbetreiber	5
Abbildung 2:	Industrieproduktion Bayern	8
Abbildung 3:	Auftragseingang Verarbeitendes Gewerbe Bayern	10
Abbildung 4:	Zentrale Indikatoren der ifo Konjunkturumfrage im Verarbeitenden Gewerbe Bayern	11
Abbildung 5:	Produktionsindikatoren der ifo Konjunkturumfrage im Verarbeitenden Gewerbe Bayern	12
Abbildung 6:	Tagesstromverbrauch für das Jahr 2015 im Vergleich ENTSO-E und SMARD	13
Abbildung 7:	Stromverbrauch in Deutschland	14
Abbildung 8:	Nettostromverbrauch in Deutschland nach Abnehmern im Jahr 2019.....	15
Abbildung 9:	Lkw-Maut-Fahrleistungsindex Deutschland, Ursprungswerte und Bereinigung.....	16
Abbildung 10:	Industrieproduktion Bayern, Ursprungswerte und Bereinigung.....	18
Abbildung 11:	Stromverbrauch RLM-Kunden und Industrieproduktion, zwei VNB.....	19
Abbildung 12:	Stromverbrauch RLM-Kunden und Industrieproduktion, alle VNB	20
Abbildung 13:	Entwicklung der Energieeffizienz nach Abnehmer, Durchschnitt 2008 bis 2017	24
Abbildung 14:	Entwicklung von Industriestrompreis, Stromverbrauch und Energieintensität Bayern	26
Abbildung 15:	Regressions-Diskontinuität nach Netzbetreibern	28
Abbildung 16:	Regressions-Diskontinuität für Deutschland.....	29
Abbildung 17:	Stündliche Lastprofile der VNB im Vergleich zu Deutschland, Durchschnitt 2015 bis 2019	31
Abbildung 18:	Maximale Leistung und gesamte Arbeit nach Spannungsebene, 2015 bis 2019.....	32
Abbildung 19:	Gleichzeitigkeitsfunktion für die Netzentgeltkalkulation	34
Abbildung 20:	Geschätzte Koeffizienten der täglichen Future-Preise.....	36
Abbildung 21:	Geschätzte Koeffizienten der wöchentlichen Future-Preise.....	37
Abbildung 22:	Geschätzte Koeffizienten der monatlichen Future-Preise	38
Abbildung 23:	Schematische Darstellung eines klassischen Konjunkturzyklus	42
Abbildung 24:	Zyklusdatierung Industrieproduktion Bayern	44
Abbildung 25:	Zyklusdatierung Stromverbrauch Bayern, zwei VNB	46
Abbildung 26:	Phasenüberlappung zwischen Industrieproduktion und Stromverbrauch	47
Abbildung 27:	Schematische Darstellung des Prognoseexperiments auf Monatsbasis.....	54
Abbildung 28:	Schematische Darstellung zur Indikatorverfügbarkeit für das Prognoseexperiment.....	56
Abbildung 29:	Nowcast-Prognosefehler des bayerischen Stromverbrauchs, zwei VNB	62
Abbildung 30:	Nowcast-Prognosegüte nach einzelnen Jahren auf Basis zweier VNB	63

Abbildungsverzeichnis

Abbildung 31: Forecast-Prognosefehler des Stromverbrauchs, zwei VNB	64
Abbildung 32: Forecast-Prognosegüte nach einzelnen Jahren auf Basis zweier VNB	65
Abbildung 33: Tagesstromverbrauch für das Jahr 2019	67
Abbildung 34: Stromverbrauch auf Wochenbasis seit 2015	68
Abbildung 35: Schematische Darstellung der unterschiedlichen Datenstände innerhalb eines Monats	69
Abbildung 36: Abweichungen der Nowcast-Prognosefehler innerhalb eines Monats	74
Abbildung 37: Abweichungen der Forecast-Prognosefehler innerhalb eines Monats	75
Abbildung 38: Exemplarischer Prognoseverlauf für Dezember 2018	78
Abbildung 39: Exemplarischer Prognoseverlauf für Juli 2019	79

Tabellenverzeichnis

Tabelle 1:	Kreuzkorrelationen der Indikatoren zur bayerischen Industrieproduktion, 2008 bis 2020	22
Tabelle 2:	Auswirkungen des Preises auf die Nachfrage, stündliche Datenbasis	39
Tabelle 3:	Auswirkungen der Stromnachfrage auf die Luftverschmutzung.....	40
Tabelle 4:	Phasenüberlappung der einzelnen Indikatoren mit dem Konjunkturzyklus der Produktion	48
Tabelle 5:	Zusammenfassung der aktuellen Prognoseliteratur mit Fokus auf unkonventionelle Konjunkturindikatoren.....	52
Tabelle 6:	Relative Prognosegüte der Indikatoren, Evaluationszeitraum 2008 bis 2020.....	58
Tabelle 7:	Relative Prognosegüte der Indikatoren, Evaluationszeitraum 2015 bis 2020.....	61
Tabelle 8:	Wöchentliche relative Prognosegüte des Stromverbrauchs, Zeitraum 2012 bis 2020.....	71
Tabelle 9:	Wöchentliche relative Prognosegüte des Stromverbrauchs, Zeitraum 2015 bis 2020.....	73
Tabelle 10:	Wöchentliche relative Prognosegüte hochfrequenter Indikatoren, Zeitraum 2012 bis 2020.....	76

Abkürzungsverzeichnis

AIC	Akaike Information Criterion
BIC	Bayesian Information Criterion
BIP	Bruttoinlandsprodukt
BNetzA	Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen
BWS	Bruttowertschöpfung
CPP	Critical-Peak-Pricing
Ct	Cent
DLC	Direkte Laststeuerung
DSM	Demand Side Management
EEG	Erneuerbare-Energien-Gesetz
EEV	Endenergieverbrauch
ENTSO-E	European Network of Transmission System Operators for Electricity
EU	Europäische Union
ggü.	gegenüber
GmbH	Gesellschaft mit beschränkter Haftung
GWh	Gigawattstunde
HLF	Hochlastzeitfenster
Hrsg.	Herausgeber
i.H.v.	in Höhe von
KfW	Kreditanstalt für Wiederaufbau
KG	Kommanditgesellschaft

KMU	kleine und mittlere Unternehmen
kWh	Kilowattstunde
Lkw	Lastkraftwagen
LOESS	Locally weighted scatterplot smoothing
MIDAS	Mixed-data sampling
MWh	Megawattstunde
NAPE	Nationaler Aktionsplan Energieeffizienz
o. Ä.	Oder Ähnliche(s)
p. a.	per annum
rd.	rund
RLM	Registrierende Leistungsmessung
RTP	Real-Time-Pricing
SLP	Standardlastprofil
STL	Seasonal and trend decomposition using loess
ToU	Time-of-Use
TWh	Terawattstunde
ÜNB	Übertragungsnetzbetreiber
vgl.	vergleiche
VGR	Volkswirtschaftliche Gesamtrechnungen
WMQPF	Wurzel des mittleren quadratischen Prognosefehlers
VNB	Verteilnetzbetreiber
WZ	Wirtschaftszweig

1 Einleitung

Der wirtschaftliche Einbruch in Folge der ersten Corona-Welle im Frühjahr 2020 untermauerte die Notwendigkeit zur Betrachtung alternativer und unkonventioneller Datenquellen, die eine zeitnahe Entwicklung der Wirtschaftslage ermöglichen. Konventionelle und turnusmäßig von der amtlichen Statistik veröffentlichte Indikatoren, welche die konjunkturelle Lage in Deutschland anzeigen, unterliegen in der Regel erheblichen Publikationsverzögerungen oder können nur in unzureichender Frequenz (bspw. Quartale) ausgewertet werden. Wenngleich die Datenverfügbarkeit für Deutschland insgesamt noch relativ gut ausfällt, ist die Verfügbarkeit auf der Ebene der Bundesländer deutlich eingeschränkter. Zentrale Konjunkturindikatoren wie die monatliche Industrieproduktion werden flächendeckend nicht für alle Bundesländer veröffentlicht oder die Messung erfolgt gar nur im jährlichen Turnus (wie bspw. beim Bruttoinlandsprodukt als zentraler Indikator für die gesamtwirtschaftliche Lage). Dieser Umstand ist insofern unzureichend, als politische Entscheidungsträger auf ein sich schnell veränderndes wirtschaftliches Umfeld nicht adäquat reagieren können. Im vorliegenden, vom Bayerischen Staatsministerium für Wirtschaft, Landesentwicklung und Energie geförderten Forschungsauftrag, widmet sich das ifo Institut der Frage, ob eine neue Datenquelle, nämlich hochfrequente Angaben zum regionalen Stromverbrauch auf Basis der vier zentralen bayerischen Verteilnetzbetreiber, für die zeitnahe wirtschaftliche und konjunkturelle Analyse im Freistaat Bayern herangezogen werden kann. Auf den folgenden Seiten präsentiert der Abschlussbericht die zentralen Ergebnisse.

Der Frage nach der Eignung des bayerischen Stromverbrauchs für die wirtschaftliche und konjunkturelle Analyse wird sich auf drei Wegen genähert. Erstens wird der Einfluss verschiedener Parameter und Politikmaßnahmen auf den Stromverbrauch untersucht. Die Senkung des Energieverbrauchs ist ein wichtiger Bestandteil der deutschen Energiewende; der Stromverbrauch ist hier allerdings nur ein Bestandteil. Darüber hinaus führt die Energiewende zu einem steigenden Anteil schwankender Erneuerbarer Energien an der Stromerzeugung, so dass die Bedeutung eines sinnvollen Lastmanagements immer weiter zunimmt. Aus diesem Grund werden die netzspezifischen Lastgänge mit dem gesamtdeutschen Lastprofil verglichen, und es wird der Frage nachgegangen, inwieweit aktuelle Strompreise und Netzentgelte sinnvolle Anreize setzen, um den Stromverbrauch im Zeitverlauf zu glätten. Zweitens wird mit der neuen Datenquelle die Frage beantwortet, ob der Stromverbrauch zur Datierung der konjunkturellen Ausschläge in Bayern dient und diese zuverlässig anzeigt. Und drittens wird untersucht, ob der aggregierte Stromverbrauch zur Prognose der bayerischen Industrieproduktion taugt und bereits bestehende Indikatoren sinnvoll ergänzen kann. Hierbei bewegt sich das ifo Institut auf neues akademisches Terrain, da Untersuchungen zur Prognosetauglichkeit neuer unkonventioneller Indikatoren auf regionaler Ebene bis dato nicht existieren.

Die bayerischen Stromverbrauchsdaten erweisen sich insgesamt als sehr nützliche Datenquelle für die in diesem Forschungsauftrag gestellten Fragen. Zur Steigerung der Energieeffizienz lassen sich jedoch aus den aggregierten Daten auf Netzbetreiberebene keine eindeutigen Schlussfolgerungen ableiten. Es zeigten sich bei allen Netzbetreibern Brüche in der Zeitreihe, die möglicherweise auf die Bekanntgabe von energiepolitischen Maßnahmen (wie der Energieeffizienzrichtlinie) zurückzuführen sind. Es wurde ein konsistenter positiver Zusammenhang zwischen der Stromnachfrage und verschiedenen Spezifikationen des Strompreises festgestellt. Eine Kausalität ist jedoch nicht nachweisbar, da die Gesamtnachfrage den Preis beeinflusst und gleichzeitig der Preis die Nachfrage individueller Abnehmer. Die Nachfragesteuerung und insbesondere die Glättung von Nachfragespitzen könnten vielversprechende Maßnahmen sein, wenn sie auf Industriekunden angewandt werden: beim Vergleich der Nachfragespitzen der bayerischen Netzbetreiber mit den in Gesamtdeutschland beobachteten Nachfragespitzen fallen insbesondere die Nachfragespitzen am Morgen als abweichend auf. Diese könnten von Interesse sein, um Systemspitzen zu vermeiden und das Gleichgewicht des Netzes zu verbessern. Schließlich wurde ein positiver Einfluss des Industriestromverbrauchs auf die wichtigsten Luftschadstoffe festgestellt, wobei die Auswirkungen auf Stickstoffdioxid (NO_2) am größten sind. Weitere Analysen unter Verwendung disaggregierter Daten könnten nicht nur die Anreize zur Nachfragesteuerung und die Energieeffizienz mit größerer Genauigkeit bewerten, sondern auch deren Auswirkungen auf die Luftqualität.

Darüber hinaus zeigen die bayerischen Stromverbrauchsdaten die konjunkturelle Entwicklung, gemessen in Form von Aufschwung- und Abschwungphasen sowie die dazugehörigen Hoch- und Tiefpunkte, zuverlässig an. Als Referenz dient der datierte Zyklus der bayerischen Industrieproduktion. Das Maß der Phasenüberlappung zwischen Stromverbrauchsdaten und bayerischer Industrieproduktion nimmt für den Zeitraum zwischen 2007 und 2020 einen sehr hohen Wert von 0,79 an, wobei ein Wert von Eins als Ausdruck für eine perfekte Übereinstimmung der Konjunkturzyklen steht. Im Vergleich zu allen anderen zur Verfügung stehenden Indikatoren ist die Phasenüberlappung bei den Stromverbrauchsdaten am höchsten. Besonders die schweren und tiefen Rezessionen sowie die sich anschließenden Erholungsphasen können mit den Stromverbrauchsdaten zuverlässig datiert werden.

Die hohe Zuverlässigkeit der Stromverbrauchsdaten bei der Zyklendatierung übersetzt sich auch in ein hohes Maß an Prognosetauglichkeit. In einem Prognoseexperiment auf Monatsbasis für die Jahre 2008 bis 2020 offenbart sich, dass die bayerischen Stromverbrauchsdaten im Durchschnitt der beste Indikator für die Prognose der bayerischen Industrieproduktion im laufenden Monat („Nowcast“) sind. Für die Prognose des folgenden Monats („Forecast“) verlieren alle Indikatoren an Prognosekraft und die Stromverbrauchsdaten reihen sich mit ihrer prognostischen Treffsicherheit hinter Kenngrößen mit besseren Vorlaufeigenschaften wie bspw. den ifo Geschäftserwartungen für das Verarbeitende Gewerbe Bayern ein. Die hohe Prognosekraft der bayerischen Stromverbrauchsdaten für den Nowcast offenbart sich auch für die einzelnen Jahre und lässt sich

nicht auf spezielle Einzelevents zurückführen. Untermauert werden die Ergebnisse auf Monatsbasis durch ein Prognoseexperiment auf Wochenbasis, welches durch die hochfrequente Natur der Stromverbrauchsdaten möglich wird. Zwar erhöht sich die Prognosekraft des Stromverbrauchs insgesamt je mehr Informationen innerhalb eines Monats zur Verfügung stehen. Jedoch liefern bereits die Angaben am Ende der ersten Woche zuverlässige prognostische Signale für die bayerische Industrieproduktion. Insgesamt sind damit die bayerischen Stromverbrauchsdaten eine wertvolle Ergänzung zu den bereits zur Verfügung stehenden bayerischen Konjunkturindikatoren wie jene des ifo Instituts und könnten ein fester Bestandteil einer zukünftigen automatischen Konjunkturberichterstattung werden.

Der Abschlussbericht ist wie folgt aufgebaut. In Kapitel 2 wird die Datengrundlage näher vorgestellt und die Datenaufbereitung für das Prognoseexperiment diskutiert. Kapitel 3 umfasst den inhaltlich ersten Block zur Frage des Energieverbrauchs und der Energieeffizienz. Im vierten Kapitel wird die Zyklusdatierung der Stromverbrauchsdaten und der Vergleich mit dem Referenzzyklus präsentiert. Kapitel 5 geht der Frage der Prognosegültigkeit nach. Das letzte Kapitel formuliert ein Fazit und zieht Schlussfolgerungen aus den hier präsentierten Ergebnissen.

2 Datengrundlage

Zunächst werden die Daten näher beschrieben, welche den Ausgangspunkt für die nachfolgenden Analysen bilden. Darunter fallen die Stromverbrauchsdaten der mit diesem Forschungsauftrag assoziierten Verteilnetzbetreiber (VNB), Konjunkturindikatoren der amtlichen Statistik für den Freistaat Bayern, die Befragungsindikatoren des ifo Instituts und weitere, potentielle Konjunkturindikatoren, welche jedoch auf gesamtdeutscher Ebene gemessen werden. Abschließend werden die Schritte zur Datenaufbereitung und erste empirische Zusammenhänge diskutiert.

2.1 Stromverbrauchsdaten Bayern

Konventionell erhobene Daten der amtlichen Statistik in Deutschland werden in aller Regel in Monatsfrequenz ausgewertet und der Öffentlichkeit präsentiert. Darunter zählen bspw. der monatlich zur Verfügung stehende Produktionsindex im Verarbeitenden Gewerbe oder die preisbereinigten Umsätze im Einzelhandel. Gesamtwirtschaftliche Maße wie das Bruttoinlandsprodukt (BIP) hingegen stehen derzeit nur in Quartalsfrequenz zur Verfügung. Die Corona-Krise hat jedoch verdeutlicht, dass höherfrequente Daten (bspw. auf Wochen- oder Tagesbasis) notwendig sind um ein aktuelles und zeitnahes Bild der wirtschaftlichen Verfassung eines Landes oder Landesteils zu zeichnen.¹ Besonderes Augenmerk liegt dabei auf der Bewertung aktuell verabschiedeter Maßnahmen seitens der Politik (z.B. der Shutdown im Frühjahr 2020) hinsichtlich ihrer Wirkungen auf die wirtschaftliche Aktivität. Hochfrequente Daten haben überdies den Vorteil, dass sie keiner Publikationsverzögerung unterliegen und am Ende eines Betrachtungszeitraums unmittelbar (z.B. am Ende eines Monats) zur Verfügung stehen.

Während für Deutschland insgesamt grundsätzlich eine Vielzahl von Konjunkturindikatoren zur Verfügung stehen, ist die Datenverfügbarkeit auf kleinräumigerer Ebene (z.B. Bundesländer) deutlich schwieriger und eingeschränkter. So wird bspw. die Industrieproduktion nicht regelmäßig von allen Bundesländern veröffentlicht und gesamtwirtschaftliche Aggregate wie das BIP stehen derzeit nur in jährlicher Frequenz zur Verfügung. Somit sind Einschätzungen zur aktuellen konjunkturellen Lage eines Bundeslandes nur sehr eingeschränkt möglich, so dass alternativen Datenquellen eine hohe Bedeutung beigemessen wird. Eine solche Datenquelle stellen hochfrequente Stromverbrauchsdaten dar, die überdies auch ohne nennenswerte Verzögerungen seitens der Anbieter veröffentlicht werden können und kaum Revisionen unterliegen.

Für die vorliegende Untersuchung kann auf Stromverbrauchsdaten der folgenden vier VNB im Freistaat Bayern zurückgegriffen werden: die Bayernwerk Netz GmbH (Bayernwerk), die LEW Verteilnetz GmbH (LVN), die N-ERGIE Netz GmbH (N-ERGIE) und die SWM Infrastruktur GmbH & Co.

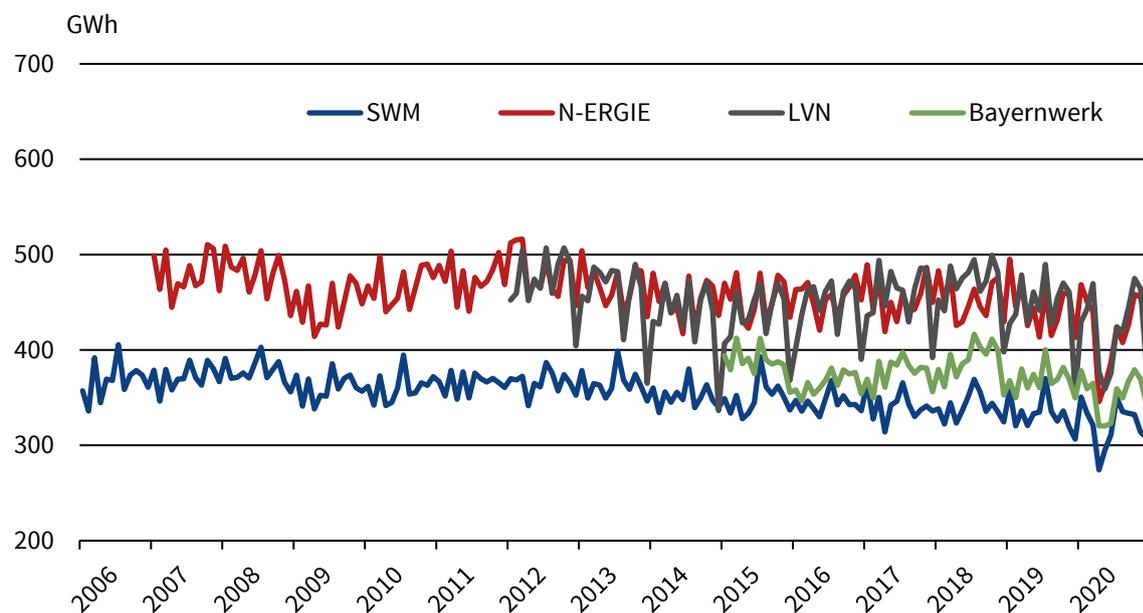
¹ An dieser Stelle sei angemerkt, dass die amtliche Statistik in Deutschland derzeit „alternative“ Indikatoren in Ergänzung etablierter Konjunkturindikatoren veröffentlicht. Zu nennen seien dabei u.a. Mobilitätsindikatoren auf Basis von Mobilfunkdaten oder Scannerdaten in der Preisstatistik. Jedoch betont das Statistische Bundesamt explizit den „experimentellen“ Charakter dieser Erhebungen: https://www.destatis.de/DE/Service/EXDAT/_inhalt.html.

KG (SWM). Bei allen VNB wird nach Kunden unterschieden, deren Stromverbrauch entweder mittels Standardlastprofilen (SLP) abgerechnet wird oder die einer Registrierenden Leistungsmessung (RLM) unterliegen; zudem besteht die Möglichkeit nachgelagerte Betreiber auszuweisen. Zur Messung konjunktureller Ausschläge des Wirtschaftsgeschehens in Bayern sind RLM-Kunden besonders geeignet, da deren Stromverbrauch im 15-Minuten-Takt elektronisch an die VNB übermittelt wird. Der Nachteil besteht jedoch darin, dass die Gruppe der RLM-Kunden nur Verbraucher mit einer jährlichen Abnahmemenge von 100.000 kWh oder mehr umfasst. Damit fußt die Analyse ausschließlich auf Großkunden, wobei kleine Unternehmen und private Haushalte nicht in Betracht gezogen werden können. Auch nachgelagerte Netzbetreiber bleiben bei der Überprüfung der prognostischen Eigenschaften unberücksichtigt.

Um zunächst einen groben Eindruck über die Entwicklung des Stromverbrauchs der RLM-Kunden zu gewinnen, wurden die im 15-Minuten-Takt vorliegenden Daten der vier VNB im ersten Schritt auf Monatebene aggregiert. Abbildung 1 stellt den originären Stromverbrauch getrennt nach VNB für die Jahre 2006 bis 2020 dar.

Abbildung 1: Stromverbrauch RLM-Kunden nach Verteilnetzbetreiber

Monatlicher Stromverbrauch, Ursprungswerte



Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH (LVN), N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG; Darstellung des ifo Instituts.

© ifo Institut

Den längsten Betrachtungszeitraum erlauben die Stromverbrauchsdaten der SWM (ab 2006), die kürzeste Zeitreihe stellt jene der Bayernwerk (ab 2015) dar. Insgesamt lassen sich drei wichtige Charakteristika bei allen VNB ablesen. Erstens unterliegen alle Reihen einem sich wiederholendem Saison- und Kalendermuster innerhalb eines Jahres (z.B. saisonale Ausschläge in den Sommer- und Wintermonaten). Daher sollten diese Einflüsse ausgeschaltet werden, um sie von der

konjunkturellen Grunddynamik zu trennen. Zweitens zeigen alle Verbrauchsreihen einen fallenden Trend, was auf eine energieeffizientere Produktion hinweisen könnte. Das dritte Charakteristikum sind die konjunkturellen Schwankungen in den Stromverbräuchen. Erkennbar sind bspw. die Rückgänge der Stromverbräuche im Zuge der Wirtschafts- und Finanzkrise 2008/2009, der wirtschaftliche Boom im Jahr 2018 und der tiefe Einschnitt des Shutdowns im Frühjahr 2020. Neben den üblichen saisonalen Veränderungen beim Stromverbrauch ist der Rückgang im Frühjahr 2020 jedoch überdurchschnittlich stark ausgeprägt, was unmittelbar auf die Einschränkungen der wirtschaftlichen Aktivität aufgrund der Corona-Pandemie zurückzuführen ist. Besonders das letzte Charakteristikum ist für die Analyse der prognostischen Eigenschaften des Stromverbrauchs entscheidend.

2.2 Industrieproduktion Bayern

Die Wahl eines geeigneten Konjunkturindikators, welcher mittels der Stromdaten prognostiziert werden soll, ist aufgrund eingeschränkter Datenverfügbarkeit auf der Ebene der Bundesländer ein eher schwieriges Unterfangen. Ein umfassender und gesamtwirtschaftlicher Indikator wie das BIP ist nur in Jahresfrequenz öffentlich zugänglich. Damit ist die Auswahl unterjährig verfügbarer Indikatoren sehr begrenzt, wobei die Wahl im Folgenden auf den Produktionsindex fällt, welcher den monatlichen Ausstoß im Verarbeitende Gewerbe sowie des Bergbaus und der Gewinnung von Steinen und Erden umfasst (vgl. Bayerisches Landesamt für Statistik 2021a).

Die Wahl des Produktionsindex hat im Wesentlichen zwei Vorteile, aber auch einen Nachteil. Der erste Vorteil ist die zentrale Bedeutung des Produktionsindex für die vierteljährliche Fortschreibung des deutschen BIP. Das Statistische Bundesamt verwendet den Produktionsindex als zentralen monatlichen Konjunkturindikator (vgl. Statistisches Bundesamt 2017). Der zweite Vorteil liegt in der inhaltlichen Vergleichbarkeit des Produktionsindex mit den Stromverbrauchsdaten der VNB. Der Großteil der RLM-Kunden dürften Industrieunternehmen sein, da diese in der Regel die Messgrenze von 100.000 kWh Stromverbrauch im Jahr überschreiten. Kleine und mittlere Betriebe oder Unternehmungen wie bspw. Gaststätten oder kleine Einzelhändler sind als RLM-Kunden ausgenommen und werden in aller Regel mittels SLP nachgewiesen. Somit dürfte es zwischen Stromverbrauch und Produktionsindex eine große Überlappung bei den betrachteten Firmen bzw. Unternehmen geben. Der Nachteil liegt in der ausschließlichen Betrachtung der Industrie. Nach Angaben des Arbeitskreises Volkswirtschaftliche Gesamtrechnungen (VGR) der Länder (2020) lag der Anteil des Verarbeitenden Gewerbes an der nominalen Bruttowertschöpfung (BWS) Bayerns im Jahr 2019 bei 25%, was etwas mehr als dem deutschen Durchschnitt entspricht (rd. 22%) und auch im europäischen Vergleich überdurchschnittlich ausfällt (EU-27: rd. 16%). Damit ist Bayern das Bundesland mit der zweithöchsten Industriequote hinter Baden-Württemberg (rd. 32%) und knapp vor dem Saarland (mehr als 24%). Jedoch ist die gesamtwirtschaftliche Bedeutung der Industrie, aufgrund ihrer Stellung in der heimischen Wertschöpfungskette, deutlich größer als es die Anteile an der BWS suggerieren. Zum einen bezieht die Industrie Vorleistungsgüter aus anderen Wirtschaftsbereichen (z.B. die Unternehmensdienstleister) für die

Produktion der eigenen Güter. Zum anderen finden Industriegüter ihre Anwendung in nachgelagerten Produktionsprozessen (z.B. Investitionsgüter aus dem Maschinenbau) oder als Güter in der letzten Verwendung (z.B. Kraftfahrzeugkauf eines privaten Haushalts). Eine konjunkturelle Schwäche im Verarbeitenden Gewerbe Deutschlands schlägt sich daher auch in diversen anderen Wirtschaftsbereichen spürbar nieder.

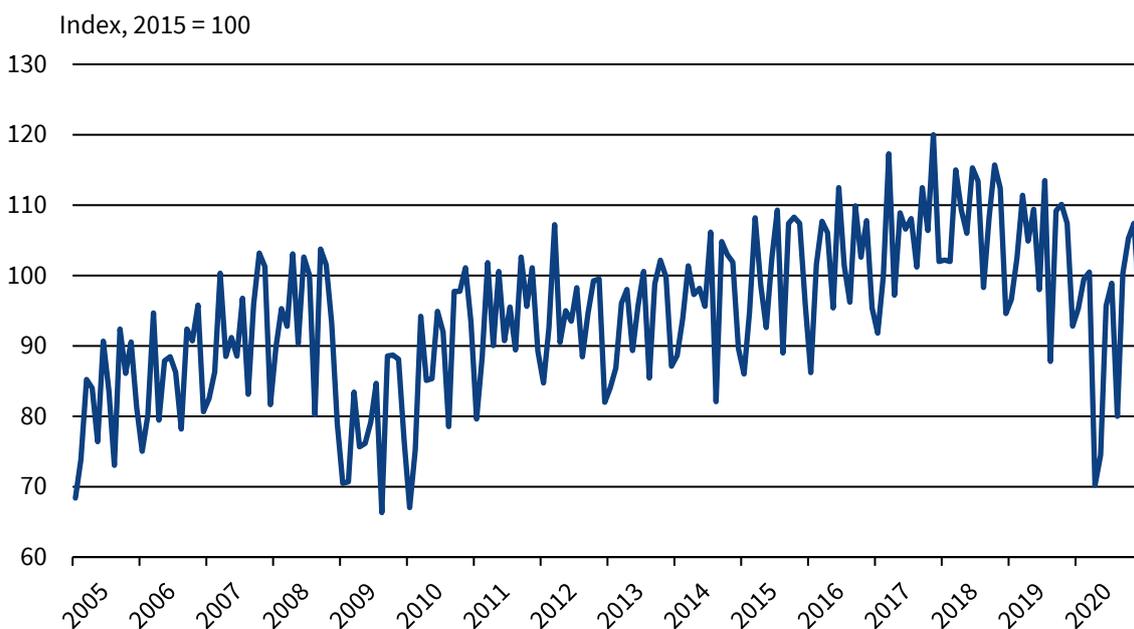
Die gewonnenen Erkenntnisse aus der vorliegenden Untersuchung müssen jedoch mit gewisser Vorsicht betrachtet werden. In aller Regel gilt die Industrie als der „Zyklusmacher“ einer Wirtschaft und ist damit verantwortlich für die konjunkturellen Schwankungen in der gesamten Wirtschaftsaktivität. In früheren Rezessionen wie jener der Jahre 2008/2009 wurde der gesamtwirtschaftliche Einbruch zu einem großen Teil durch eine industrielle Schwäche initiiert, wodurch der Produktionsindex als geeignetes Maß für die Schwankungen des BIP hergenommen werden kann. Die Rezession im Zuge der Corona-Pandemie hingegen zeichnet sich durch ein anderes Muster aus. So gerieten auch konsumnahe Dienstleister, bei denen soziale Kontakte ein wichtiger Bestandteil des Geschäftsmodells sind, in die Krise, da der Staat zur Eindämmung der Virusausbreitung einen Shutdown verordnete und da Unternehmen und Verbraucher ihr Verhalten an das Leben mit dem Virus anpassten. Aber auch Wirtschaftsbereiche, welche sonst kaum von wirtschaftlichen Schwankungen beeinflusst sind, wie bspw. die Öffentlichen Dienstleister sowie der Bereich Erziehung und Unterricht, verzeichneten kräftige Einbußen bei der Wertschöpfung.

Insgesamt ist der Produktionsindex jedoch eine geeignete Wahl für das vorliegende Vorhaben, da andere monatliche Konjunkturindikatoren (z.B. Umsätze im Bauhauptgewerbe oder im Einzelhandel) einen noch geringeren Anteil des Wirtschaftsgeschehens repräsentieren, nicht in höherer Frequenz verfügbar sind (z.B. vierteljährliches BIP) oder in den Stromverbrauchsdaten nicht abgebildet werden (z.B. kleine Unternehmen). Zudem zeigt der Produktionsindex im Verarbeitenden Gewerbe den stärksten Zusammenhang mit dem BIP. So liegt die Korrelation zwischen der Veränderung des deutschen Produktionsindex gegenüber dem Vorquartal und der Wachstumsrate des deutschen BIP im Zeitraum von 1994 bis 2019 bei 0,78 und damit höher als die Korrelationskoeffizienten anderer Konjunkturindikatoren mit der gesamtwirtschaftlichen Aktivität (Produktion im Bauhauptgewerbe: 0,38; Umsätze im Einzelhandel: 0,49). Auch für den Freistaat Bayern zeigt sich – gemessen auf jährlicher Basis – ein enger Zusammenhang zwischen Produktionsindex und BIP. Die Korrelation beträgt 0,89 für die Jahre 2008 bis 2020. Wie alle Konjunkturindikatoren der amtlichen Statistik unterliegt aber auch der Produktionsindex für Bayern einer gewissen Publikationsverzögerung, die sich durchschnittlich auf eineinhalb Monate beläuft. So standen bspw. Anfang März 2021 ausschließlich die Angaben zum Produktionsindex in Bayern bis Dezember 2020 zur Verfügung. Dahingehend liefern die Stromverbrauchsdaten einen deutlichen Mehrwert, da sie – neben der hochfrequenten Messung – auch zeitnah und ohne wesentliche Publikationsverzögerungen ausgewertet werden können.

Für die vorliegende Analyse findet der Produktionsindex in Form eines Volumenindex Anwendung, wobei die Produktionsangaben mittels der Erzeugerpreise preisbereinigt werden. Das Basisjahr ist derzeit auf 2015 festgelegt. Da es im Verlauf der letzten Jahrzehnte zu Veränderungen bei der Klassifikation der Wirtschaftszweige kam, liegt derzeit eine lange Zeitreihe der Produktion nach aktuell gültiger Wirtschaftszweigklassifikation WZ 2008 erst ab Januar 2008 vor. Angaben vor diesem Datum werden vom Bayerischen Landesamt für Statistik in den jeweils zu diesem Zeitpunkt gültigen Klassifikationen ausgewiesen. Um die Vergleichbarkeit herzustellen, haben wir die unterschiedlichen Angaben der amtlichen Statistik rückverkettet. Da sich die Angaben der aktuell gültigen WZ 2008 von der vorher geltenden Klassifikation WZ 2003 nur wenig unterscheiden, kann der Produktionsindex für den hier analysierten Zeitraum ab 2005 uneingeschränkt verglichen werden. Die monatlichen Ursprungswerte für die bayerische Industrieproduktion sind in Abbildung 2 dargestellt.

Abbildung 2: Industrieproduktion Bayern

Monatlicher Produktionsindex, preisbereinigte Ursprungswerte



Quellen: Bayerisches Landesamt für Statistik; Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

Ähnlich zu den Stromverbrauchsdaten zeigt sich auch bei der Industrieproduktion ein ausgeprägtes Saison- und Kalendermuster, welches im Vorfeld der Prognose ausgeschaltet werden muss. Darüber hinaus sind die beiden schweren Rezessionen der letzten 15 Jahre deutlich sichtbar. Die Wirtschafts- und Finanzkrise führte zu einem kräftigen Einbruch der bayerischen Industrieproduktion zum Jahreswechsel 2008/2009 und erholte sich anschließend eher schleppend. Der Aufschwung setzte dann in etwa mit dem Jahr 2010 ein, gefolgt von einem trendmäßigen Anstieg der Industrieproduktion bis ins Jahr 2018. Im Anschluss daran geriet die bayerische In-

dustrie in den Abschwung und mit der ersten Corona-Welle im Frühjahr 2020 in eine schwere Rezession. Jedoch erholte sich das Verarbeitende Gewerbe nach Aufhebung der Maßnahmen recht schnell, da internationale Wertschöpfungsketten zügig wiederhergestellt werden konnten und die industriellen Sektoren der wichtigsten deutschen Handelspartner ebenfalls relativ schnell ihre wirtschaftliche Aktivität hochgefahren haben. Von der zweiten Corona-Welle im Winter 2020/2021 blieb die bayerische Industrie recht unbeeindruckt, da die hiesigen Industrieunternehmen – im Vergleich zum Frühjahr 2020 – ihre Produktion aufgrund unternehmerischer Entscheidungen im Zuge der Pandemie nicht drosselten.

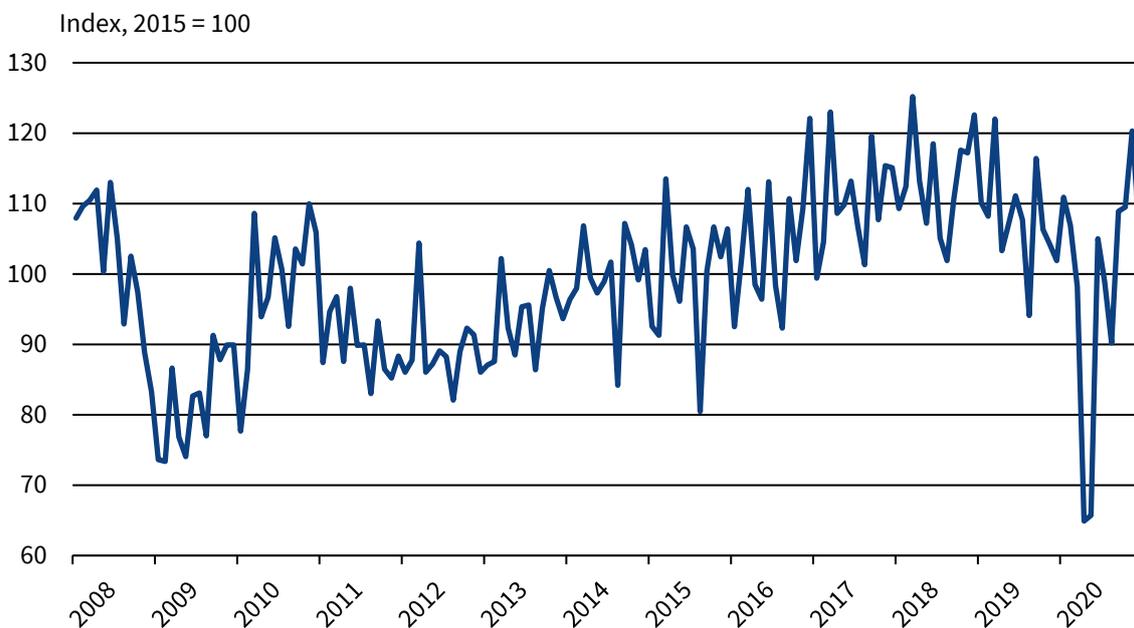
2.3 Auftragseingang Verarbeitendes Gewerbe Bayern

Als zentraler Konjunkturindikator der amtlichen Statistik, welcher frühzeitig die Entwicklung im Verarbeitenden Gewerbe anzeigt, gilt der Auftragseingangsindex. Dieser Indikator umfasst die neu eingegangenen inländischen und ausländischen Aufträge der in Bayern tätigen Industriebetriebe; Stornierungen werden nicht berücksichtigt (vgl. Bayerisches Landesamt für Statistik 2021b). Solange Stornierungen quantitativ unbedeutend sind, sollten Neuaufträge mit einer gewissen Verzögerung auch in ähnlichem Maße in Produktionsausstoß münden. Daher wird dem Auftragseingangsindex als Vorlauf- bzw. Frühindikator zur konjunkturellen Einschätzung im Verarbeitenden Gewerbe eine entscheidende Rolle beigemessen. Jedoch unterliegt auch der Auftragseingang der gleichen Restriktion wie der Produktionsindex: hier beträgt die Publikationsverzögerung ebenfalls in etwa eineinhalb Monate, sodass konjunkturelle Abschätzungen am aktuellen Rand nur eingeschränkt durchführbar sind.

Der Auftragseingangsindex liegt derzeit ab dem Monatsbericht Januar 2008 frei zugänglich vor. Jedoch kann eine lange Zeitreihe nicht abgerufen werden und musste aus diversen Publikationen selber erstellt werden. Da einzelne Jahre mit unterschiedlichen Basisjahren ausgewiesen werden, wurden ältere Publikationen auf das aktuelle gültige Basisjahr 2015 umbasiert. Analog zur Industrieproduktion wurde der Volumenindex der Neuaufträge, welcher von Preiseinflüssen abstrahiert, betrachtet. Abbildung 3 zeigt den Verlauf des preisbereinigten Auftragseingangsindex für das Verarbeitende Gewerbe in Bayern seit 2008. Das Verlaufsmuster bei den Neuaufträgen ist dabei grundsätzlich sehr ähnlich zu jenem der Industrieproduktion aus Abbildung 2. Jedoch fallen ausgeprägtere Spitzen und Ausschläge beim Auftragseingangsindex auf. Diese Ausschläge könnten mit der Vergabe von Großaufträgen zusammenhängen, die sich auch im Auftragseingangsindex für das Verarbeitende Gewerbe in Deutschland zeigen und das konjunkturelle Grundbild verzerren könnten. Für Deutschland insgesamt liegen die Auftragseingänge daher getrennt nach Angaben inkl. und exkl. Großaufträge vor; für das Verarbeitende Gewerbe in Bayern stehen solche Angaben unseres Wissens nach nicht zur Verfügung. Insgesamt zeigen die Neuaufträge sehr deutlich die beiden Rezessionen der Jahre 2008/2009 und jene im Frühjahr 2020 sowie den sich daran anschließenden Aufschwung in den 2010er Jahren und den Boom im Jahr 2018 an.

Abbildung 3: Auftragseingang Verarbeitendes Gewerbe Bayern

Monatlicher Auftragseingangsindex, preisbereinigte Ursprungswerte



Quellen: Bayerisches Landesamt für Statistik; Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

2.4 Konjunkturindikatoren des ifo Instituts

Neben quantitativen Angaben der amtlichen Statistik stehen nichtamtliche Befragungsindikatoren des ifo Instituts für die Einschätzung der aktuellen konjunkturellen Lage zur Verfügung.¹ Für ausgewählte Bundesländer veröffentlicht das ifo Institut Regionalauswertungen seiner Konjunkturumfrage (vgl. Lehmann et al. 2019). Für den Freistaat Bayern findet die Auswertung exklusiv für das Bayerische Staatsministerium für Wirtschaft, Landesentwicklung und Energie statt (vgl. Bauer et al. 2021). Die Indikatoren des ifo Instituts sind rein qualitativer Natur, haben aber den Vorteil der schnelleren Verfügbarkeit. Beispielsweise liegen die ifo Indikatoren für Februar 2021 bereits am Ende desselben Monats vor, während der Produktionsindex für Februar 2021 erst im April 2021 veröffentlicht wurde.

Grundsätzlich können alle für die deutsche Industrie verfügbaren ifo Befragungsindikatoren auch für Bayern über einen längeren Zeitraum ausgewertet werden. Eine Liste der Indikatoren für das Verarbeitende Gewerbe liefert Sauer (2020). Im Folgenden wird sich auf fünf Indikatoren der ifo Konjunkturumfrage im bayerischen Verarbeitenden Gewerbe konzentriert. Neben den drei zentralen Indikatoren ifo Geschäftslage, ifo Geschäftserwartungen und ifo Geschäftsklima ergänzen wir die Analyse um zwei Fragen zur Produktion der hiesigen Industriefirmen: die ifo

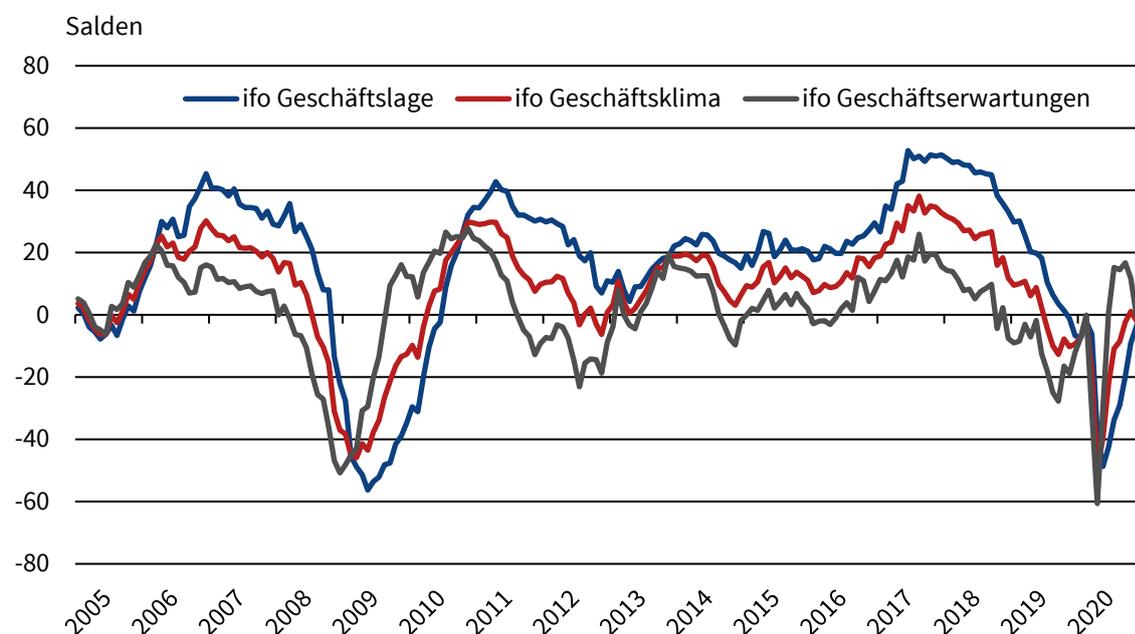
¹ Eine ausführliche Darstellung der ifo Konjunkturumfrage (Fragekatalog, Methodik etc.) findet sich in Sauer und Wohrabe (2020).

Produktionstätigkeit aus dem Vormonat und die ifo Produktionspläne für die kommenden drei Monate. Während die ersten drei Indikatoren eher auf die allgemeine Geschäftstätigkeit abzielen, bilden die letzten beiden Indikatoren ggf. besser die Entwicklung des Produktionsindex ab, da die beiden Fragen spezifisch auf die Produktion der Unternehmen ausgerichtet sind.

Abbildung 4 zeigt zunächst die saison- und kalenderbereinigte Entwicklung der ifo Geschäftslage, die ifo Geschäftserwartungen und das ifo Geschäftsklima für den Zeitraum 2005 bis 2020. Deutlich zu erkennen sind die beiden schweren Rezessionen der Jahre 2008/2009 und zu Jahresbeginn 2020. Analog zum Produktionsindex zeigt sich der im Jahr 2010 einsetzende Aufschwung im Verarbeitenden Gewerbe auch in den ifo Befragungsindikatoren, welcher im Verlaufe des Jahres 2018 zu Ende ging. Dem nachfolgend einsetzenden Abschwung folgte die schwere Rezession im Frühjahr 2020 aufgrund zahlreicher Produktionsstilllegungen in der bayerischen Industrie. Mit dem Abebben der ersten Corona-Welle erholten sich sowohl die Lageeinschätzung der bayerischen Industriefirmen als auch deren Erwartungen an die Geschäftsentwicklung der kommenden sechs Monate. Auch zu Beginn der zweiten Corona-Welle im Winter 2020/2021 verbesserte sich die aktuelle Geschäftslage der antwortenden Unternehmen. Jedoch deuteten die Geschäftserwartungen für das erste Halbjahr 2021 auf eine sich verlangsamende Gangart im Verarbeitenden Gewerbe Bayerns hin.

Abbildung 4: Zentrale Indikatoren der ifo Konjunkturumfrage im Verarbeitenden Gewerbe Bayern

Befragungsergebnisse im Verarbeitenden Gewerbe Bayern, saison- und kalenderbereinigt



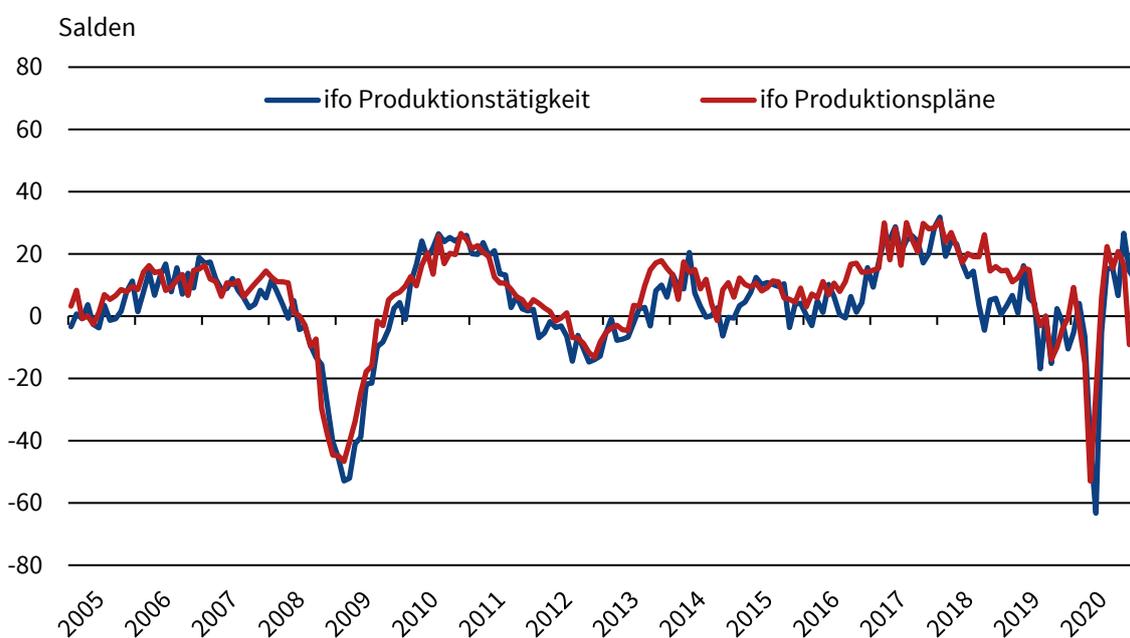
Quellen: ifo Konjunkturumfrage Bayern; Darstellung des ifo Instituts.

© ifo Institut

Abbildung 5 ergänzt das Bild der drei zentralen ifo Indikatoren um die Einschätzungen der bayerischen Industriefirmen um ihre vergangene und zukünftige Produktionstätigkeit. Insgesamt sind die Verläufe der ifo Produktionstätigkeit und der ifo Produktionspläne etwas unruhiger als jene der drei zentralen Indikatoren. Jedoch verlaufen beide Produktionsindikatoren recht synchron, wobei die Produktionspläne schon einen gewissen Vorlauf vor der Produktionstätigkeit aufweisen. Beide Indikatoren zeigen die konjunkturellen Bewegungen im bayerischen Verarbeitenden Gewerbe eindeutig an, so z.B. die Rezession der Jahre 2008/2009, den Boom im Jahr 2018 und der Corona-bedingte Einbruch im Frühjahr 2020.

Abbildung 5: Produktionsindikatoren der ifo Konjunkturumfrage im Verarbeitenden Gewerbe Bayern

Befragungsergebnisse im Verarbeitenden Gewerbe Bayern, saison- und kalenderbereinigt



Quellen: ifo Konjunkturumfrage Bayern; Darstellung des ifo Instituts.

© ifo Institut

2.5 Weitere potentielle Konjunkturindikatoren

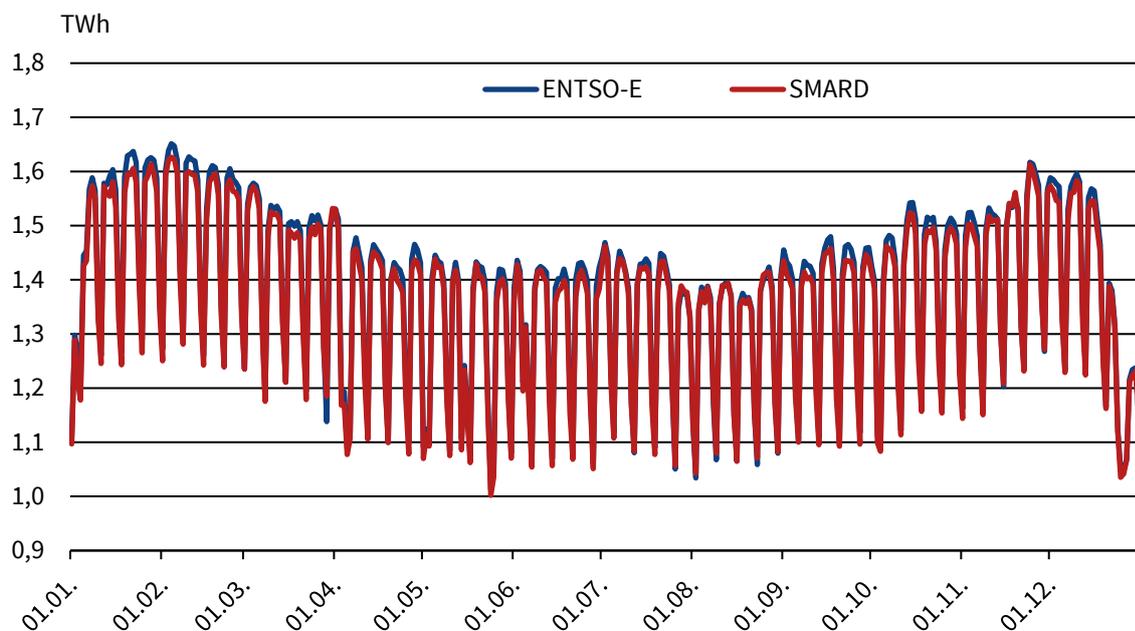
Auch gesamtdeutsche Konjunkturindikatoren können grundsätzlich zur Prognose der bayerischen Industrieproduktion herangezogen werden, sofern es eine enge Verknüpfung der bayerischen mit der gesamtdeutschen Wirtschaft gibt. Daher werden zwei gesamtdeutsche Größen herangezogen, welche ebenfalls auf Tagesebene erhoben werden: der von der Bundesnetzagentur ausgewiesene gesamte Stromverbrauch Deutschlands und der vom Statistischen Bundesamt neu veröffentlichte Lkw-Maut-Fahrleistungsindex. Beide Indikatoren werden im Folgenden näher beschrieben.

2.5.1 Stromverbrauchsdaten Deutschland

Der gesamte Stromverbrauch in Deutschland wird von der Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen (BNetzA) nachgewiesen. Über das Portal SMARD – Strommarktdaten für Deutschland – können Stromverbrauchsdaten im 15-Minuten-Takt ab 2015 kostenfrei heruntergeladen werden (vgl. Bundesnetzagentur 2021). Diese Daten bezieht die BNetzA unmittelbar vom European Network of Transmission System Operators for Electricity (ENTSO-E), dem europäischen Dachverband der Übertragungsnetzbetreiber. Die europäische Transparenzverordnung (Verordnung (EU) Nr. 543/2013 der Kommission) regelt dabei die Übermittlung und Veröffentlichung von Stromverbrauchsdaten ab dem Jahr 2015. Da diese Zeitreihe in der Regel eher zu kurz für die vorliegenden Analysen ist, kombinieren wir die historischen Daten der ENTSO-E für die Jahre 2006 bis 2015 (vgl. ENTSO-E 2021) mit dem von der BNetzA ausgewiesenen Stromverbrauch. Grundsätzlich ist dieses Vorgehen zulässig. Jedoch muss bei der Verwendung der langen Zeitreihe zum Stromverbrauch ein Aspekt bei der Interpretation berücksichtigt werden. Nach Rücksprache mit dem SMARD-Team der BNetzA kommt es im Zeitverlauf zu methodischen Änderungen seitens der Betreiber bei der Erfassung des Stromverbrauchs. Diese Änderungen werden aber lediglich auf die Daten bis in das Jahr 2015 zurück angewandt und nicht auf ältere Zeiträume. In beiden Datenquellen liegt ein Überlappungsjahr (2015) vor, mit welchem die Daten beider Anbieter miteinander verglichen werden können. Hierfür wurden im Vorfeld die 15-Minuten-Daten zu Tageswerten aggregiert, welche in Abbildung 6 dargestellt sind.

Abbildung 6: Tagesstromverbrauch für das Jahr 2015 im Vergleich ENTSO-E und SMARD

Täglicher Stromverbrauch, Ursprungswerte



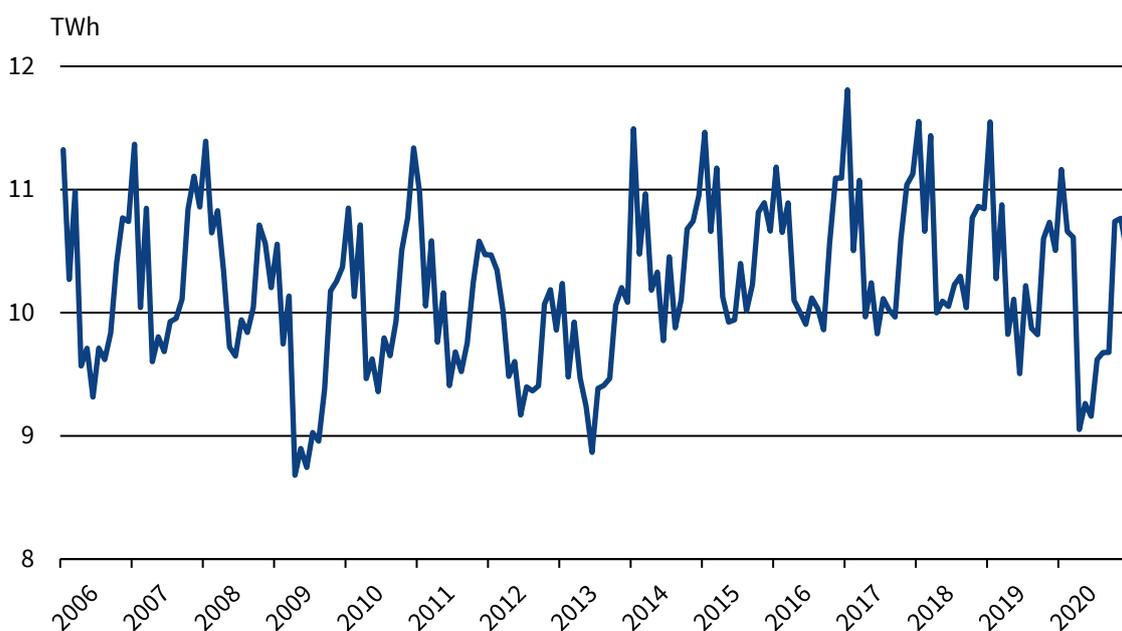
Quellen: ENTSO-E, Bundesnetzagentur SMARD; Darstellung des ifo Instituts.

© ifo Institut

Die beiden Reihen unterscheiden sich vor allem in den Tagesspitzen voneinander, was dazu führt, dass der Jahresstromverbrauch nach ENTSO-E um 5 TWh bzw. 1% über dem von SMARD ausgewiesenen Stromverbrauch liegt. Da beiden Reihen aber einen deckungsgleichen Verlauf aufweisen, sehen wir diese Abweichung als vertretbar an, so dass beide Quellen zugunsten einer langen Zeitreihe zum Stromverbrauch in Deutschland im Folgenden miteinander kombiniert werden. Abbildung 7 zeigt die kombinierte Stromverbrauchsreihe für Deutschland ab dem Jahr 2006. Analog zu den bayerischen Stromverbrauchsdaten sowie der Produktion und dem Auftragseingang weist der Stromverbrauch in Deutschland ausgeprägte Saison- und Kalendereinflüsse auf, welche für das Prognoseexperiment in den Daten ausgeschaltet werden müssen. Jedoch wird auch ohne Bereinigung die konjunkturelle Entwicklung im Stromverbrauch bereits sichtbar. So geht der Stromverbrauch in Deutschland im Zuge der Wirtschafts- und Finanzkrise 2008/2009 sowie in der ersten Corona-Welle spürbar zurück.

Abbildung 7: Stromverbrauch in Deutschland

Monatlicher Stromverbrauch, Ursprungswerte



Quellen: ENTSO-E, Bundesnetzagentur SMARD; Darstellung des ifo Instituts.

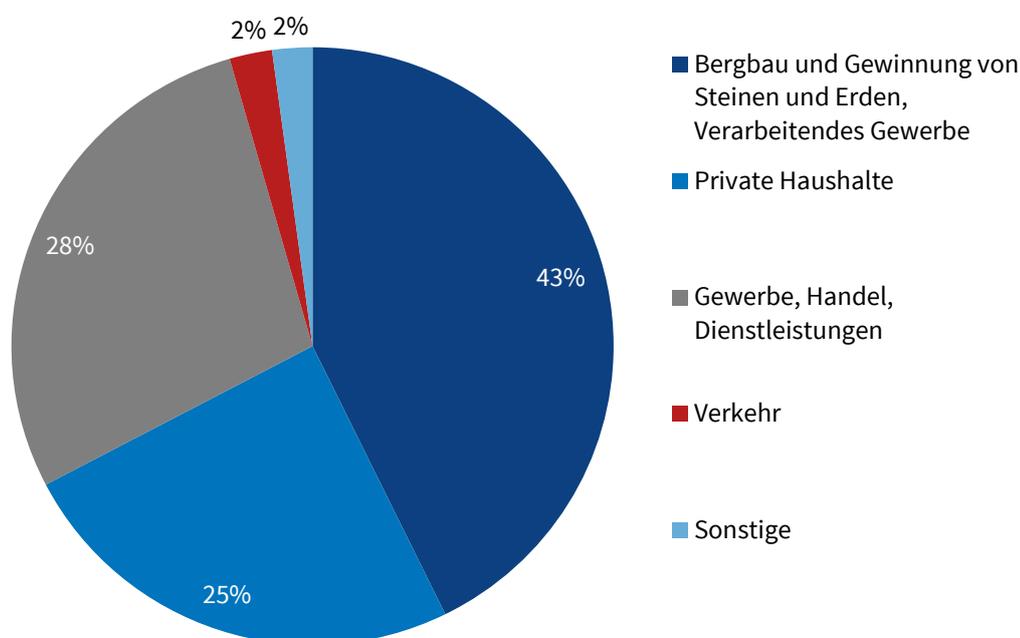
© ifo Institut

Insgesamt sind die deutschen Stromverbrauchsdaten weniger schwankungsanfällig als die bayerischen Angaben. So beträgt die Standardabweichung der monatlichen Zuwachsraten beim deutschen Stromverbrauch 2,4 Prozentpunkte und 2,7 Prozentpunkte bei den bayerischen Stromverbrauchsdaten. Neben der kleinräumigeren Nachweisebene bestehen zudem auch konzeptionelle Unterschiede zwischen den ENTSO-E/SMARD-Daten und den Angaben der bayerischen VNB. Während Letztere – wie zuvor erwähnt – nur die RLM-Kunden mit einer Abnahmemenge von mindestens 100.000 kWh abdeckt, umfassen die Stromverbrauchsdaten für Deutschland alle Abnehmer des Nettostromverbrauchs wie bspw. die privaten Haushalte

(vgl. Abbildung 8).¹ So fragte den größten Anteil am Nettostromverbrauch des Jahres 2019 mit 43% die Industrie (hier: Bergbau, Gewinnung von Steinen und Erden, Verarbeitendes Gewerbe) nach (vgl. AG Energiebilanzen e.V. 2021). Daran anschließend bezog mit 28% der Bereich Gewerbe, Handel, Dienstleistungen die zweitgrößte Menge an Strom. Die privaten Haushalte in Deutschland steuern ein Viertel des gesamten Nettostromverbrauchs bei. Somit ergeben sich zwischen den bayerischen Stromverbrauchsdaten und den gesamtdeutschen Angaben schon deutliche Unterschiede, welche u.U. die Prognosegüte für den bayerischen Produktionsindex beeinflussen könnten. Sofern sich diese Aussage im nachfolgenden Prognoseexperiment bewahrheitet, sollten die Stromverbrauchsdaten der bayerischen VNB einen deutlichen Mehrwert für die Prognose des Produktionsausstoßes der bayerischen Industrie liefern.

Abbildung 8: Nettostromverbrauch in Deutschland nach Abnehmern im Jahr 2019

Anteile am gesamten Nettostromverbrauch



Quellen: AG Energiebilanzen e.V.; Darstellung des ifo Instituts.

© ifo Institut

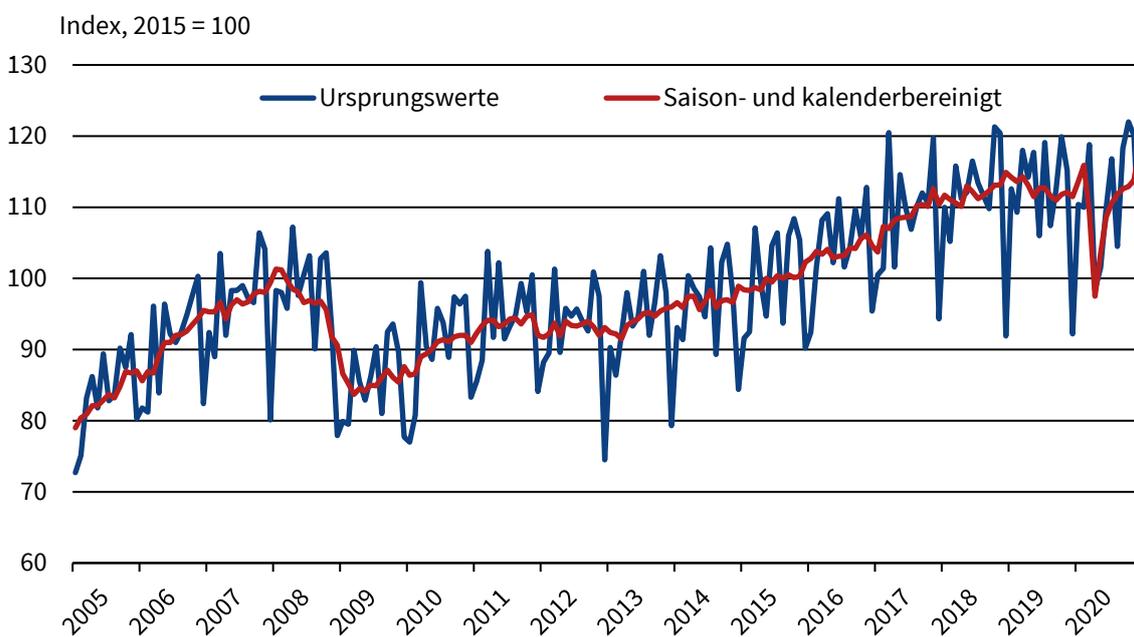
¹ Nach unserem Wissen können die SMARD-Daten keine Aussage zu den Abnehmern des Stromverbrauchs leisten. Daher haben wir die SMARD-Angaben zum Stromverbrauch mit jenen der AG Energiebilanz e.V. verglichen und festgestellt, dass beide Quellen in etwa zu gleichen Angaben in Mrd. kWh kommen. Nach Rücksprache mit der AG Energiebilanzen e.V. ist dieser Vergleich mit einer gewissen Unschärfe auf Jahresebene durchaus zulässig. Folglich nehmen wir an, dass die Angaben der AG Energiebilanz e.V. mit jenen vom SMARD annähernd deckungsgleich sind und die Zusammensetzung nach Abnehmern analog für die Daten der BNetzA gelten.

2.5.2 Lkw-Maut-Fahrleistungsindex

Neben hochfrequenten Stromverbrauchsdaten werden in Deutschland zudem Prozessdaten zur Fahrleistung mautpflichtiger Lastkraftwagen (Lkw) vom Bundesamt für Güterverkehr ausgewertet und als Index der breiten Öffentlichkeit zur Verfügung gestellt (vgl. Cox et al. 2020). Das Statistische Bundesamt hat diesen Lkw-Maut-Fahrleistungsindex seit 2018 als Produkt in sein Veröffentlichungsprogramm aufgenommen. Dabei stehen zwei Frequenzen zur Verfügung: monatlich und täglich. Die monatlichen Angaben liegen ab dem Jahr 2005 vor und umfassen einen Großteil der Fahrleistungen mautpflichtiger Lkw auf deutschen Bundesautobahnen (für eine detaillierte Beschreibung des Index siehe Cox et al. 2018). Sowohl die täglichen als auch die monatlichen Angaben zur mautpflichtigen Fahrleistung stehen in Ursprungswerten zur Verfügung oder werden bereits saison- und kalenderbereinigt vom Statistischen Bundesamt ausgewiesen (vgl. Abbildung 9). Auch beim Lkw-Maut-Fahrleistungsindex zeigen sich die zwei tiefen Rezessionen im Zuge der Wirtschafts- und Finanzkrise 2008/2009 und der ersten Corona-Welle im Frühjahr 2020. Darüber hinaus wird der gesamtwirtschaftliche Aufschwung der Jahre nach der Wirtschafts- und Finanzkrise deutlich.

Abbildung 9: Lkw-Maut-Fahrleistungsindex Deutschland, Ursprungswerte und Bereinigung

Monatlicher Lkw-Maut-Fahrleistungsindex



Quellen: Statistisches Bundesamt; Darstellung des ifo Instituts.

© ifo Institut

Die schnelle Verfügbarkeit des Lkw-Fahrleistungsindex macht diesen Konjunkturindikator interessant für die Prognose der bayerischen Industrieproduktion, zumal der Fahrleistungsindex eine hohe Korrelation mit der Industrieproduktion und dem BIP für Deutschland aufweist (vgl. Cox et al. 2020). Jedoch hat der Lkw-Maut-Fahrleistungsindex zwei (mögliche) entscheidende Nachteile für unseren Anwendungsfall. Erstens bildet der Index die Fahrleistungen des gesamten Bundesgebiets ab und kann – nach unserem Wissen – nicht für einzelne Bundesländer bestimmt werden. So kann es vorkommen, dass das Fahraufkommen kräftig steigt aufgrund höherer Nachfrage nach Fahrdienstleistungen in anderen Bundesländern und der bayerische Produktionsindex davon unberührt bleibt. Zweitens umfasst der Lkw-Maut-Fahrleistungsindex alle Fahrdienstleistungen, unabhängig davon für welche Wirtschaftsbereiche die Dienstleistung erbracht wird. Damit kann keine trennscharfe Unterscheidung nach Wirtschaftsbereichen (bspw. Verarbeitendes Gewerbe vs. Großhandel) vorgenommen werden, was möglicherweise die prognostischen Eigenschaften für die bayerische Industrieproduktion weiter einschränkt. Da die Wirtschaft des Freistaates Bayern jedoch durch einen hohen Industrialisierungsgrad gekennzeichnet ist, kann zumindest vermutet werden, dass der Lkw-Maut-Fahrleistungsindex einen passablen prognostischen Gehalt aufweist.

2.6 Datenaufbereitung für das Prognoseexperiment

Prognosen werden in aller Regel für so genannte Verlaufsdaten formuliert. Bei einer Verlaufsrate handelt es sich um die prozentuale Veränderung der Zielgröße gegenüber der unmittelbar vorangegangenen Periode (z.B. gegenüber dem Vormonat oder dem Vorquartal). Sofern die betrachteten Zielgrößen saisonale Muster oder Kalendereinflüsse aufweisen, ist die Berechnung von Verlaufsdaten wenig zielführend zur Offenlegung der konjunkturellen Grunddynamik. Daher müssen im Vorfeld die Stromverbrauchsdaten (Bayern und Deutschland) sowie der bayerische Produktions- und Auftragseingangsindex saison- und kalenderbereinigt werden; die ifo Indikatoren sowie der Lkw-Maut-Fahrleistungsindex werden bereits bereinigt veröffentlicht.

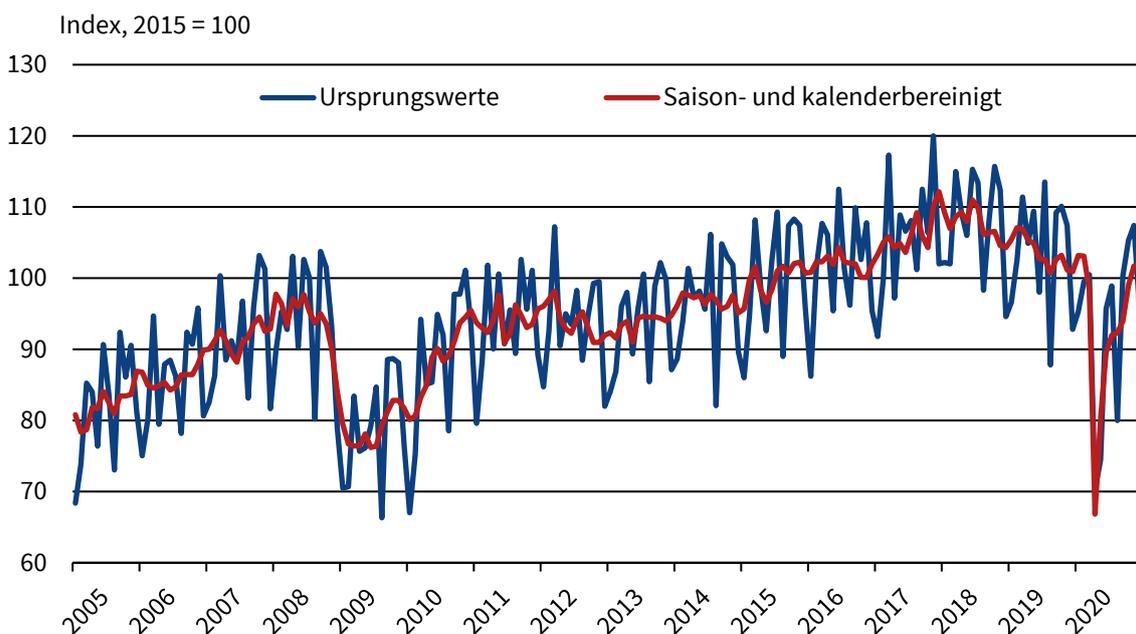
Die Saison- und Kalenderbereinigung ist keineswegs eine triviale Angelegenheit und wird intensiv auf obersten Statistikebenen (Statistisches Bundesamt in Deutschland und Eurostat in Europa) diskutiert. Da die Saisonfigur und der kalendarische Einfluss unbeobachtbare Größen sind, liegt es immer im Ermessen des Anwenders wie „gut“ oder „schlecht“ die vorgenommene Bereinigung ist. Zwar verfügen die standardmäßig zur Verfügung stehenden Saisonbereinigungsverfahren über implementierte Teststatistiken, welche Aufschluss darüber geben sollen, ob die bereinigten Daten noch saisonale Einflüsse im statistischen Sinne aufweisen oder nicht. Jedoch basieren diese Tests auf einer gewissen Fehlertoleranz, so dass zumindest an dieser Stelle ein gewisser Spielraum besteht und keine Aussage getroffen werden kann ob die eine Bereinigung der Anderen überlegen ist. Aufgrund mangelnder saison- und kalenderbereinigter Daten für Bayern orientieren wir uns im Folgenden an den Ausführungen des Statistischen Bundesamts zur Bereinigung der monatlichen Konjunkturindikatoren (vgl. Linz et al. 2018). Die Bereinigung er-

folgt mit der Methode X13 JDemetra+, wobei wir Spezifika des bayerischen Kalenders explizit berücksichtigen. Anstatt die Arbeitstage für Deutschland insgesamt zu verwenden, kommt eine eigens konstruierte Reihe der bayerischen Arbeitstage zum Einsatz. Bei der Bereinigung der Stromverbrauchsdaten müssen wir hingegen auf eigene Erfahrungen und Plausibilitätsüberlegungen zurückgreifen, da nach unserem Wissen keine offiziell saison- und kalenderbereinigten Stromverbrauchsdaten für Deutschland veröffentlicht werden. Schlussendlich haben wir uns für zwei Ansätze entschieden, die zu ähnlichen Ergebnissen führten. Erstens haben wir das Bereinigungsverfahren anhand diverser Kriterien automatisch entscheiden lassen, welche Spezifikation es – gegeben der Daten – für am besten geeignet hält. Zweitens haben wir die gleichen Einstellungen wie für den bayerischen Produktionsindex gewählt, da beide Zeitreihen aufgrund ihrer inhaltlichen Kohärenz ähnliche Eigenschaften aufweisen sollten. Im Folgenden findet die Prozedur auf Basis der vom Statistischen Bundesamt empfohlenen Parametereinstellungen ihre Anwendung.

Abbildung 10 stellt die Ursprungswerte der bayerischen Industrieproduktion den von uns saison- und kalenderbereinigten Werten gegenüber. Nach der Bereinigung der Zeitreihe ist deren Verlauf deutlich ruhiger und die wiederkehrenden Ausschläge aufgrund der Saison und des Kalenders werden durch das Verfahren eliminiert. Übrig bleiben die Konjunktur- und Trendkomponente sowie irreguläre Ausschläge, welche die wirtschaftliche Tätigkeit beeinflussen (bspw. Streiks). In den saison- und kalenderbereinigten Daten werden die zwei tiefen Rezessionen der letzten 15 Jahre, der lang andauernde Aufschwung der 2010er Jahre und der kräftige Boom im Jahr 2018 nochmals deutlicher abgebildet als in den Ursprungswerten.

Abbildung 10: Industrieproduktion Bayern, Ursprungswerte und Bereinigung

Monatlicher Produktionsindex, preisbereinigt



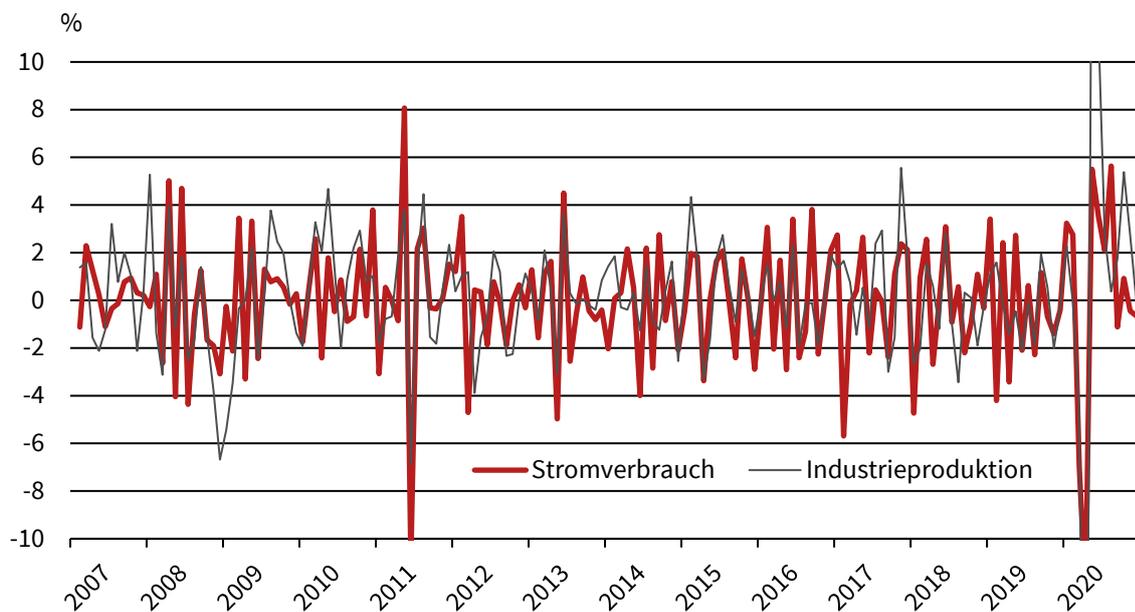
Quellen: Bayerisches Landesamt für Statistik; Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

Nach der Durchführung der Saison- und Kalenderbereinigung können nunmehr die Verlaufsraten bzw. Wachstumsraten zum Vormonat sowohl für die Industrieproduktion als auch den Stromverbrauch berechnet werden. Abbildung 11 zeigt die Vormonatsveränderungen der saison- und kalenderbereinigten Industrieproduktion sowie des Stromverbrauchs im Zeitraum 2007 bis 2020, wobei die kräftigen Ausschläge im Zuge der ersten Corona-Welle zur Lesbarkeit der Abbildung abgeschnitten wurden. Für diesen Zeitraum entspricht der Stromverbrauch den Angaben der zwei VNB N-ERGIE Netz GmbH und SWM Infrastruktur GmbH & Co. KG. Insgesamt zeigt sich, dass der Stromverbrauch etwas weniger schwankungsanfällig ist als die Industrieproduktion. Die Standardabweichung der monatlichen Zuwachsraten beträgt für die Industrieproduktion 3,8 Prozentpunkte und ist damit etwas mehr als einen Prozentpunkt größer wie jene für den Stromverbrauch (2,7 Prozentpunkte). Trotz der geringeren Schwankungsanfälligkeit des Stromverbrauchs zeigen beide Zeitreihen einen engen Gleichlauf, der im nachfolgenden Abschnitt näher beschrieben werden soll. Basierend auf diesen optischen Eindrücken kann ein hoher prognostischer Gehalt der Stromverbrauchsdaten für die Industrieproduktion Bayern vermutet werden.

Abbildung 11: Stromverbrauch RLM-Kunden und Industrieproduktion, zwei VNB

Veränderung gegenüber dem Vormonat, saison- und kalenderbereinigt



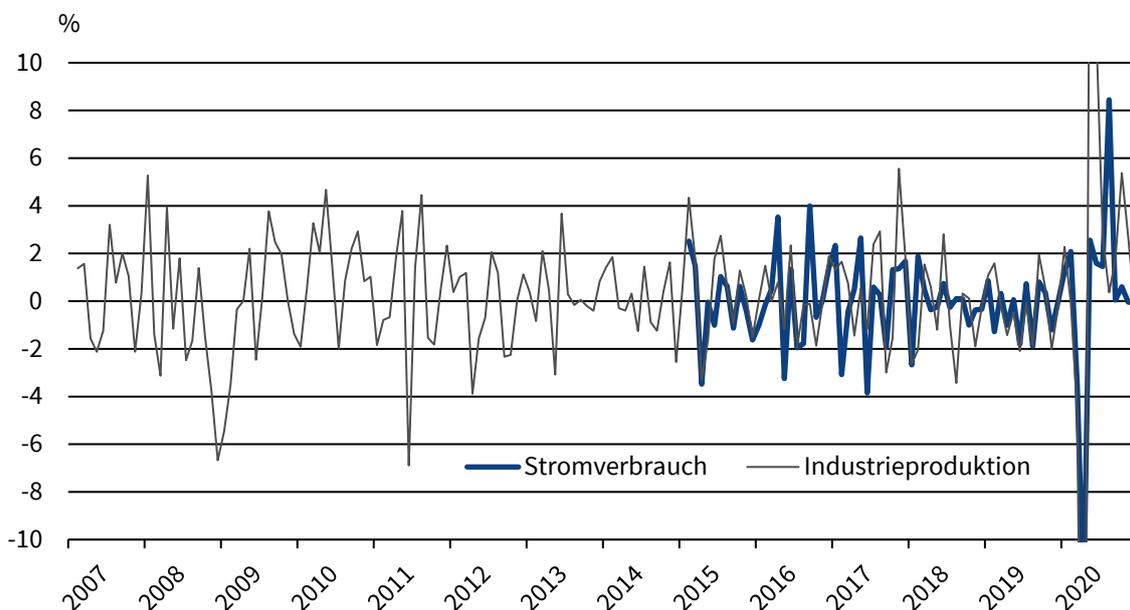
Quellen: N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG;
Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

Das Bild bestätigt sich, wenn man anstatt der Stromverbrauchsdaten zweier VNB die Angaben aller vier Akteure für den Zeitraum zwischen 2015 und 2020 heranzieht (vgl. Abbildung 12). Beide Abgrenzungen für die monatliche Veränderung im Stromverbrauch weisen eine ähnlich starke Volatilität auf (zwei VNB: 2,9 Prozentpunkte, vier VNB: 2,4 Prozentpunkte). Zudem zeigen beide Zeitreihen sehr ähnliche Verlaufsmuster, was sich auch in der starken positiven Korrelation von 0,91 widerspiegelt.

Abbildung 12: Stromverbrauch RLM-Kunden und Industrieproduktion, alle VNB

Veränderung gegenüber dem Vormonat, saison- und kalenderbereinigt



Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH, N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG; Darstellung des ifo Instituts.

© ifo Institut

Die Unterscheidung in eine lange Stromverbrauchsreihe mit nur zwei VNB und einer kurzen Zeitreihe aller VNB spielt vor allem für das Prognoseexperiment eine zentrale Rolle. Um valide Aussagen über die prognostische Güte eines Indikators zu erhalten, müssen ausreichend lange Zeitreihen vorliegen. Die kurze Zeitreihe ab 2015 ist dabei schon als eher kritisch anzusehen. Dennoch spezifizieren wir Prognoseexperimente für den langen und den kurzen Zeitraum, interpretieren die Ergebnisse für den kürzeren Zeitraum aber ausschließlich qualitativ.

2.7 Empirische Zusammenhänge für die Prognose

Um zunächst einen Eindruck davon zu bekommen, ob die berücksichtigten Indikatoren einen gewissen zeitlichen Zusammenhang zur Zielgröße aufweisen, berechnen wir so genannte Kreuzkorrelationen. Dabei handelt es sich im Grundsatz um einfache Korrelationskoeffizienten, wobei zeitliche Verzögerungen der Indikatoren explizit berücksichtigt werden. So kann bspw. der durchschnittliche Grad des Zusammenhangs des gestrigen Werts eines Indikators mit der Ausprägung der Zielgröße heute berechnet werden. Verallgemeinert ist die Berechnung für jede Zahl an Zeitperioden in der Vergangenheit oder in der Zukunft möglich. Für die Prognose sind aber besonders jene Indikatoren wertvoll, die entweder einen Gleichlauf oder einen Vorlauf vor der zu prognostizierenden Größe aufweisen (vgl. Nierhaus und Sturm 2020).

Konjunkturindikatoren mit einem Gleichlauf sind dann besonders für die Prognose geeignet, wenn sie keinen Publikationsverzögerungen unterliegen (z.B. ifo Indikatoren sind bereits am Ende eines Monats verfügbar) oder gar in höherer Frequenz (z.B. täglich) zur Verfügung stehen. Damit sind gleichlaufende Indikatoren besonders wertvoll für die Prognose des jeweils aktuellen Monats, was gemeinhin auch als „Nowcast“ bezeichnet wird. Konjunkturindikatoren mit einem Vorlauf sind hingegen besonders geeignet für die Prognose der kommenden Monate, da sie die Entwicklung der Zielgröße frühzeitig anzeigen.

Im Folgenden werden die Kreuzkorrelationen zwischen der bayerischen Industrieproduktion und jeweils einem der Indikatoren (Stromverbrauch, Auftragseingang, ifo Indikatoren und Lkw-Maut-Fahrleistungen) separat betrachtet. Hierfür wurden die saison- und kalenderbereinigten Indikatoren in Veränderungen zum Vormonat transformiert, was bei den quantitativen Indikatoren prozentualen Veränderungen und bei den ifo Indikatoren den einfachen Differenzen entspricht. Es werden ausschließlich Zeitverschiebungen von 0 Monaten (Gleichlauf) bis 3 Monaten (starker Vorlauf) betrachtet. Tabelle 1 präsentiert diese Kreuzkorrelationen.

Insgesamt fällt auf, dass alle Indikatoren die jeweils stärkste Korrelation bei einem Gleichlauf aufweisen und die Stärke des Zusammenhangs mit größer werdendem Vorlauf weiter abnimmt. Bemerkenswert ist die starke Korrelation zwischen bayerischen Stromverbrauchsdaten und bayerischer Industrieproduktion, was bei Vormonatsveränderungen aufgrund der hohen Volatilität der Zeitreihe eher selten der Fall ist. In der längeren Betrachtung der Stromverbrauchsdaten zweier VNB (2008-2020) beträgt die Korrelation beim Gleichlauf 0,62 und für den kürzeren Zeitraum basierend auf den Angaben der vier VNB 0,72 (2015-2020); sofern man die Korrelationen für gleich kurze Zeitfenster berechnet (2015-2020), steigt die Korrelation zwischen den Stromverbrauchsdaten der zwei VNB und der bayerischen Produktion geringfügig auf einen Wert von 0,69 an. Ein ähnlich starker Gleichlauf findet sich auch zwischen dem Auftragseingang und der Produktion (Korrelation: 0,63), was für den gleichen Zeitraum etwas schwächer im Vergleich zu Deutschland ausfällt (Korrelation: 0,81).

Die ifo Indikatoren weisen insgesamt eine etwas schwächere kontemporäre Korrelation mit der Industrieproduktion in Bayern auf, zeigen dafür aber Eigenschaften als Frühindikatoren mit einem gewissen Vorlauf. Hervorzuheben sind hier insbesondere die ifo Geschäftserwartungen. Die geringere Korrelation zwischen den ifo Indikatoren und Vormonatsveränderungen im Vergleich zu quantitativen Indikatoren wie dem Auftragseingang ist kein neues Phänomen, sondern zeigt sich auch für Deutschland insgesamt, für das die ifo Indikatoren als wichtigste Frühindikatoren gelten und einen hohen prognostischen Gehalt aufweisen (vgl. Lehmann 2020). Maßgeblich für die geringere Stärke des Zusammenhangs sind die Eigenschaften der betrachteten Zeitreihen. Während die Vormonatsveränderung der Industrieproduktion sehr volatil und schwankungsfähig ist, weisen die ifo Indikatoren einen deutlich glatteren Verlauf auf.

Tabelle 1: Kreuzkorrelationen der Indikatoren zur bayerischen Industrieproduktion, 2008 bis 2020

Indikator	Vorlauf in ... Monaten			
	0	1	2	3
Stromverbrauch Bayern, zwei VNB	0,62	-0,00	-0,21	-0,06
Stromverbrauch Bayern, vier VNB ^a	0,72	-0,08	-0,28	-0,05
Auftragseingang Verarbeitendes Gewerbe Bayern	0,63	0,14	-0,18	-0,10
ifo Geschäftslage Verarbeitendes Gewerbe Bayern	0,42	-0,01	-0,07	0,07
ifo Geschäftsklima Verarbeitendes Gewerbe Bayern	0,55	0,19	-0,16	-0,01
ifo Geschäftserwartungen Verarbeitendes Gewerbe Bayern	0,50	0,27	-0,18	-0,06
ifo Produktionstätigkeit Verarbeitendes Gewerbe Bayern	0,35	-0,03	-0,14	0,08
ifo Produktionspläne Verarbeitendes Gewerbe Bayern	0,54	0,11	0,03	-0,11
Stromverbrauch Deutschland	0,36	0,01	-0,13	0,01
Lkw-Maut-Fahrleistungsindex	0,64	0,15	-0,20	-0,06

Anmerkung: Die bayerische Industrieproduktion, der Auftragseingang, die Stromverbrauchsdaten und der Lkw-Maut-Fahrleistungsindex wurden vorab in Vormonatsveränderungen transformiert. Die ifo Indikatoren werden in einfachen Differenzen ausgedrückt. a) Angepasster Zeitraum: 2015 bis 2020. Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH, N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG, ifo Konjunkturumfrage Bayern, ENTSO-E, Bundesnetzagentur SMARD, Bayerisches Landesamt für Statistik, Statistisches Bundesamt; Berechnungen des ifo Instituts.

Die gesamtdeutschen Stromverbrauchsdaten weisen eine eher schwache Korrelation (Gleichlauf: 0,36) auf, was möglicherweise auf die unterschiedlichen Abgrenzungen der Stromverbrauchsdaten zurückzuführen ist. Der Lkw-Maut-Fahrleistungsindex hingegen scheint recht vielversprechend zu sein, da er – analog zu den bayerischen Stromverbrauchsdaten – einen kräftigen Gleichlauf (Korrelation: 0,64) mit der Veränderung der bayerischen Industrieproduktion offenbart. Insgesamt scheinen alle betrachteten Indikatoren geeignet für die Prognose zu sein. Besonders aber die neu in die Diskussion gebrachten Stromverbrauchsdaten versprechen einen hohen prognostischen Gehalt.

3 Energieverbrauch und Energieeffizienz

Das dritte Kapitel umfasst die Bearbeitung des ersten Arbeitspaketes. Stromverbräuche der Industrie sind auch über ihre Prognosefähigkeit hinaus eine interessante Datenquelle. Zum einen ist die Erhöhung der Energieeffizienz einer der Pfeiler der deutschen Energiewende und Klimapolitik, und die Daten zum Stromverbrauch erlauben einen Einblick in die Effizienzentwicklung in diesem Bereich. In diesem Kontext kann sich ggf. die Aussagekraft des Stromverbrauchs als Konjunkturindikator ändern, wenn sich die Stromverbrauchsintensität der Produktion über die Zeit ändert. Zum anderen bringt die Energiewende Veränderungen im Strommarkt mit sich; aufgrund der steigenden Anteile fluktuierender Erneuerbarer an der Stromerzeugung nimmt die Bedeutung des Lastmanagements zu und es stellt sich die Frage, inwieweit die aktuellen Strompreise und Netzentgelte hier sinnvolle Anreize setzen, Stromverbräuche zu glätten bzw. im Zeitverlauf zu verschieben.

Das folgende Kapitel befasst sich auf Basis der vorliegenden Verbrauchsdaten mit der Stromintensität der bayerischen Industrieproduktion, mit der Bedeutung der aktuellen Netzentgeltstrukturen und mit dem Zusammenspiel von Strompreisen und Stromnachfrage. Es beleuchtet außerdem den Zusammenhang zwischen Stromverbrauch und Luftverschmutzung in Bayern. In allen Abschnitten werden die Ergebnisse mithilfe von kurzen Literaturüberblicken in einen allgemeineren Kontext gesetzt und Ausblicke gegeben, welche weiteren Analysen mit stärker disaggregierten Daten möglich wären.

3.1 Energieeffizienz und Energieintensität

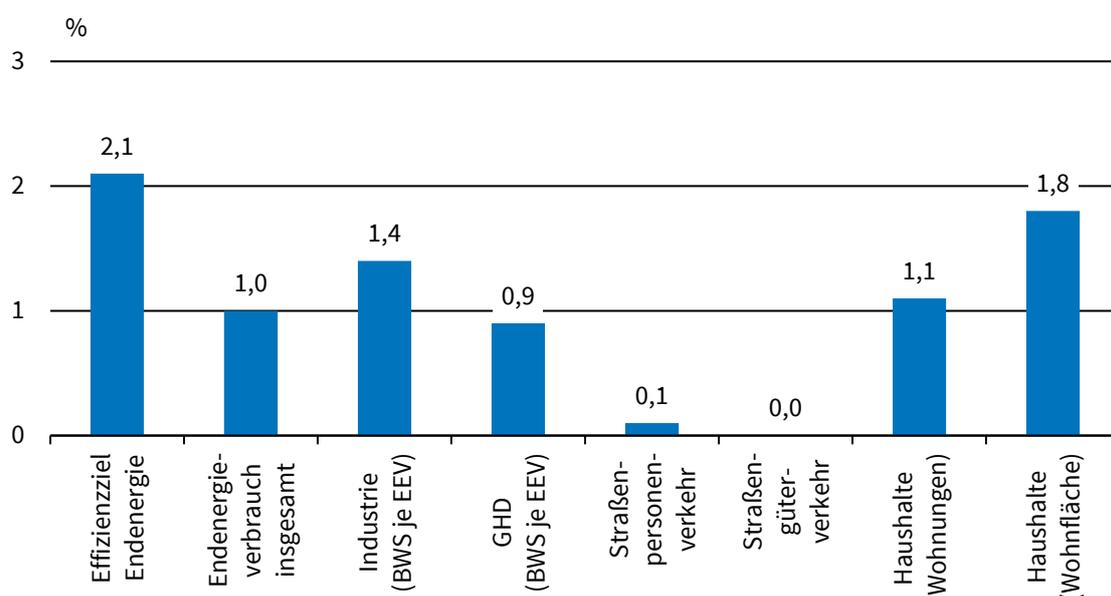
Um die Ziele der Energiewende und des Klimaschutzes zu erreichen, spielt in den Plänen der Europäischen Union (EU) und der Bundesregierung die Reduktion des Energieverbrauchs eine entscheidende Rolle. Um dies zu messen, wird üblicherweise der Primärenergieverbrauch oder der Endenergieverbrauch verwendet. Beim Primärenergieverbrauch lassen sich die genutzten Energieträger unterscheiden, beim Endenergieverbrauch die nutzenden Verbrauchssektoren. In der Summe unterscheiden sich die beiden Maße insbesondere durch die Verluste in der Energieumwandlung und durch den nicht-energetischen Verbrauch.

Je nach Verbrauchssektor werden die Endenergieverbräuche in Relation zu einer anderen Größe gesetzt, um Effizienz bzw. Intensität darzustellen. Bei Haushalten wird häufig der Endenergieverbrauch pro Kopf, pro Wohnung oder pro Wohnfläche verwendet. In der Industrie hingegen setzt man den Energieverbrauch ins Verhältnis zum Bruttoproduktionswert; für Gewerbe, Handel und Dienstleistungen wird üblicherweise mit der BWS verglichen. In Deutschland blieb die Energieintensität der Industrie (in Gigajoule/1.000 Euro Bruttoproduktionswert) im hier betrachteten Zeitraum zwischen 2015 und 2019 konstant bei 2,34 (vgl. AG Energiebilanzen 2020).

Zwischen 2008 und 2017 sank die Energieintensität in der Industrie um durchschnittlich 1,4% pro Jahr (vgl. Expertenkommission 2019). Damit konnte allerdings das in der Energiewende vorgegebene Effizienzziel von durchschnittlich 2,1% p. a. zwischen 2008 und 2017 nicht erreicht werden (vgl. Abbildung 13). Industrie und das Aggregat bestehend aus Gewerbe, Handel und Dienstleistungen (GHD) weisen zwar bessere Werte auf als der Verkehr, liegen aber immer noch deutlich unter dem Ziel (vgl. Expertenkommission 2019).

Abbildung 13: Entwicklung der Energieeffizienz nach Abnehmer, Durchschnitt 2008 bis 2017

Durchschnittliche jährliche Effizienzsteigerung



Abkürzungen: BWS je EEV - Bruttowertschöpfung je Endenergieverbrauch; GHD - Gewerbe, Handel, Dienstleistungen. Quellen: Expertenkommission zum Monitoring Prozess "Energie der Zukunft". © ifo Institut

Tatsächlich lassen sich auch aus der Literatur zur „Energieeffizienzlücke“ (energy efficiency gap) einige Gründe anführen, warum kostendeckende Investitionen in Energieeffizienz häufig nicht durchgeführt werden (vgl. Gillingham und Palmer 2014). Ein Grund ist das Risiko fluktuierender Energie- (und CO₂-) Preise: bei irreversiblen Investitionen und fluktuierenden Energiepreisen muss ein höherer Ertrag gewährleistet sein als ohne dieses Risiko. Im Vergleich dazu ist der Ausbau von Erneuerbaren-Erzeugungsanlagen unter dem Erneuerbare-Energien-Gesetz (EEG) risikoarm, da die Zahlungsbeträge pro eingespeister Kilowattstunde von vornherein feststehen.¹ Noch wichtiger ist aber sicherlich das Argument der Opportunitätskosten. Die Identifikation und Umsetzung von Energiesparmaßnahmen – selbst mit Hilfe eines kostenlosen Energieaudits o. Ä. – bindet wertvolle Personalressourcen, die dann für andere produktive Einsätze fehlen (vgl. Anderson und Newell 2004). In kleinen Unternehmen mit wenigen Mitarbeitern fallen diese Hemmnisse noch stärker ins Gewicht. Dazu kommt die Möglichkeit des Rebound-Effekts, wonach die durch

¹ Aus einer bisher unveröffentlichten Umfrage des ifo Instituts für die Stiftung Familienunternehmen geht hervor, dass mehr Unternehmen in eigene Erzeugungsanlagen aus Erneuerbarer Energie investieren als in Energieeffizienzmaßnahmen.

Energieeinsparungen freiwerdende Mittel zu einer Wiedererhöhung des Energieverbrauchs führen; empirische Untersuchungen kommen aber zu dem Schluss, dass der Rebound-Effekt Einsparungen wohl nicht vollständig kompensiert (vgl. Borenstein 2015).

Wenn im gesamtwirtschaftlichen Kontext von einer Veränderung der Energieintensität gesprochen wird, werden dabei typischerweise zwei Kanäle unterschieden (vgl. Haas und Kempa 2018): der strukturelle Effekt (Änderung der Energieintensität durch eine Verschiebung der wirtschaftlichen Aktivität von energieintensiven zu stärker dienstleistungsorientierten Branchen) und der Effizienzeffekt (Effizienzsteigerungen innerhalb von Branchen, insbesondere innerhalb der energieintensiven Industrie). Der strukturelle Effekt wird durch die Produktivität in den verschiedenen Wirtschaftsbereichen getrieben. Der Effizienzeffekt geht auf den Einfluss von Preisen und Innovationsaktivitäten vor allem im energieintensiven Bereich zurück (die wiederum beide durch Politikmaßnahmen beeinflusst werden können). Auf Basis von Daten für 1995 bis 2007 zeigen Haas und Kempa (2018), dass in diesem Zeitraum in Deutschland der Effizienzeffekt dominierte.

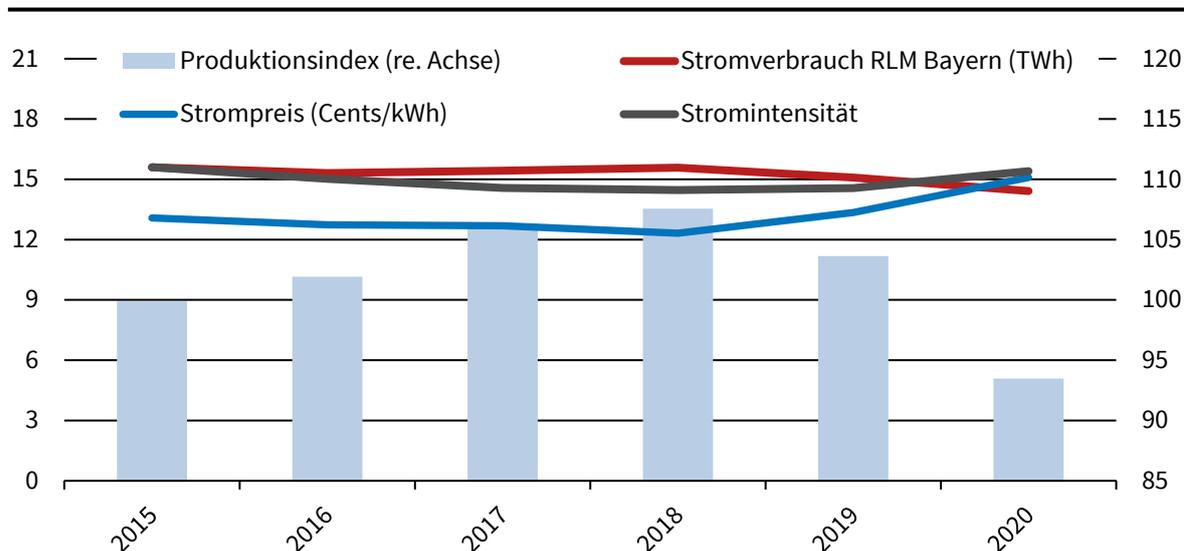
Mit den vorliegenden Daten zum Stromverbrauch der Industrie kann offensichtlich nur der Effizienzeffekt beurteilt werden, und auch nur in begrenztem Maße. Der Bezug von Strom ist nur eine Komponente des Endenergieverbrauchs. Auch aufgrund der Substitutionsmöglichkeiten zwischen verschiedenen Energieträgern lässt sich vom Verbrauch des Energieträgers Strom nicht zwangsläufig auf den Endenergieverbrauch schließen. Insbesondere die Elektrifizierung von Industrieprozessen auf dem Weg zur Klimaneutralität 2045 wird voraussichtlich zu einem Anstieg des deutschen Industriestromverbrauchs spätestens ab 2035 führen (vgl. Prognos et al. 2021), ohne dass man dies als Rückschritt in der Energieeffizienz beurteilen sollte.

Was sich im Kontext von Stromverbräuchen darstellen lässt, ist die Entwicklung der deutschen Industriestrompreise im Vergleich zum Stromverbrauch: wie oben erwähnt, geht die Literatur davon aus, dass Energiepreise die Effizienz beeinflussen. Allerdings sind die deutschen Strompreise – anders als die Preise importierter Energieträger – stark von der deutschen Stromnachfrage beeinflusst: eine höhere Stromnachfrage geht in der kurzen Frist mit höheren Börsenstrompreisen einher (siehe auch Abschnitt 3.3), die sich dann auch mittelfristig in höhere langfristige Preise übersetzen. Einzelne Unternehmen können natürlich auf höhere Strompreise mit Stromeinsparungen reagieren; in der aggregierten Analyse wird aber immer auch der Zusammenhang zu sehen sein, dass die Gesamtnachfrage den Preis beeinflusst. Somit ist auf Basis von aggregierten Daten ein kausaler Zusammenhang zwischen Verbrauch und Preisen nicht ohne Weiteres identifizierbar.

Basierend auf den aktuell vorliegenden, aggregierten Daten der bayerischen VNBs lässt sich weder ein klarer Trend bei der Stromintensität (Verhältnis des Stromverbrauchs zum Produktionsindex Bayerns) noch ein eindeutiger Zusammenhang zwischen Strompreisen und Energieintensität erkennen (vgl. Abbildung 14). Der Stromverbrauch bei Großabnehmern in Bayern war zwischen 2015 und 2019 recht konstant.

Abbildung 14: Entwicklung von Industriestrompreis, Stromverbrauch und Energieintensität Bayern

Stromintensität in Bayern



Der angegebene Strompreis ist der mittlere Preis für deutsche Industriekunden mit einem jährlichen Verbrauch von 2.000 MWh bis 20.000 MWh. Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH, N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG; Bayerisches Landesamt für Statistik, Eurostat; Berechnungen und Darstellung des ifo Instituts. © ifo Institut

Zum Vergleich: In Deutschland lag die Energieintensität in der Industrie (in Gigajoule / 1.000 Euro Bruttowertsatz) zwischen 2015 und 2019 konstant bei 2,34. Die Stromintensität (in Kilowattstunden / 1.000 Euro Bruttowertsatz) sank im gleichen Zeitraum leicht von 206,46 auf 201,43 (vgl. AG Energiebilanzen 2020).

Neben den Preisen können Politikmaßnahmen zu Effizienzsteigerungen beitragen. Energieeffizienzprogramme unterscheiden sich von anderen Klimaschutz- und Energiewendemaßnahmen wie etwa dem Emissionshandel oder dem EEG: bei Letzteren ist relativ klar, was und wen sie regulieren, zu welchem Zeitpunkt sie in Kraft treten und welche Preise oder Tarife zu welcher Zeit gelten. Im Vergleich dazu sind Programme zur Steigerung der Energieeffizienz viel kleinteiliger und teilweise auch überlappend, was die Evaluierung der Wirkung erschwert (vgl. Expertenkommission 2019). In Deutschland beinhaltet z.B. der Nationale Aktionsplan Energieeffizienz (NAPE) mehrere unterschiedliche Maßnahmen, die den Energie- und potentiell den Stromverbrauch in der Industrie adressieren. Dazu gehört das KfW-Energieeffizienzprogramm für Produktionsanlagen und Prozesse, der Energieeffizienzfonds, die Energieauditpflicht für nicht-KMUs und die Initiative Energieeffizienznetzwerke (vgl. Bundesministerium für Wirtschaft und Energie 2019). Auf Basis der verfügbaren Daten ist die Wirkung solcher Maßnahmen schwer zu evaluieren. Der NAPE wurde im Dezember 2014 veröffentlicht, galt also über den gesamten Betrachtungszeitraum hinweg. Viele der Maßnahmen wurden und werden zu unterschiedlichen Zeitpunkten individuell umgesetzt.

Die Analyse von Politikmaßnahmen und Stromverbrauch konzentriert sich deshalb auf zwei eher allgemeine Ankündigungen auf EU-Ebene: das „Saubere Energie für alle Europäer“-Paket (vgl. Europäische Kommission 2016) und zwei Richtlinien, die im Dezember 2018 verabschiedet wurden: die Erneuerbare-Energien-Richtlinie (vgl. Europäische Union 2018a) und die Energieeffizienzrichtlinie (vgl. Europäische Union 2018b). Die Kommunikation des „Saubere Energie für alle Europäer“-Pakets ist eine Ankündigung von geplanten Politikmaßnahmen, hat also selbst keinen rechtsverbindlichen Charakter; die Richtlinien enthalten Vorschriften für die EU-Mitgliedsstaaten, geben ihnen aber Zeit und Gestaltungsspielraum zur Umsetzung.

Trotz oder gerade wegen dieses allgemeinen Charakters der EU-Ankündigungen kann eine Analyse lohnenswert sein: auch die Bekanntgabe geplanter Politiken kann dazu beitragen, Normen zu verbreiten und Erwartungen zu formen; diese „expressive role of law“ (vgl. Bénabou und Tirole 2011) erreicht alle Unternehmen gleichzeitig, unabhängig davon, ob sie von umgesetzten Maßnahmen tatsächlich betroffen wären. Auch empirische Studien zeigen, dass Unternehmen häufig schon auf politische Ankündigungen reagieren und das Datum des Inkrafttretens nicht immer relevant ist (vgl. Lemoine 2017, Hendricks et al. 2021).

Abbildung 15 zeigt Regressions-Diskontinuitäts-Analysen rund um die beschriebenen Politikankündigungen (einzeln für jeden VNB): es wird unter Berücksichtigung von Kontrollvariablen wie Anzahl der Kunden pro Netzbetreiber geprüft, ob es zu den beschriebenen Zeitpunkten einen Bruch im aggregierten Strombezug gibt. Für das „Saubere Energie für alle Europäer“-Paket (jeweils linke Seite) ist dies nicht der Fall. Zum Zeitpunkt der beiden Richtlinien zu Erneuerbaren Energien und Energieeffizienz scheint es bei allen Netzbetreibern eine gewisse Diskontinuität zu geben: außer bei den SWM überlappen sich die Konfidenzintervalle links und rechts von der Bruchlinie nicht. Interessant ist, dass dieser Bruch bei den Stromverbrauchsdaten für ganz Deutschland (vgl. Abbildung 16) nicht sichtbar ist. Die Gesamtdaten für Deutschland enthalten auch den Stromverbrauch der Haushalte – dies könnte ein Hinweis darauf sein, dass insbesondere in der Industrie eine Änderung stattgefunden hat. Ein klarer Beweis für die „expressive“ Wirksamkeit der beiden Richtlinien ist die Analyse allerdings nicht. Es könnten zeitgleich auch andere Faktoren eine Rolle gespielt haben. Dazu kommt die allgemeine Frage, inwieweit der Stromverbrauch beim anvisierten Energieeffizienzgewinn eine Rolle spielt.

Abbildung 15: Regressions-Diskontinuität nach Netzbetreibern

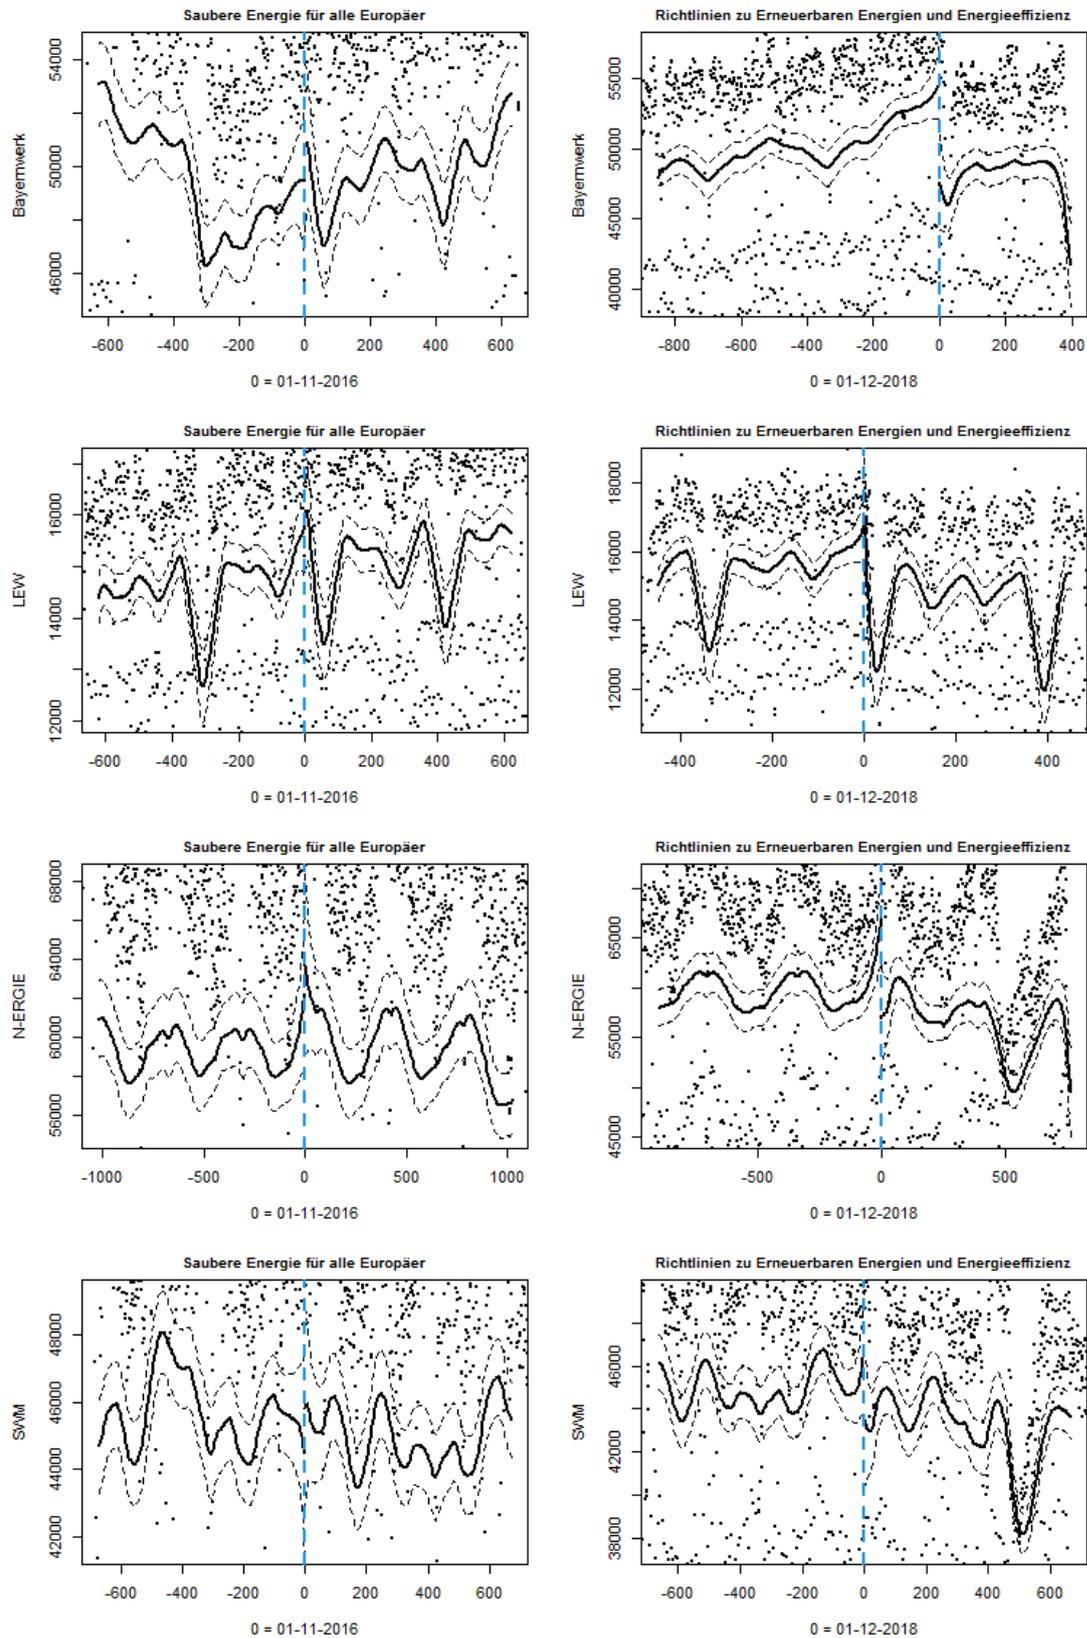
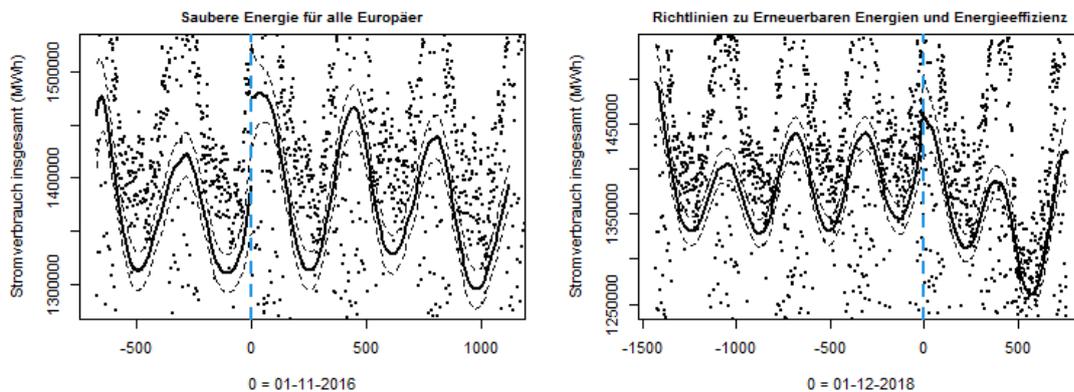


Abbildung 16: Regressions-Diskontinuität für Deutschland



3.2 Lastmanagement: Möglichkeiten und Netzentgeltstruktur

Die ehrgeizigen Dekarbonisierungsziele und der verstärkte Einsatz erneuerbarer Energiequellen erfordern nicht nur eine höhere Energieeffizienz, sondern auch eine größere Flexibilität des Netzes, um eine stabile und zuverlässige Versorgung zu gewährleisten. Derzeit kann ein höherer Anteil an variablen Erneuerbaren dazu führen, dass die Stromversorgung volatiler wird. Eine Möglichkeit, dies zu überwinden, ist die Entwicklung eines neuen dynamischen Gleichgewichts zwischen Angebot und Nachfrage durch Demand Side Management (DSM). Im Allgemeinen umfasst DSM eine Reihe von Maßnahmen, die das Ausmaß und/oder den Zeitpunkt der Stromnachfrage verändern, um den gesamtwirtschaftlichen Nutzen zu erhöhen (vgl. Arnold und Janssen 2016). DSM-Programme können wie folgt klassifiziert werden (vgl. Palensky und Dietrich 2011):

- Anreizbasierte DSM:
 - Direkte Laststeuerung (DLC): Versorgungsunternehmen oder Netzbetreiber erhalten freien Zugang zu den Kundenprozessen.
 - Unterbrechbare/kurzfristige Tarife: Kunden erhalten Sonderverträge mit begrenzten Abnahmemengen.
 - Notfallprogramme: freiwillige Reaktion auf Notfallsignale.
 - Kapazitätsmarktprogramme: Kunden garantieren die Einspeisung, wenn das Netz in Not ist.
 - Programme zur Nachfragebegrenzung (Demand Bidding): Kunden können ein Gebot für die Einspeisung zu attraktiven Preisen abgeben.
- Zeitabhängige DSM:
 - Time-of-Use-Tarife (ToU): Es wird ein statisches Preisschema angewandt.
 - Kritische Spitzenlasttarife (Critical-Peak-Pricing, CPP): Eine weniger vorherbestimmte Variante von ToU.
 - Real-Time-Pricing (RTP): Die Großhandelsmarktpreise werden an die Endkunden weitergeleitet.

Insgesamt gibt es weniger Studien zu DSM-Programmen in der Industrie als für Privathaushalte. Die verfügbaren Studien zeigen jedoch positive Ergebnisse. Krzikalla et al. (2013) zeigen beispielsweise, dass DSM in der Industrie im Vergleich zu den meisten Flexibilitäts- und Zuverlässigkeitsmaßnahmen eine der kosteneffizientesten und am einfachsten umzusetzenden Strategien ist. Darüber hinaus zeigen verschiedene Simulationsstudien, dass das höchste Einsparungspotenzial bei den Betriebskosten von etwa 10% für Industriekunden gegenüber durchschnittlich 5% für Haushaltskunden möglich ist (vgl. Logenthiran et al. 2012). In dieser Hinsicht haben DSM-Programme, wenn sie auf industrielle Verbraucher angewandt werden, das Potenzial, die Zuverlässigkeit des Netzes erheblich zu verbessern und monetäre Einsparungen zu erzielen, anstatt in Netzkapazitätserweiterungen zu investieren. Ein relevantes Beispiel für ein regionales DSM-Programm ist das Pilotprojekt Demand Side Management Bayern, das Unternehmen darin unterstützen soll, ihre Stromnachfrage flexibler zu gestalten.

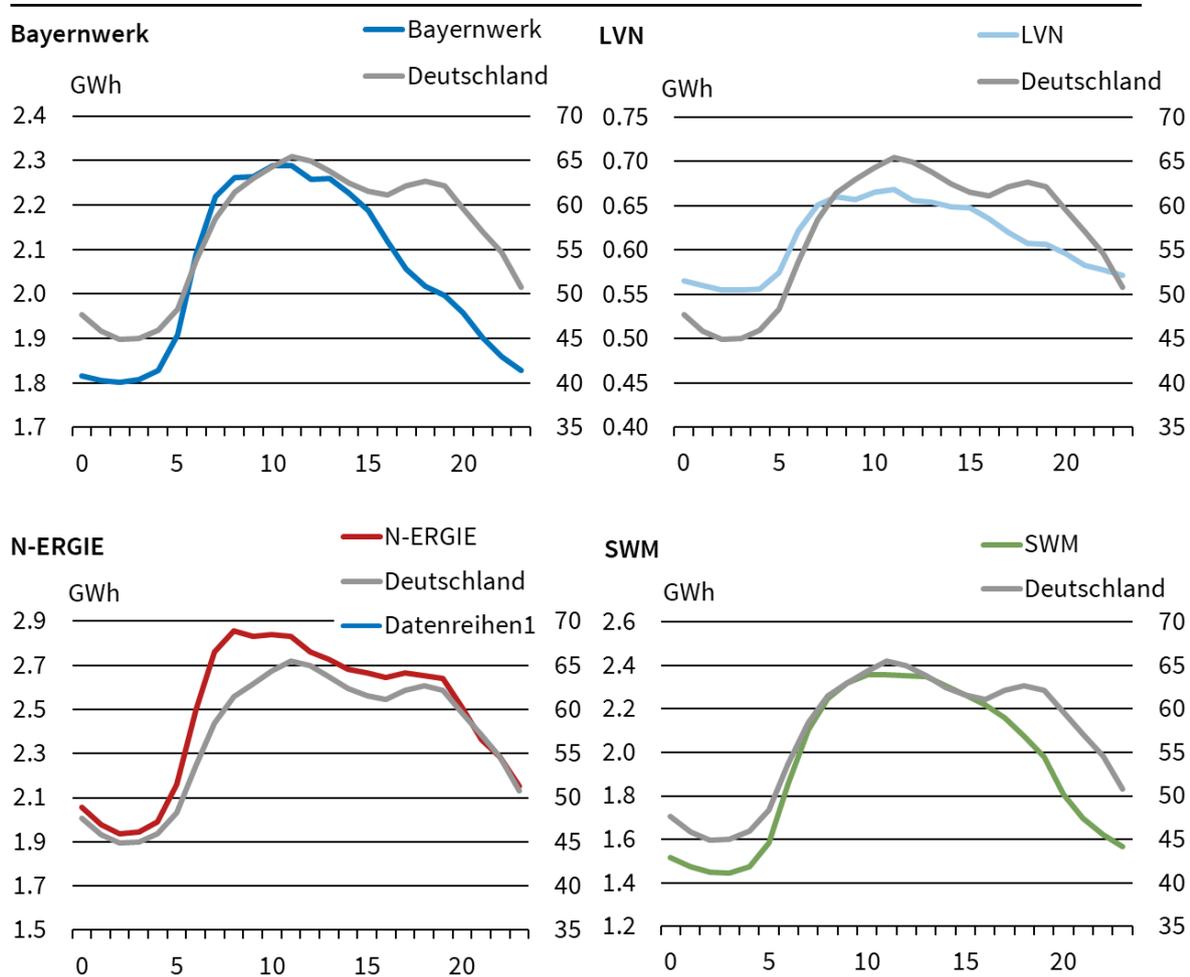
Allgemein könnten Stromverbrauchsdaten großer Industriekunden zur Ausarbeitung spezifischer Anreizsysteme sowie zur Weiterentwicklung und Quantifizierung der Nachfragesteuerung beitragen. Während die derzeit verfügbaren aggregierten Daten keine Schätzung der Kosteneinsparungen oder der Effizienz eines spezifischen DSM-Programms erlauben, können wir eine erste explorative Analyse durchführen, indem wir die durchschnittliche stündliche Stromnachfrage jedes Netzbetreibers mit der Gesamtnachfrage in Deutschland im Zeitraum von 2015 bis 2019 vergleichen (vgl. Abbildung 17).

Im Vergleich der Nachfrageprofile der bayerischen RLM-Kunden (blaue, rote, grüne Linien) mit der gesamtdeutschen Nachfrage (graue Linien) zeigt sich zunächst der klare Abfall der Industrienachfrage in den Abendstunden, wohingegen der gesamtdeutsche Stromabsatz – der auch Haushaltskunden enthält – noch einen zweiten Peak in den Abendstunden aufweist. Interessant ist auch, dass die Nachfrage der bayerischen RLM-Kunden früher am Morgen ansteigt und die Lastspitze etwas früher erreicht wird als in Gesamtdeutschland. Beim VNB N-ERGIE Netz GmbH fällt dies besonders auf; andererseits bewegt sich die Nachfrage dort in den Abendstunden stärker analog zur Nachfrage im Gesamtnetz. Dies könnte bedeuten, dass bei Kunden der N-ERGIE Netz GmbH ein höheres Einsparungspotential besteht, wenn die abendliche Netzspitze gezielt gesenkt werden soll.

Abbildung 17: Stündliche Lastprofile der VNB im Vergleich zu Deutschland, Durchschnitt 2015 bis 2019

Durchschnittliche stündliche Lastprofile

Stromverbrauch insgesamt



Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH (LVN), N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG; Bundesnetzagentur; Darstellung des ifo Instituts.

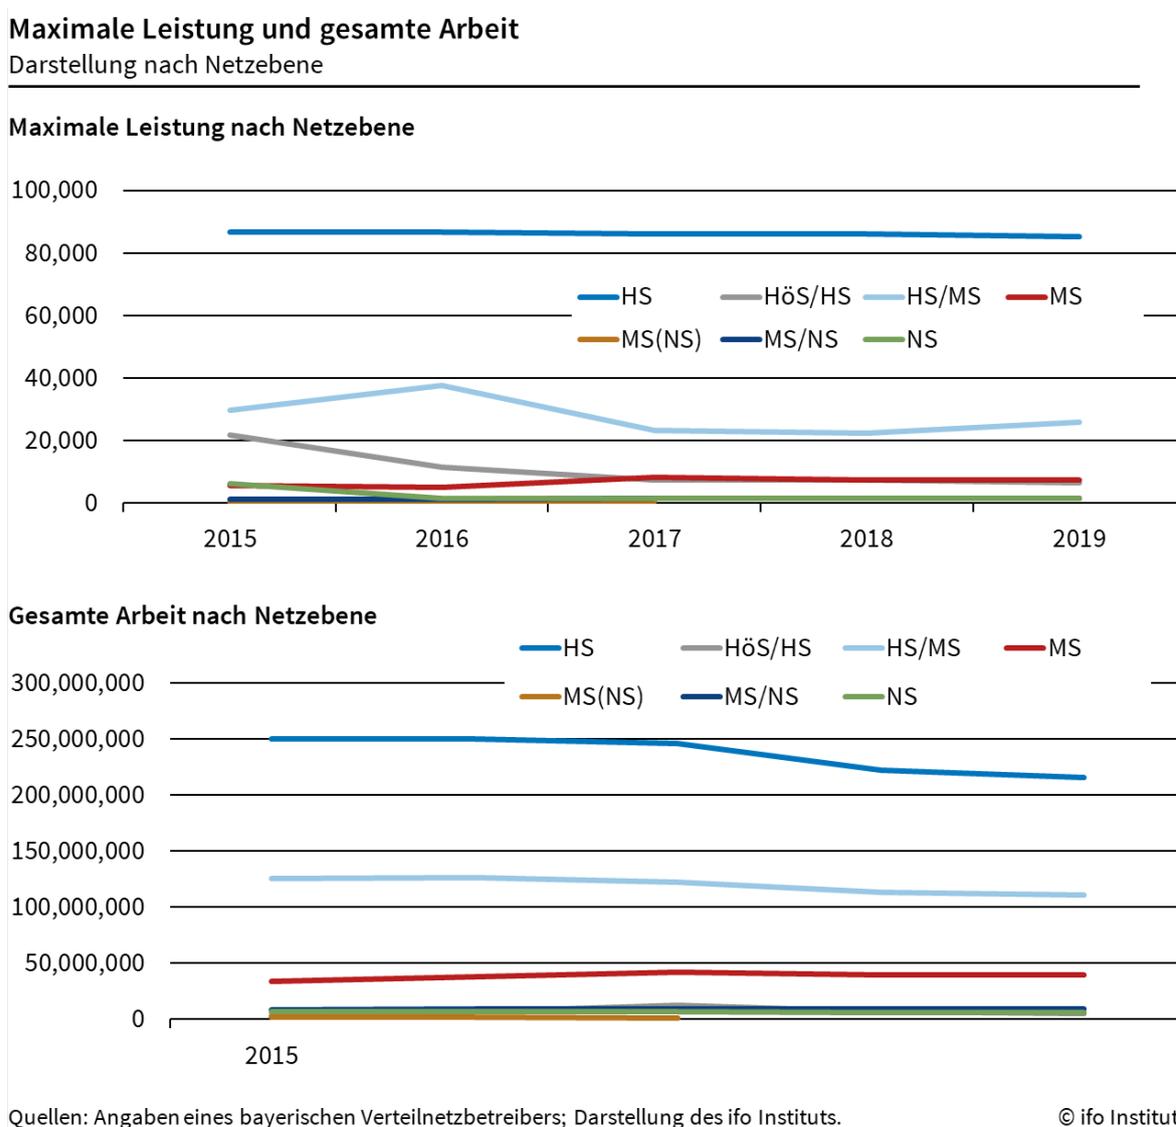
© ifo Institut

Detailliertere Informationen über die höchsten Spitzenwerte (maximale Leistung) pro Jahr nach Netzebene sind ebenfalls verfügbar. RLM-Kunden können an folgende Netzebenen angeschlossen werden:

- Umspannung Höchstspannung zu Hochspannung (HöS/HS),
- Hochspannung (HS),
- Umspannung Hochspannung zu Mittelspannung (HS/MS),
- Mittelspannung (MS),
- Umspannung Mittelspannung zu Niederspannung (MS/NS),
- Niederspannung (NS).

Die Entwicklung der Spitzenwerte von 2015 bis 2019 und die Entwicklung des Gesamtstromverbrauchs (gesamte Arbeit) nach Netzebene ist in der Abbildung 18 beispielhaft für einen Netzbetreiber dargestellt. Zwischen den Jahren 2016 und 2017 kam es zu einigen Anschlusswechseln, die sich in der „vertauschten“ Arbeit nach Netzebene (zwischen der Hochspannungs-/Mittelspannungsanschlussstelle und Mittelspannung) widerspiegeln. Andererseits scheint zwischen 2016 und 2017 die maximale Leistung im Mittelspannungsbereich nicht so stark angestiegen zu sein wie die Jahresarbeit. Im Hochspannungsbereich sank die maximale Leistung analog zur Gesamtarbeit. Insgesamt lassen sich aber viele Veränderungen im Jahresvergleich durch Anschlusswechsel, Neuanschlüsse bzw. Netzgebietsveränderungen erklären.

Abbildung 18: Maximale Leistung und gesamte Arbeit nach Netzebene, 2015 bis 2019



Aktuell können Großverbraucher ein individuelles, geringeres Netzentgelt bezahlen, wenn sie „atypische Netznutzung“ nachweisen (also vorwiegend außerhalb der „Hochlastzeitfenster“ Strom abnehmen) oder besonders gleichmäßig Strom beziehen (über 7.000 Jahresbenutzungsstunden). Außerdem gibt es auf Ebene der Übertragungsnetzbetreiber (ÜNB) ebenfalls Anreize zum Lastmanagement (vgl. Eicke et al. 2021): über Regelleistungsmärkte, die Verordnung zum Abschalten von Lasten, und schließlich auch über den Strom-Spotmarkt (Intraday), wo einige der größten Verbraucher ihren Strom direkt an der Börse zu zeitspezifischen Preisen kaufen, die eine gewisse Knappheit widerspiegeln. Die übrige Netzentgeltssystematik bietet aber eher Anreize für einen gleichmäßigen, hohen Strombezug – und diese Mechanismen wirken finanziell stärker als der Anreiz der möglichen Erlöse durch die oben genannten Märkte (Deutsche Energie-Agentur 2018).

Vor diesem Hintergrund und wegen der sich ändernden Stromerzeugungsstruktur (Kohleausstieg, größerer Anteil Erneuerbarer Energien) wird derzeit auf Ebene der Bundesnetzagentur eine Änderung der Netzentgeltregelungen für Großkunden diskutiert (vgl. Agora Energiewende 2021, Deutsche Energie-Agentur 2018). Die Rolle und Handlungsfähigkeit der Bundesnetzagentur als Unterstützung der Energiewende-Politik wurde allerdings durch das jüngste Urteil des Europäischen Gerichtshofs in Frage gestellt: „Der Europäische Gerichtshof (EuGH) hat Deutschland aufgefordert, der unter anderem für die Regulierung der Strom- und Gasnetze zuständigen Bundesnetzagentur mehr Unabhängigkeit einzuräumen“¹; Netzbetreiber befürchten Investitionsunsicherheit.

Für die aktuellen Netzentgelte der RLM-Kunden (abgesehen von atypischer Netznutzung) sind nur zwei Werte maßgeblich: die Arbeit (Gesamtstromverbrauch im Jahr) und die Leistung (individuelle Spitzenlast im Jahr). Diese Werte sind völlig unabhängig davon, wann und wo im Netz die Lastspitzen angefallen sind. Zur Festlegung der Netzentgelte müssen die Netzbetreiber eine Gleichzeitigkeitsfunktion anwenden. Der Gleichzeitigkeitsgrad repräsentiert die Wahrscheinlichkeit, dass die Einzelentnahme einen hohen Beitrag zur Jahreshöchstlast der jeweiligen Netz- bzw. Umspannebene leistet. Es wird angenommen, dass diese Wahrscheinlichkeit mit einer höheren Anzahl von Nutzungsstunden steigt. Die Gleichzeitigkeitsfunktion hat einen „Knick“ bei 2.500 Benutzungsdauern pro Jahr: unterhalb dieser Benutzungsdauer spielt der Leistungspreis (in Euro/kW/Jahr) eine geringere Rolle als der Arbeitspreis (in Ct/kWh). Für Abnehmer mit höheren Benutzungsdauern wird der Leistungspreis deutlich relevanter. Für Abnehmer rechts und links des „Knicks“ gelten also völlig unterschiedliche Anreizstrukturen zur Netznutzung.

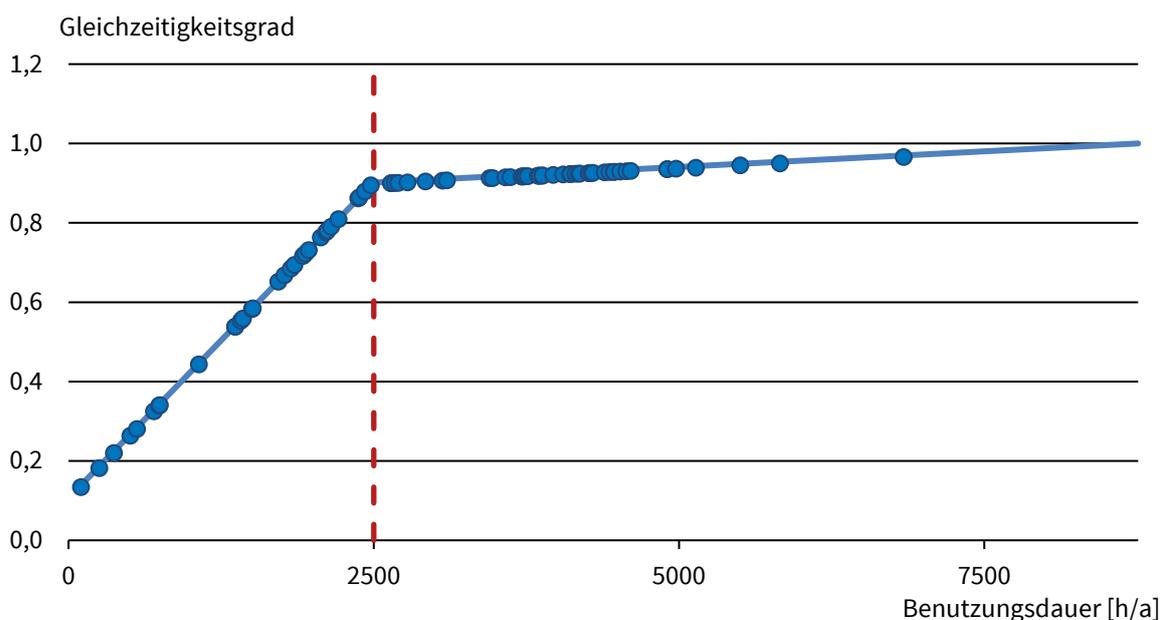
Abbildung 19 zeigt schematisch die entsprechende Funktion (dargestellt als Linie) für einen der teilnehmenden Verteilnetzbetreiber und die Position der Abnehmer rund um die Funktion (dargestellt mit Kreisen). Die Funktion lässt sich aus den Leistungs- und Arbeitspreisen des Netzbetreibers errechnen. Bei den Kreisen muss betont werden, dass die Werte approximiert sind: die

¹ Artikel auf ZEIT ONLINE abrufbar unter: <https://www.zeit.de/wirtschaft/2021-09/eugh-urteil-bundesnetzagentur-unabhaengigkeit-regulierung-energiemarkt-leitungskosten>.

Nutzungsstunden (x-Achse) werden als Verhältnis von Gesamtarbeit zu Leistung berechnet (entsprechend Stromnetzentgeltverordnung). Über die tatsächliche Gleichzeitigkeit der Abnehmer (y-Achse) haben wir keine Informationen, da wir nicht wissen, zu welcher Zeit die individuellen Lastspitzen angefallen sind. Deshalb sind die Kreise der einzelnen Abnehmer auf der Gleichzeitigkeitsfunktion abgetragen; in Wirklichkeit streuen sie stark um die Linie (vgl. Agora Energiewende 2021). Interessant ist aber die Frage, ob sich Abnehmer strategisch rechts oder links des „Knicks“ positionieren. Dies lässt sich auf Anhieb nicht eindeutig erkennen, auch wenn es eine leichte Häufung der Kreise knapp über 2.500 Benutzungsstunden gibt. Dies ließe auf eine leichte Präferenz für einen geringeren Arbeits- und höheren Leistungspreis schließen, also eine „glattere“ Nachfrage. Insgesamt bewegt sich aber zumindest auf dieser Netzebene die Mehrheit der Abnehmer in großem Abstand zum Bruch in der Anreizstruktur.

Abbildung 19: Gleichzeitigkeitsfunktion für die Netzentgeltkalkulation

Gleichzeitigkeitsfunktion



Quellen: Angaben eines bayerischen Verteilnetzbetreibers; Darstellung des ifo Instituts.

© ifo Institut

Bei Verfügbarkeit disaggregierter Verbrauchsdaten auf Abnehmerebene könnten die Auswirkungen aktueller Entgeltstrukturen genauer analysiert werden: bspw. könnten die individuellen Spitzenlasten auch zeitlich analysiert und mit relevanten Daten zu Strom- und Netzpreisen kombiniert werden. Darüber hinaus könnten die Auswirkungen alternativer Vorschläge für die Netzentgeltstruktur (wie Echtzeit- oder diverse Spitzenlast-basierte Preissysteme) analysiert werden. Eine solche Analyse kann wichtige Erkenntnisse für Tarifgestaltungs- und Netzausbauoptionen liefern.

3.3 Zusammenhang zwischen Stromverbrauch und Börsenstrompreisen

Eine vielversprechende Variable für die Vorhersage der Nachfrage könnten die Preise von Futures sein. Dafür wurden für das Jahr 2015 die Nachfragedaten der Netzbetreiber mit den Marktdaten von relevanten Futures verknüpft. In den folgenden Abbildungen sieht man die geschätzten Kleinstquadrat-Koeffizienten von einfachen linearen Modellen mit der Nachfrage als abhängiger Variable. Die Modellnummer bezieht sich auf die zugehörigen Regressionstabellen, wo mit aufsteigender Nummer für mehr Kovariablen kontrolliert wird. Man muss die Futures jedoch nach Differenz von Handelszeitpunkt und Lieferzeitpunkt unterscheiden. Deshalb gibt die Zahl im Variablennamen genau diese Differenz an (in Tagen bzw. Monaten). Zusätzlich werden Base- und Peak-Future-Preise unterschieden.

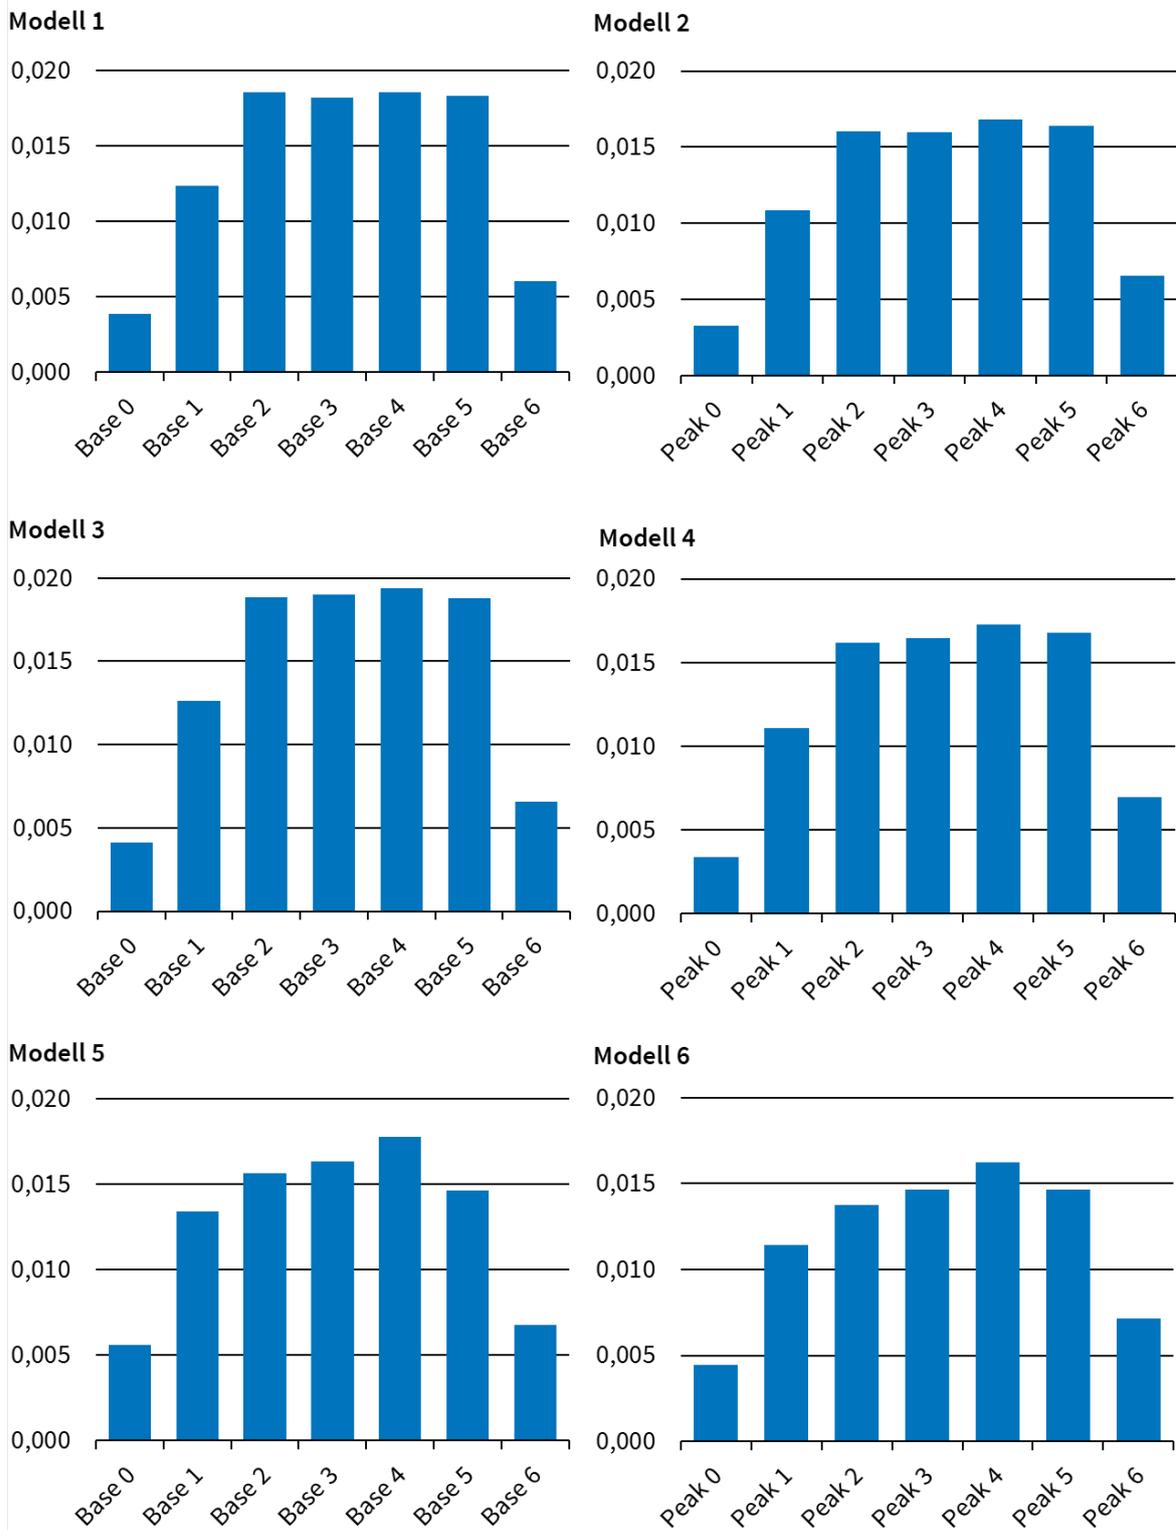
Bei den täglichen Daten (vgl. Abbildung 20) sieht man einen positiven Zusammenhang zwischen der Nachfrage und den Preisen, welcher 2-5 Tage vor dem Liefertag am stärksten zu sein scheint. Hier gibt es keine nennenswerten Unterschiede zwischen Base- und Peak-Future-Preisen. Bei den wöchentlichen Daten (vgl. Abbildung 21) sieht man einen leichten Unterschied zwischen Base- und Peak-Future-Preisen: bei ersteren ist der Zusammenhang eine Woche vor Lieferung am stärksten. Bei Letzteren hingegen sieht man den stärkeren Zusammenhang für die zweiwöchigen Futures. Für die monatlichen Daten (vgl. Abbildung 22) ergibt sich zumindest bei den Base-Future-Preisen ein ähnliches Bild. Für die Peak-Future-Preise in Modell 2 allerdings nicht, hier sieht man sogar zwei negative Koeffizienten. Die Aussagekraft der monatlichen Daten ist aufgrund der niedrigen Zahl an Beobachtungen jedoch sehr begrenzt.

Aus prognostischer Sicht wäre die Verwendung von monatlichen Termindaten zwar am vorteilhaftesten, da sie im Voraus verfügbar sind, aber aufgrund der Divergenz der geschätzten Koeffizienten für die monatlichen Daten zwischen Basis- und Spitzennachfrage sowie der geringen Anzahl von Beobachtungen ist diese Analyse nicht für die Prognose geeignet.

Abbildung 20: Geschätzte Koeffizienten der täglichen Future-Preise

Schätzungen für die täglichen Future-Preise

Koeffizienten



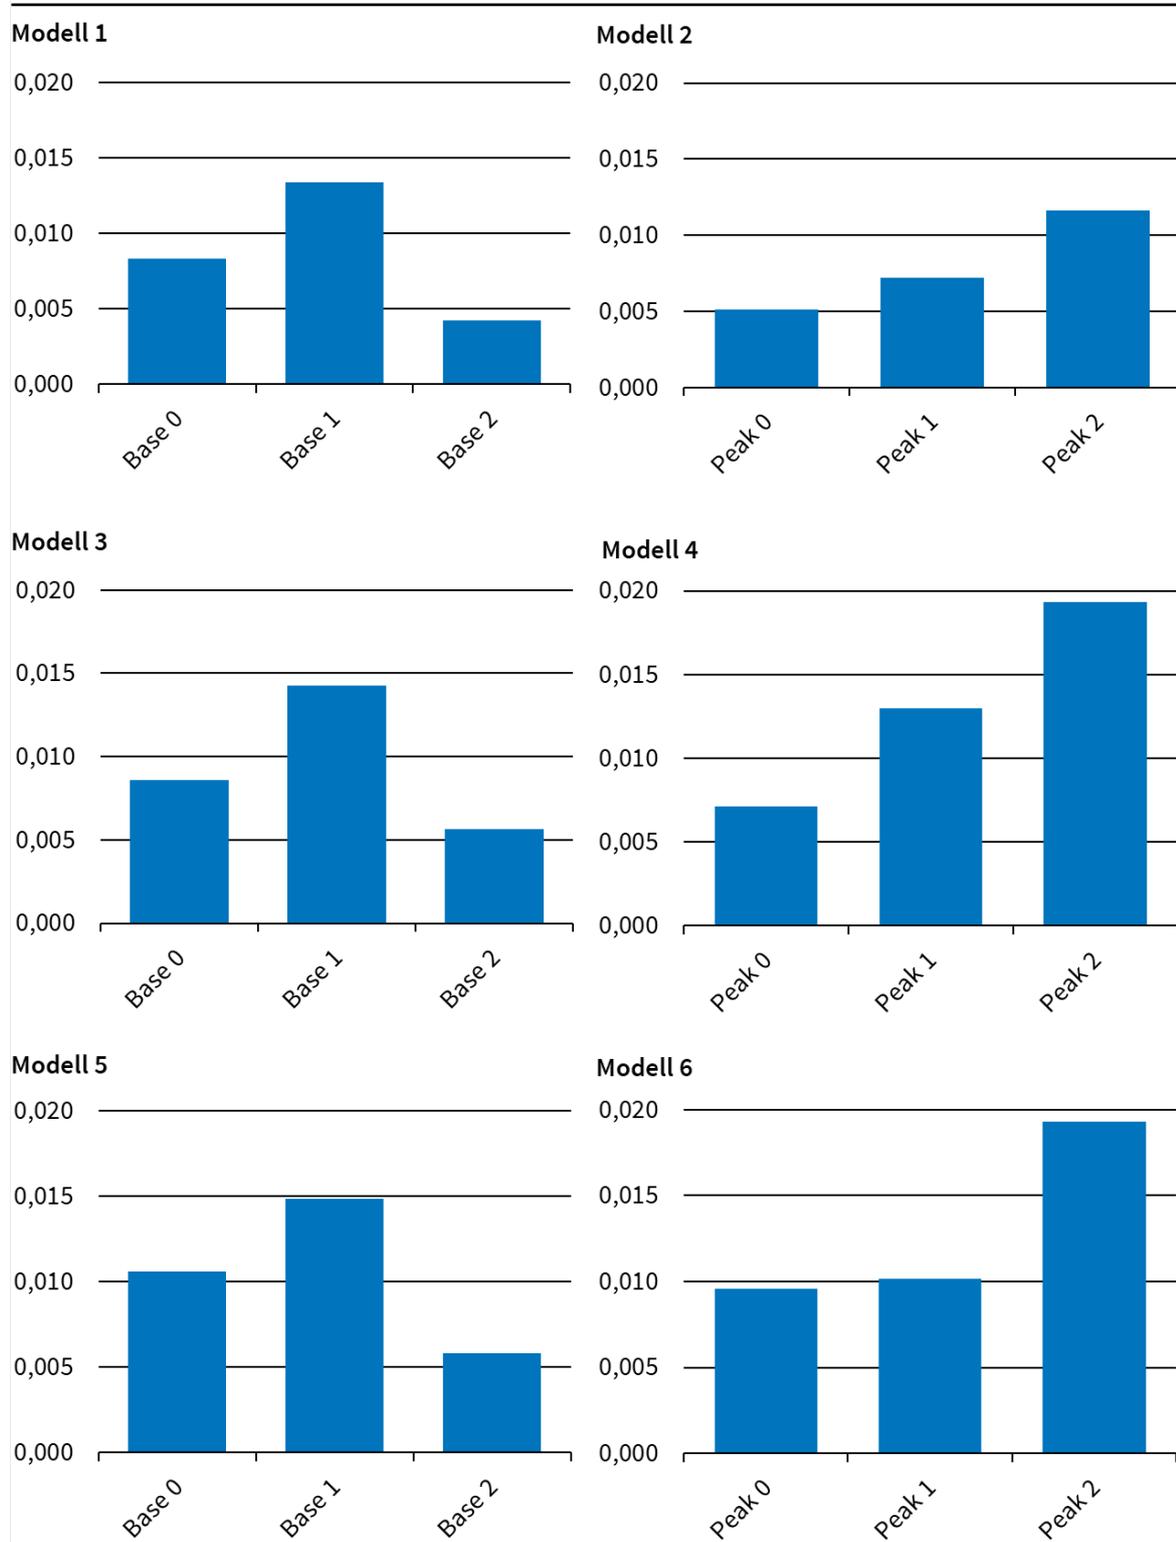
Quellen: Berechnung und Darstellung des ifo Instituts.

© ifo Institut

Abbildung 21: Geschätzte Koeffizienten der wöchentlichen Future-Preise

Schätzungen für die wöchentlichen Future-Preise

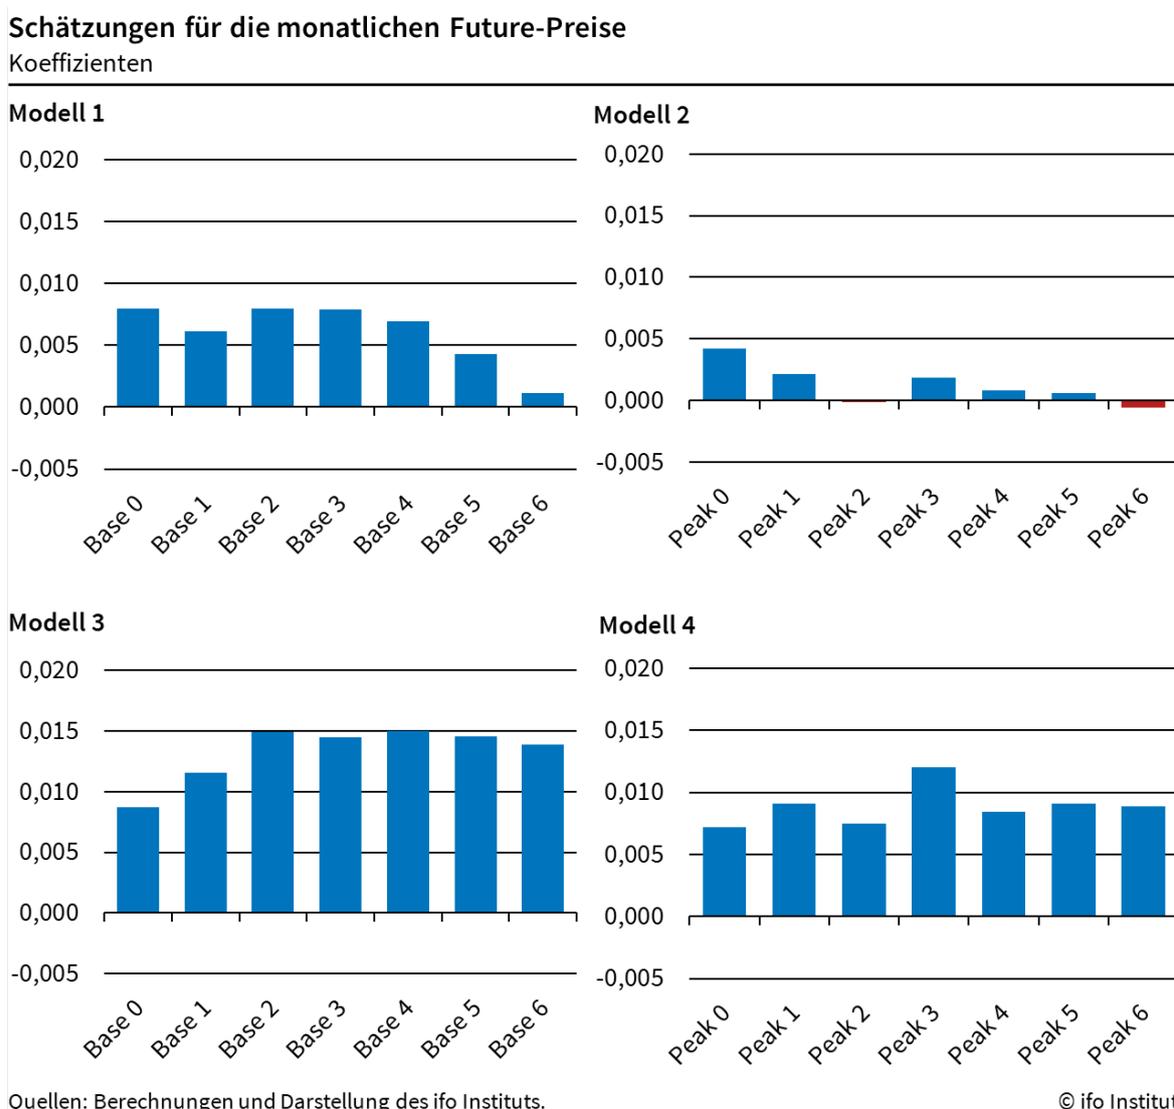
Koeffizienten



Quellen: Berechnung und Darstellung des ifo Instituts.

© ifo Institut

Abbildung 22: Geschätzte Koeffizienten der monatlichen Future-Preise



Zusätzlich zu den Futures-Daten untersuchen wir den Zusammenhang zwischen Day-Ahead-Strommarktpreisen und Stromverbrauch. Die Ergebnisse der Schätzung der Regressionen sind in Tabelle 2 aufgeführt. Unter Berücksichtigung von Kontrollvariablen wie Netzbetreiber, Zeitpunkt, Lufttemperatur, Sonneneinstrahlung etc. wird immer noch ein positiver und statistisch signifikanter Effekt beobachtet. Obwohl wir die Koeffizienten nicht kausal interpretieren können, zeigen die Schätzungen eine konsistente positive Beziehung zwischen den Day-Ahead-Strompreisen und der industriellen Stromnachfrage.

Tabelle 2: Auswirkungen des Preises auf die Nachfrage, stündliche Datenbasis

abhängige Variable: log(Stromnachfrage in MWh)						
Modell	(1)	(2)	(3)	(4)	(5)	(6)
<i>Variablen</i>						
log(Strompreis _{t-1}) ^a	0,06* (0,02)		0,07* (0,02)		0,06* (0,02)	
log(Strompreis _{t-2}) ^a		0,05* (0,02)		0,05* (0,02)		0,06* (0,02)
Temperatur ^a			0,02* (0,01)	0,02* (0,01)	0,02* (0,01)	0,02* (0,01)
Temperatur ^{2,a}			$-2 \times 10^{-4} **$ (7×10^{-5})	$-2 \times 10^{-4} **$ (7×10^{-5})	$-2 \times 10^{-4} **$ (7×10^{-5})	$-2 \times 10^{-4} **$ (7×10^{-5})
Sonneneinstrahlung, direkt			9×10^{-6} (3×10^{-5})	3×10^{-6} (3×10^{-5})	-3×10^{-5} (5×10^{-5})	$1 \times 10^{-4} **$ (3×10^{-5})
Sonneneinstrahlung, diffus			$5 \times 10^{-4} ***$ (6×10^{-5})	$5 \times 10^{-4} ***$ (6×10^{-5})	$5 \times 10^{-4} ***$ (6×10^{-5})	$5 \times 10^{-4} ***$ (6×10^{-5})
Einstrahlung × Strompreis _{t-1}					$1 \times 10^{-6} *$ (5×10^{-7})	
Einstrahlung × Strompreis _{t-2}						$-3 \times 10^{-6} **$ (6×10^{-7})
Zeitkonstante Effekte ^b	Ja	Ja	Ja	Ja	Ja	Ja
Beobachtungen	205.965	205.961	172.142	172.234	172.142	172.234
R ² (gesamt)	0,93	0,93	0,96	0,95	0,96	0,95
R ² (within)	0,04	0,03	0,36	0,34	0,36	0,34

Anmerkung: a) Angaben für Deutschland. b) Dummies für verschiedene Netze und Datumsangaben. Auf Netzebene geclusterte Standardfehler in Klammern. Koeffizienten signifikant von Null verschieden zum 1%-, 5%- oder 10%-Konfidenzniveau (***, **, *). Quellen: Berechnungen des ifo Instituts.

3.4 Zusammenhang zwischen Stromverbrauch und Luftverschmutzung

Ein weiterer wichtiger Bereich, der in der verfügbaren Literatur im Zusammenhang mit der Verbesserung der Energieeffizienz und des Stromverbrauchs häufig untersucht wird, sind die zusätzlichen Vorteile einer geringeren Luftverschmutzung (vgl. Yue et al. 2021). In diesem Zusammenhang konzentrieren sich die meisten Studien auf die Auswirkungen, die in einem bestimmten Industriezweig erzielt werden können – zum Beispiel in der Zement-, Papier- oder Stahlindustrie. Eine Studie von Zhang et al. (2015), die sich auf die Zementindustrie in China konzentriert, legt bspw. nahe, dass die Einführung von Energieeffizienzmaßnahmen dazu beitragen kann, bis 2030 5% der CO₂-, 3% der PM-, 15% der SO₂- und 12% der NO_x-Emissionen zu senken.

Auch wenn uns keine Informationen über die spezifischen Branchen der RLM-Kunden vorliegen, ist es dennoch interessant zu prüfen, wie viel ihr Stromverbrauch zur Luftverschmutzung beiträgt. Zu diesem Zweck haben wir die vier Hauptschadstoffe CO, NO₂, PM_{2,5} und PM₁₀ ausgewählt und die Auswirkungen des Stromverbrauchs auf jeden dieser Schadstoffe analysiert (vgl. Tabelle 3). Die Schätzergebnisse lassen sich wie folgt interpretieren: Die Stromnachfrage steht in einem positiven Zusammenhang mit allen Schadstoffen. Am stärksten ist die Auswirkung auf die NO₂-Belastung: der Anstieg des Stromverbrauchs um 1% geht mit einem durchschnittlichen Anstieg der NO₂-Belastung um 0,15% einher. Daher kann für künftige Untersuchungen, die auf disaggregierten Daten beruhen und die Einführung von Energieeffizienzmaßnahmen für Industriekunden analysieren, auch ein positiver Zusatznutzen in Form einer geringeren Luftverschmutzung erwartet werden.

Tabelle 3: Auswirkungen der Stromnachfrage auf die Luftverschmutzung

abhängige Variable	log(CO)	log(NO ₂)	log(PM _{2,5})	log(PM ₁₀)
	<i>Variablen</i>			
Konstante	-1,65*** (0,01)	2,24*** (0,01)	2,19*** (0,01)	2,32*** (0,01)
log(Stromnachfrage in MWh)	0,10*** (1 × 10 ⁻³)	0,12*** (1 × 10 ⁻³)	0,05*** (2 × 10 ⁻³)	0,09*** (2 × 10 ⁻³)
Temperatur ^a	-0,02*** (7 × 10 ⁻⁵)	-0,01*** (9 × 10 ⁻⁵)	-0,02*** (1 × 10 ⁻⁴)	-0,01*** (1 × 10 ⁻⁴)
Beobachtungen	280.483	280.483	280.483	280.483
adj. R ²	0,21	0,11	0,08	0,05

Anmerkung: a) Angaben für Deutschland. Standardfehler in Klammern. Koeffizienten signifikant von Null verschieden zum 1%-, 5%- oder 10%-Konfidenzniveau (***, **, *). Quellen: Berechnungen des ifo Instituts.

4 Stromverbrauch und Konjunktur

Im folgenden Abschnitt wird der Frage nachgegangen, ob die Stromverbrauchsdaten der bayerischen VNB zu einer gleichen bzw. ähnlichen Datierung der Konjunkturzyklen führen wie die bayerische Industrieproduktion. Hierfür wird zunächst der verwendete Datierungsalgorithmus eingeführt und in Grundzügen beschrieben. Im Anschluss wird die Zyklendatierung der Industrieproduktion und des Stromverbrauchs näher beleuchtet; der Abschnitt schließt mit einer Diskussion zur Konkordanz der beiden individuell extrahierten Konjunkturzyklen.

4.1 Grundzüge des Datierungsalgorithmus

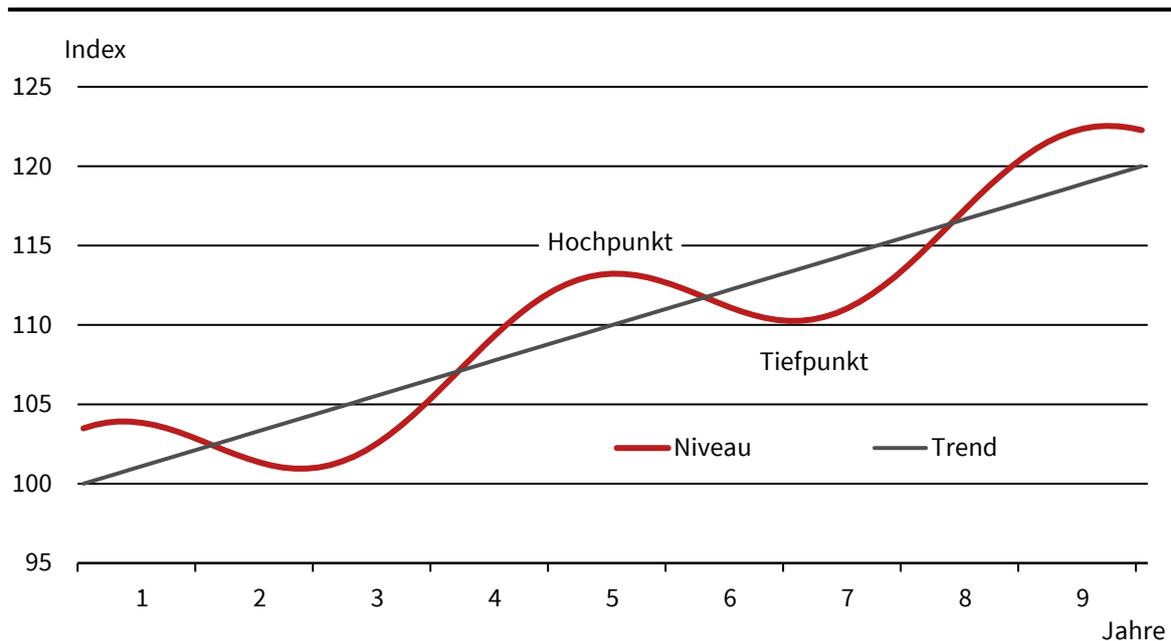
Die Datierung der konjunkturellen Grunddynamik einer Volkswirtschaft bzw. eines ökonomischen Indikators ist sowohl für die angewandte Konjunkturanalyse und -prognose als auch wirtschaftspolitische Entscheidungsträger von wichtiger Bedeutung. So haben sich in der akademischen Literatur eine Handvoll Datierungsalgorithmen herausgebildet, welche u.a. in parametrische und nicht-parametrische Ansätze eingeteilt werden können (vgl. Harding und Pagan 2003). Während erstere Klasse ökonometrische Herangehensweisen wie bspw. Markov-Switching-Modelle umfasst, basieren nicht-parametrische Methoden auf mehr oder weniger einfachen Entscheidungsregeln¹ oder visuellen Inspektionen der zu untersuchenden Größen. Für die vorliegende Forschungsfrage entscheiden wir uns für den nicht-parametrischen Datierungsalgorithmus nach Bry und Boschan (1971), da dieser – im Sinne der externen Replizierbarkeit – recht simpel, transparent und leicht nachvollziehbar ist. Zudem zeigen Harding und Pagan (2003), dass der nicht-parametrische Ansatz sehr gute und robuste Ergebnisse (z.B. durch Hinzunahme neuer Beobachtungen) im Vergleich zu parametrischen Herangehensweisen generiert.

Der Bry-Boschan-Algorithmus modelliert die Schwankungen der wirtschaftlichen Aktivität als sogenannten klassischen Konjunkturzyklus, d.h. das Niveau der zu untersuchenden Größe wird betrachtet. Im Gegensatz dazu ist der Wachstumszyklus definiert als Abweichung der aktuellen wirtschaftlichen Aktivität von einem trendmäßigen bzw. potentiellen Aktivitätsniveau (siehe bspw. Abberger und Nierhaus 2007). Wir folgen hier der Empfehlung von Harding und Pagan (2002) und untersuchen das Niveau des Stromverbrauchs bzw. der bayerischen Industrieproduktion. Maßgeblich hierfür ist, dass der Trend einer Zielgröße eine unbekannte Größe ist und die Schätzung bzw. Filterung dieser Größe das Ergebnis der Zyklendatierung erheblich beeinflussen kann. Abbildung 23 zeigt die schematische Darstellung eines klassischen Konjunkturzyklus. Hierbei steigt das Aktivitätsniveau über die Zeit hinweg trendmäßig an, wenngleich sich regelmäßige Schwankungen im Ausstoß ergeben. Phasen mit steigender Wirtschaftsaktivität werden anschließend abgelöst von Zeiträumen, in denen das Niveau der wirtschaftlichen Aktivität sinkt.

¹ Dazu zählt auch die so genannte „technische Rezession“, welche immer wieder in der öffentlichen Debatte vorkommt. Eine technische Rezession liegt genau dann vor, wenn bspw. das BIP zweimal in Folge rückläufig ist.

Abbildung 23: Schematische Darstellung eines klassischen Konjunkturzyklus

Niveau der wirtschaftlichen Aktivität



Quellen: Darstellung des ifo Instituts.

© ifo Institut

Im Rahmen des Bry-Boschan-Algorithmus wird der Konjunkturzyklus in ein 2-Phasen-Schema unterteilt, wobei sich Aufschwünge (Phasen zunehmender wirtschaftlicher Aktivität) und Abschwünge (Phasen abnehmender Wirtschaftsaktivität) nacheinander abwechseln. Dabei müssen die Ausschläge und Längen der Phasen keineswegs konstant über die Zeit sein. Verbunden miteinander werden die beiden Phasen durch den Hochpunkt („peak“) und den Tiefpunkt („trough“), d.h. der Aufschwung endet mit dem Hochpunkt, während der Abschwung sein Ende im Tiefpunkt findet. Ein kompletter Zyklus liegt vor, wenn alle Phasen genau einmal durchlaufen sind. Das Ziel des Algorithmus ist es nun, die Hoch- und Tiefpunkte zu identifizieren und damit den Zyklus einer Größe zu datieren.

Gemäß Harding und Pagan (2002) muss ein Algorithmus generell drei Anforderungen erfüllen. Erstens ist es natürlich wichtig, dass der gewählte Ansatz eine gewisse Anzahl von Hoch- und Tiefpunkten in einer Zielgröße entdeckt. Zweitens sollten sich die Hoch- und Tiefpunkte voneinander unterscheiden und im Zeitverlauf schwanken. Die dritte Anforderung umfasst die Einhaltung zuvor spezifizierter Regeln (so genannte „censoring rules“), so dass die identifizierten Hoch- und Tiefpunkte einen Zyklus datieren, dessen Phasen gewissen Mindestanforderungen entsprechen. Der Bry-Boschan-Algorithmus erfüllt genau diese Bedingungen.

Der ursprüngliche Algorithmus von Bry und Boschan (1971) wurde für Daten in monatlicher Frequenz konzipiert. Harding und Pagan (2002) erweiterten den Ansatz zur Anwendung für Quartalsdaten, weshalb der Algorithmus in der akademischen Literatur meist als BBQ-Algorithmus abgekürzt wird. Das Ziel ist es, lokale Maxima (Hochpunkte) und Minima (Tiefpunkte) zu identifizieren. Ein lokaler Hochpunkt im Aktivitätsniveau zum Zeitpunkt t liegt genau dann vor, wenn die wirtschaftliche Aktivität eine gewisse Zeit vor und nach dem Hochpunkt ($t \pm k$) niedriger ausfällt. Das Gegenteil ergibt sich für einen lokalen Tiefpunkt: dieser liegt zum Zeitpunkt t genau dann vor, wenn das Aktivitätsniveau eine gewisse Zeit davor und danach nicht unterhalb des Niveaus des lokalen Tiefpunkts sinkt (vgl. die mathematische Repräsentation im Anhang). Darüber hinaus müssen die beiden Phasen Auf- und Abschwung eine gewisse Zeit andauern und ein kompletter Zyklus darf eine Mindestdauer nicht unterschreiten.

Bei der vorliegenden Anwendung für den bayerischen Stromverbrauch und die bayerische Industrieproduktion orientieren wir uns an den gesetzten Standardwerten aus der angewandten Literatur (vgl. Harding und Pagan 2002, 2003 für Anwendungen auf amerikanische Daten; Schirwitz 2009 für eine Zyklendatierung des deutschen BIP).¹ So beträgt die Zeitspanne, welche den lokalen Hoch- und Tiefpunkt definiert, $k = 2$ Quartale. Darüber hinaus müssen Aufschwünge und Abschwünge mindestens zwei Quartale anhalten und ein kompletter Zyklus muss mindestens fünf Quartale andauern. Auf Basis dieser Setzungen kann nunmehr eine Zyklendatierung für jede ökonomische Kenngröße vorgenommen werden. Daran wird deutlich, dass der Algorithmus simpel, leicht nachvollziehbar und vor allem robust ist. Die Zyklendatierung ist dabei unabhängig von der Anzahl der Beobachtungen, was als Vorteil gegenüber parametrischen Verfahren gewertet werden kann. Jedoch wohnt den Setzungen der eben beschriebenen Standardwerte eine gewisse Beliebigkeit inne. Da unser Ziel aber ist zu untersuchen, ob der bayerische Stromverbrauch den gleichen Konjunkturzyklus wie die Referenzgröße – die Industrieproduktion Bayerns – aufweist, stellen wir für beide Größen die gleichen Standardwerte ein. Der anschließende relative Vergleich sollte dieses Problem zumindest teilweise abmildern.

Trotz der Verfügbarkeit des Algorithmus auf Monatsebene haben wir uns für die Transformation zu Quartalsdaten entschieden. Diese Entscheidung fußt auf mehreren Gründen und ist vor allem durch die Aufsätze von Schirwitz et al. (2009a, b, c) motiviert. Diese Aufsatzserie enthält die einzig uns bekannte Zyklendatierung auf der Ebene der deutschen Bundesländer und widmet sich den länderspezifischen Zyklen der Umsätze im Verarbeitenden Gewerbe. Der erste Grund liegt in der Saison- und Kalenderbereinigung der monatlichen Angaben, die u.U. eine hohe Volatilität in den Zeitreihen erzeugt. Zwar haben wir selbst eine Bereinigung der Daten vorgenommen, jedoch entsprechen unsere Saison- und Kalenderfaktoren keinen offiziellen Angaben seitens der amtlichen Statistik; für die Stromverbrauchsdaten gibt es zudem keinerlei amtliches Vorbild. Der zweite Grund liegt in der kleinräumigen Betrachtung der Untersuchung. Kleinere Aggregate schwanken

¹ Die Zyklendatierung wurde mit dem von James Engel bereitgestellten modifizierten BBQ-Algorithmus durchgeführt. Der entsprechende Matlab-Code kann unter folgendem Link heruntergeladen werden: <http://www.ncer.edu.au/resources/data-and-code.php>.

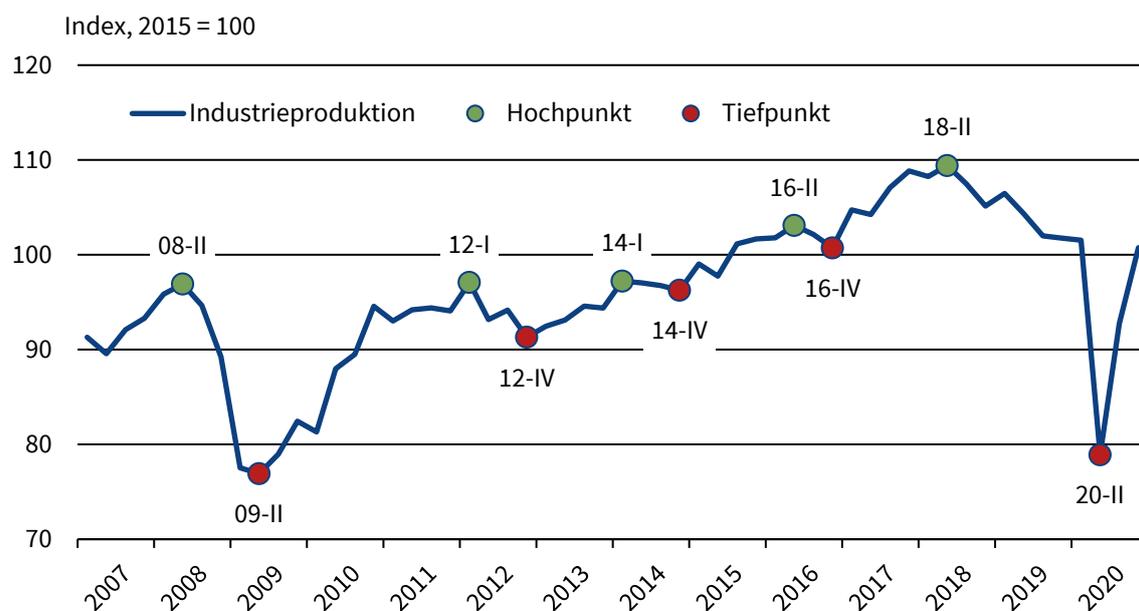
naturgemäß deutlich stärker als Größere. Schirwitz et al. (2009b) motivieren dies mit der Bearbeitung von länderspezifischen Großaufträgen in der Industrie. Sofern Großaufträge in unterschiedlichen Zeitintervallen oder -abfolgen bearbeitet werden, dürfte das die Schwankungen einer gesamtdeutschen Zeitreihe kaum berühren, während sich schon allein dadurch die Volatilitäten auf der Ebene der Bundesländer erheblich voneinander unterscheiden dürften. Demnach treffen so genannte irreguläre Einflüsse die Bundesländer deutlich intensiver als Deutschland insgesamt. Der letzte Grund ist durch die Aussagen von Bry und Boschan (1971) selbst motiviert. Die Autoren schlagen selbst eine Glättung der Monatsreihen im Vorfeld der Datierung vor („smoothing“), um der starken Schwankungsanfälligkeit entgegen zu wirken. Mögliche Ansätze könnten hier z.B. gleitende Monatsdurchschnitte mit unterschiedlichen Längen oder Extremwertbereinigungen sein. Da auch bei der Glättung erheblicher Spielraum des Anwenders besteht und diese unmittelbar die Datierung tangieren, ist die Aggregation zu Quartalsdaten die objektivste Vorgehensweise und sollte einen Großteil möglicher Probleme auffangen.

4.2 Referenzzyklus der bayerischen Industrieproduktion

Die Zyklusdatierung der bayerischen Industrieproduktion im Zeitraum 2007 bis 2020 ist in Abbildung 24 dargestellt. Der erste Hochpunkt findet sich im zweiten Quartal 2008 (08-II) und damit kurz vor dem Ausbruch der Wirtschafts- und Finanzkrise 2008/2009. Der daran anschließende Tiefpunkt folgt im zweiten Quartal 2009 (09-II), also im gleichen Zeitraum exakt ein Jahr später.

Abbildung 24: Zyklusdatierung Industrieproduktion Bayern

Saison- und kalenderbereinigter Produktionsindex, Hoch- und Tiefpunkte



Anmerkung: Hoch- und Tiefpunkte beschriftet mit Jahres- und Quartalsangaben (JJ-Q).

Quellen: Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

Der Abschwung der Produktionstätigkeit in der bayerischen Industrie umfasst dabei in etwa den gleichen Zeitraum wie die Phaseneinteilung der Gemeinschaftsdiagnose für das deutsche BIP ergeben hat (vgl. Projektgruppe Gemeinschaftsdiagnose 2018). Zudem ist der hier gefundene erste Hochpunkt identisch mit dem oberen Wendepunkt aus Schirwitz et al. (2009b) für die Umsätze des bayerischen Verarbeitenden Gewerbes. Die Untersuchung von Schirwitz et al. (2009b) endet mit dem Jahr 2008, so dass an dieser Stelle keine weiteren Vergleiche mit der Literatur mehr angestellt werden können. Die drei folgenden Zyklen im Nachgang der Wirtschafts- und Finanzkrise 2008/2009 mit den Hochpunkten im ersten Quartal 2012 (12-I), dem ersten Quartal 2014 (14-I) und dem zweiten Quartal 2016 (16-II) sowie den Tiefpunkten im jeweils vierten Quartal der Jahre 2012, 2014 und 2016 dürften im sich wiederholenden Aufblähen der Eurokrise zu sehen sein. Die Projektgruppe Gemeinschaftsdiagnose (2018) datiert annähernd gleiche Hoch- und Tiefpunkte für das deutsche BIP, wenngleich gesamtdeutsch kein Zwischentief und kein Zwischenhoch wie in Bayern in den Jahren 2014 und 2016 zu beobachten ist. Der industrielle Aufschwung in der bayerischen Industrie fand im zweiten Quartal 2018 (18-II) seinen zwischenzeitlichen Hochpunkt und trat im Anschluss in die Phase des Abschwungs ein. Den Tiefpunkt erreichte die wirtschaftliche Aktivität in der bayerischen Industrie im zweiten Quartal 2020 (20-II), welches maßgeblich von der ersten Corona-Welle bestimmt ist.

Im Durchschnitt dauert ein Aufschwung in der bayerischen Industrie sieben Quartale, mit einem durchschnittlichen Zuwachs von 11,2%. Der kumulierte Anstieg der Aufschwünge beträgt knapp 62%. Ein mittlerer Abschwung in der bayerischen Industrie ist mit vier Quartalen zwar etwas kürzer als ein durchschnittlicher Aufschwung. Jedoch sind die Verluste etwas ausgeprägter: im Durchschnitt sinkt die bayerische Industrieproduktion um -13,1%. Dieses Ergebnis verwundert nicht, da der hier betrachtete Zeitraum der Jahre 2007 bis 2020 die zwei schwersten Rezessionen der Nachkriegsgeschichte Deutschlands umfasst. Da die Abschwünge jedoch recht kurzfristiger Natur sind, beträgt der kumulierte Verlust über den betrachteten Zeitraum nur -28,4% und damit absolut gesehen deutlich weniger als die kumulierten Zuwächse in den Aufschwüngen. Nachfolgend werden die verschiedenen Kennziffern des Konjunkturzyklus der bayerischen Industrieproduktion mit jenen für den bayerischen Stromverbrauch verglichen.

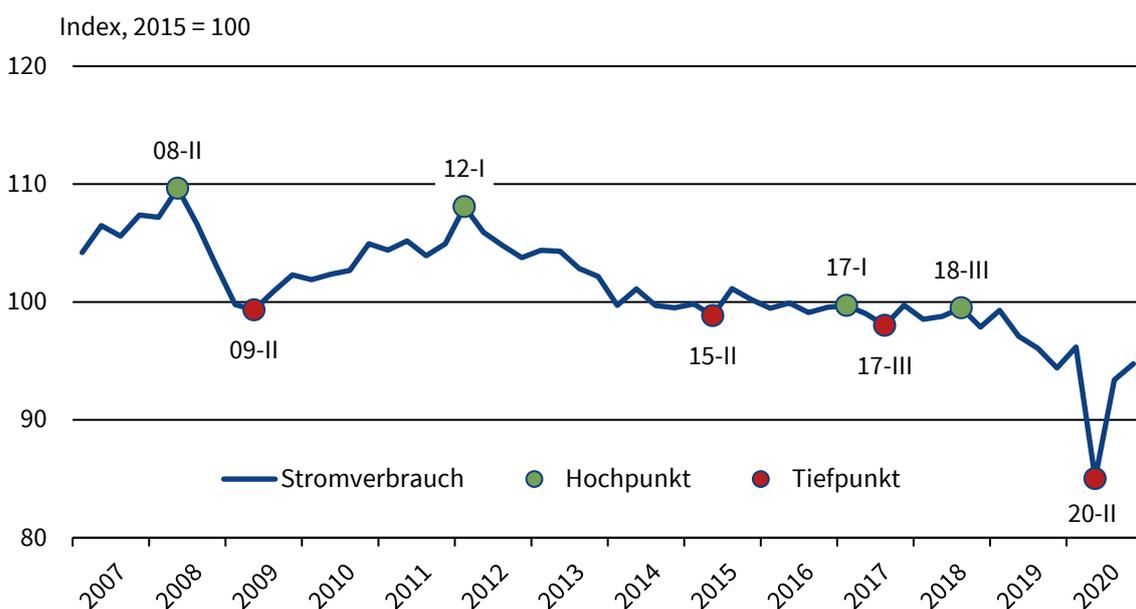
4.3 Zyklusdatierung Stromverbrauch Bayern

Die Zyklusdatierung für die bayerischen Stromverbrauchsdaten wird im Folgenden ausschließlich auf Basis zweier VNB betrachtet, da die Zeitreihe zum Stromverbrauch aller vier VNB für diese Anwendung zu kurz ist. Ansonsten kann leider nicht garantiert werden, dass der Algorithmus aussagekräftige Ergebnisse liefert. Abbildung 25 präsentiert den bayerischen Stromverbrauch für die Jahre 2007 bis 2020 – zur besseren Lesbarkeit indexiert auf den Jahresdurchschnitt 2015 – und die dazugehörigen Hoch- und Tiefpunkte auf Basis des BBQ-Algorithmus. Der erste Konjunkturzyklus umfasst den Hochpunkt im zweiten Quartal 2008 (08-II) und den Tiefpunkt im zweiten Quartal 2009 (09-II). Damit ist dieser erste Zyklus identisch zur bayerischen Industrieproduktion,

so dass der Stromverbrauch die wirtschaftlichen Verwerfungen im Zuge der Wirtschafts- und Finanzkrise 2008/2009 zuverlässig anzeigt. Der zweite Hochpunkt beim Stromverbrauch ist abermals identisch zur Industrieproduktion und wird auf das erste Quartal 2012 (12-I) datiert. Der Zyklus der Industrieproduktion im Jahr 2014 wird vom Stromverbrauch hingegen nicht angezeigt.

Abbildung 25: Zyklusdatierung Stromverbrauch Bayern, zwei VNB

Saison- und kalenderbereinigter Stromverbrauch, Hoch- und Tiefpunkte



Anmerkung: Hoch- und Tiefpunkte beschriftet mit Jahres- und Quartalsangaben (JJ-Q).

Quellen: Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

Der nächste Tiefpunkt in den Stromverbrauchsdaten ist auf das zweite Quartal 2015 (15-II) datiert. Ein dritter Zyklus findet sich im Jahr 2017 und damit etwas später als bei der Industrieproduktion. Der anschließende Aufschwung im Stromverbrauch dauert bis zum dritten Quartal 2018 (18-III) an, so dass der Hochpunkt annähernd identisch zur bayerischen Produktion ist. Im Anschluss schwenkt der bayerische Stromverbrauch in einen längeren Abschwung ein, der – analog zur Industrieproduktion – seinen Tiefpunkt im zweiten Quartal 2020 und damit in der ersten Corona-Welle findet.

Ein durchschnittlicher Aufschwung im bayerischen Stromverbrauch dauert etwas mehr als sieben Quartale und damit geringfügig länger als bei der bayerischen Industrieproduktion. Im Mittel steigt der Stromverbrauch im Aufschwung 3,6% und der kumulierte Zuwachs beträgt 20%. Damit sind die Aufschwünge in ihrer Intensität deutlich geringer ausgeprägt im Vergleich zur Industrieproduktion Bayerns. Auch das verwundert nicht, wenn die beiden Zeitreihen visuell miteinander verglichen werden. Während die Industrieproduktion trendmäßig über die Zeit zulegt, nimmt der Stromverbrauch in der Tendenz ab. Die Verluste in den Abschwüngen sind beim Stromverbrauch

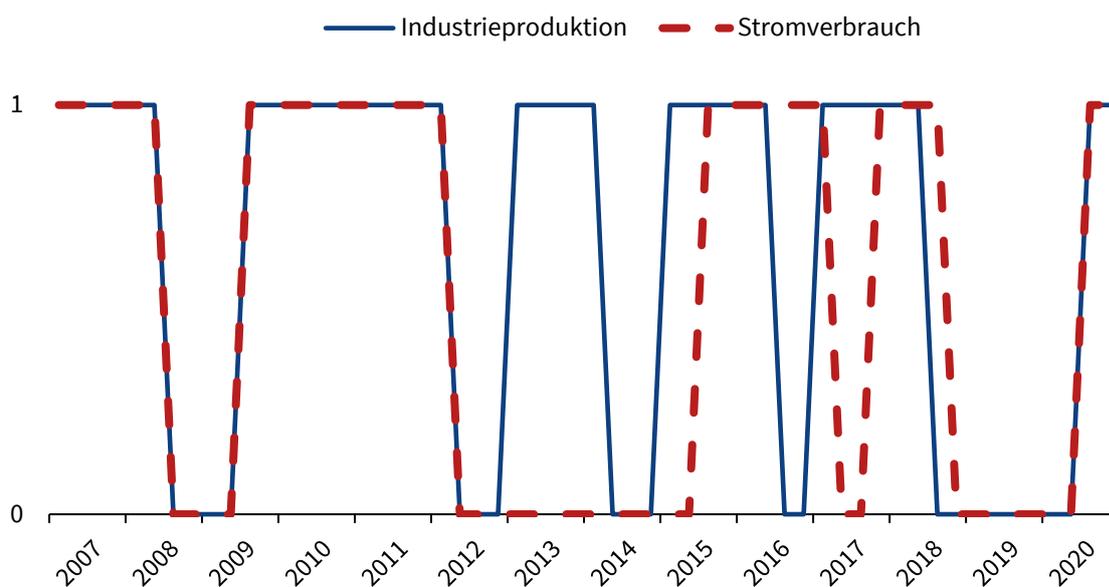
deutlich ausgeprägter verglichen mit den eigenen Aufschwungphasen. Im Mittel sinkt der Stromverbrauch im Abschwung um -9,1%; der Rückgang ist aber etwas geringer ausgeprägt als bei der Produktion (-13,1%). Die kumulierten Verluste im Abschwung belaufen sich auf -34,4%. Insgesamt liefert der Stromverbrauch wichtige und zuverlässige Anhaltspunkte über den Konjunkturverlauf der bayerischen Industrieproduktion. Insbesondere schwere und tiefe Rezessionen (2008/2009 und die erste Corona-Welle), gefolgt von kräftigen Erholungsphasen, zeigen die Stromverbrauchsdaten zuverlässig an. Die Überlappung bzw. Konkordanz der beiden Konjunkturzyklen wird – neben der Datierung – im folgenden Abschnitt untersucht.

4.4 Konkordanz zwischen den Konjunkturzyklen

Ausgehend von den visuellen Datierungen aus den vorhergehenden Abschnitten wird nachfolgend untersucht, ob sich die Konjunkturphasen der Industrieproduktion und des Stromverbrauchs überlappen. Je höher die Überlappung ausfällt, desto mehr gleichen sich die beiden Konjunkturzyklen. Abbildung 26 gibt einen ersten visuellen Eindruck der Phasenüberlappung. Die Linien im Diagramm nehmen den Wert 1 an, wenn die entsprechende Größe sich im Aufschwung befindet; der Wert 0 entspricht dem Abschwung. Die Sprungstellen, an denen die Linien im Diagramm entweder in den Auf- oder Abschwung wechseln, entsprechen exakt den datierten Hoch- und Tiefpunkten aus Abbildung 24 und Abbildung 25.

Abbildung 26: Phasenüberlappung zwischen Industrieproduktion und Stromverbrauch

Auf- und Abschwungphasen



Anmerkung: Aufschwung = 1, Abschwung = 0.

Quellen: Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

Bis zum Ende des Jahres 2012 laufen beide Phasendiagramme komplett identisch. Im Anschluss daran zeigt sich bei der bayerischen Industrieproduktion ein zusätzlicher Konjunkturzyklus, während die Stromverbrauchsdaten in der Abschwungphase verharren. Ab dem Jahr 2015 nimmt die Synchronität tendenziell wieder zu, wenngleich die Stromverbrauchsdaten etwas zeitverzögert reagieren. Mit dem zweiten / dritten Quartal 2018 herrscht zwischen den beiden Konjunkturzyklen schließlich wieder perfekte Konkordanz.

Um den Grad der Konkordanz in einer Kennziffer auszudrücken, wird nachfolgend das Maß der Phasenüberlappung („concordance index“) nach Harding und Pagan (2002) berechnet. Schirwitz et al. (2009b) verwenden dieses Maß ebenfalls zur Bestimmung des Grads der Konvergenz zwischen den bundeslandspezifischen Konjunkturzyklen. Das Maß der Phasenüberlappung kann auch als Ausdruck für den Gleichlauf („co-movement“) zweier Konjunkturzyklen interpretiert werden. Es ist definiert als das Verhältnis derjenigen Zeitpunkte, in denen beide Kenngrößen sich in der gleichen Konjunkturphase befinden, zur Gesamtheit der betrachteten Zeitpunkte (für die mathematische Repräsentation vgl. Anhang). Die Phasenüberlappung nimmt den Wert Eins an, wenn beide Kenngrößen exakt prozyklisch zueinander verlaufen, d.h. alle Phasen sowie Hoch- und Tiefpunkte sind identisch. Dem Maß wird der Wert Null zugeordnet, wenn beide Kenngrößen exakt antizyklisch zueinander verlaufen, d.h. ist Kenngröße A im Aufschwung, befindet sich Kenngröße B parallel dazu im Abschwung. Tabelle 4 zeigt die indicatorspezifischen Maße der Phasenüberlappung mit dem Konjunkturzyklus der bayerischen Industrieproduktion.

Tabelle 4: Phasenüberlappung der einzelnen Indikatoren mit dem Konjunkturzyklus der Produktion

Indikator	Maß der Phasenüberlappung
Stromverbrauch Bayern, zwei VNB	0,79
Auftragseingang Verarbeitendes Gewerbe Bayern	0,50
ifo Geschäftslage Verarbeitendes Gewerbe Bayern	0,71
ifo Geschäftsklima Verarbeitendes Gewerbe Bayern	0,66
ifo Geschäftserwartungen Verarbeitendes Gewerbe Bayern	0,61
ifo Produktionstätigkeit Verarbeitendes Gewerbe Bayern	0,70
ifo Produktionspläne Verarbeitendes Gewerbe Bayern	0,61
Stromverbrauch Deutschland	0,75
Lkw-Maut-Fahrleistungsindex	0,79

Quellen: N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG, ifo Konjunkturumfrage Bayern, ENTSO-E, Bundesnetzagentur SMARD, Bayerisches Landesamt für Statistik, Statistisches Bundesamt; Berechnungen des ifo Instituts.

Der bayerische Stromverbrauch sowie der Lkw-Maut-Fahrleistungsindex zeigen beide den höchsten Grad der Phasenüberlappung mit jeweils einem Maß von 0,79. Dahinter folgenden der Stromverbrauch Deutschlands (0,75), die ifo Geschäftslage im Verarbeitenden Gewerbe Bayern (0,71) und die ifo Produktionstätigkeit im Verarbeitenden Gewerbe Bayern (0,70). Besonders letztere Ergebnisse stechen heraus, da die Umfragedaten auf qualitativen Angaben beruhen, während die Stromverbräuche sowie der Lkw-Maut-Fahrleistungsindex quantitativ gemessen sind. Verwunderlich ist auch nicht, dass die Maße der Phasenüberlappung für die restlichen drei ifo Indikatoren zwar absolut sehr hohe aber etwas geringere Werte als die anderen Umfrageindikatoren annehmen. Bei diesen drei Indikatoren handelt es sich um Vorlaufindikatoren, welche das wirtschaftliche Geschehen bereits früher anzeigen sollen. Da es sich beim Maß der Phasenüberlappung aber um eine Kennziffer für den Gleichlauf handelt, müssen diese Indikatoren zwangsläufig etwas schlechter abschneiden. Demzufolge ist der niedrigere Wert bei der Phasenüberlappung der drei ifo Indikatoren kein Ausdruck für fehlende Güte dieser, sondern vielmehr für deren Eigenschaft konjunkturelle Phasenwechsel bereits frühzeitig anzuzeigen. Der Auftragseingang schneidet mit einem Wert von 0,50 insgesamt am schlechtesten ab.

Insgesamt bleibt festzuhalten, dass der bayerische Stromverbrauch – in Ergänzung zu den anderen bereits verfügbaren Indikatoren – eine nützliche Kenngröße für die konjunkturelle Entwicklung der bayerischen Industrieproduktion darstellt. Besonders die schweren und tiefen Rezessionen sowie die sich anschließenden Erholungsphasen können mit den Stromverbrauchsdaten datiert werden. Sofern die amtliche Statistik (oder entsprechende andere Stellen) darüber hinaus offiziell saison- und kalenderbereinigte Werte veröffentlichen würde, ist es durchaus denkbar, dass das bereits sehr gute Ergebnis aus diesem Abschnitt nochmals besser ausfällt.

5 Prognosetauglichkeit

Im folgenden Abschnitt wird die Prognosetauglichkeit der bayerischen Stromverbrauchsdaten für die bayerische Industrieproduktion untersucht und mit den prognostischen Eigenschaften weiterer zur Verfügung stehender Konjunkturindikatoren verglichen. Zunächst wird hierfür ein kurzer Literaturüberblick über aktuelle wissenschaftliche Artikel gegeben, die sich mit Prognosen unter Zuhilfenahme neuer, hochfrequenter und damit unkonventioneller Indikatoren beschäftigen. Danach wird der Aufbau des in diesem Bericht etablierten Prognoseexperiments näher beschrieben und die allgemeine Vorgehensweise präsentiert. Daran anschließend werden die Prognoseergebnisse auf der Basis von Monatsdaten diskutiert. Die hochfrequente Natur der Stromverbrauchsdaten erlaubt zudem eine Analyse der prognostischen Eigenschaften auf Wochenbasis, welche im vorletzten Unterabschnitt durchgeführt wird. Den Abschluss dieses Abschnitts bilden Schlussfolgerungen für die angewandte Prognose.

5.1 Unkonventionelle Konjunkturindikatoren in der akademischen Prognoseliteratur

Im Zuge der sich rasch veränderten konjunkturellen Lage während der Corona-Krise hat sich der Trend hin zu unkonventionellen und höherfrequenten Konjunkturindikatoren zur frühzeitigen Prognose der wirtschaftlichen Entwicklung beschleunigt. Nachfolgend wird eine Zusammenfassung zu den in der Literatur verwendeten unkonventionellen Indikatoren gegeben, welche in Tabelle 5 dargestellt ist.¹

Im internationalen Kontext können diese unkonventionellen Indikatoren in fünf Kategorien eingeteilt werden: Energiedaten, Verkehrsdaten, Finanztransaktionsindikatoren, Internetsuchanfragen und Zeitungsnachrichten. In Studien mit Energiedaten werden in der Regel der Strom- oder Gasverbrauch als Maß für die konjunkturelle Entwicklung gewählt (vgl. bspw. Fornaro 2020, Janzen und Radulescu 2020). Verkehrsdaten beziehen sich auf Lkw-Aufkommen, Flugaufkommen oder Luftverschmutzung (vgl. Fornaro 2020). Die Finanztransaktionsindikatoren messen in der Regel Kreditkarten- oder Einzelhandelsumsätze (vgl. Aastveit et al. 2020). Internetsuchanfragen bilden das Interesse von Internetnutzern an bestimmten Themen ab (vgl. Götz und Knetsch 2019).² Schließlich werden auch Konjunkturindikatoren aus Zeitungsnachrichten erstellt, indem die Themen von Artikeln mithilfe von Machine-Learning-Algorithmen ausgewertet oder Stimmungslagen (Sentimentanalyse) analysiert werden (vgl. Ellingsen et al. 2020). Ein prominenter Ansatz, der eine Vielzahl der oben genannten Indikatoren verbindet, ist die Analyse von Lewis et

¹ Aufgrund der sich schnell entwickelnden Literatur zu dem Thema beschränkt sich die vorliegende Übersicht notwendigerweise auf eine kleine Anzahl an Aufsätzen, die exemplarisch für weitere Studien stehen.

² Dahinter steckt die Idee, dass ein erhöhtes Suchaufkommen für bestimmte Begriffe charakteristisch für konjunkturelle Krisenzeiten oder Boomphasen ist.

al. (2020) für die USA. Diese Autoren fassen zehn verschiedene Zeitreihen mittels Hauptkomponentenanalyse zu einem wöchentlichen Aktivitätsindex zusammen, der zur Prognose des BIP dienen soll. Allerdings ist nicht immer das BIP als gesamtwirtschaftliches Maß die Zielzeitreihe der Indikatoren. Je nach Indikator werden auch die Industrieproduktion oder die privaten Konsumausgaben als Zielgröße definiert.

Auch im deutschen Kontext stehen einige der oben genannten unkonventionellen Konjunkturindikatoren zur Verfügung. So verwenden bspw. Askitas und Zimmermann (2013) Daten zum Lkw-Verkehrsaufkommen aus dem deutschen Maut-System zur Prognose der monatlichen Industrieproduktion. Vosen und Schmidt (2012) sowie Götz und Knetsch (2019) nutzen Google-Suchanfragen zur Prognose der privaten Konsumausgaben bzw. des BIP. Ein relativ neuer Indikator ist der „Wöchentliche Aktivitätsindex“ der Bundesbank (vgl. Eraslan und Götz 2020), der auf Basis von neun wöchentlichen Zeitreihen die aktuelle Entwicklung des deutschen BIP schätzt und dabei der Vorgehensweise von Lewis et al. (2020) folgt. Die verwendeten Zeitreihen umfassen den Stromverbrauch, den Lkw-Maut-Fahrleistungsindex, das Flugaufkommen, die Anzahl der Google-Suchanfragen zu „Arbeitslosigkeit“, „Kurzarbeit“ und „Staatshilfe“, das Passantenaufkommen in deutschen Innenstädten, Luftverschmutzungsdaten sowie Daten zum Konsumentenvertrauen.

Während also auf gesamtdeutscher Ebene eine Reihe von höherfrequenten, unkonventionellen Konjunkturindikatoren zur Verfügung stehen, ist dies für Bayern (und andere Bundesländer) bisher nicht der Fall. Demnach bewegt sich das ifo Institut hier auf neuem akademischen Terrain. Durch die vom ifo erstellten regionalen Konjunkturindikatoren stehen zumindest ein paar wenige, eher konventionelle Indikatoren auf der Ebene der bayerischen Wirtschaft zur Verfügung, welche allerdings nur auf monatlicher Basis vorliegen. Sofern sich die hochfrequenten Stromverbrauchsdaten als geeignet für die Prognose regionaler Wirtschaftsaktivität im Verarbeitenden Gewerbe erweisen, kann das vorliegende Forschungsprojekt als Pilotstudie auf diesem Gebiet angesehen werden.

Tabelle 5: Zusammenfassung der aktuellen Prognoseliteratur mit Fokus auf unkonventionelle Konjunkturindikatoren

Referenz	Indikatoren, Land	Zielvariable	Frequenz	Methode, Resultate
Lourenço und Rua (2021)	„Aktivitätsindex“; Portugal	BIP	t	Täglicher Aktivitätsindex konstruiert aus fünf Zeitreihen (u.a. Stromverbrauch und Lkw-Aufkommen); Eignung für Nowcast
Aastveit et al. (2020)	Kartenzahlungen; Norwegen	privater Konsum	w	Kartenzahlungen verbessern Nowcast ab 5. Woche im Quartal relativ zu einfachen Zeitreihenmodellen und Indikatoren
Ellingsen et al. (2020)	Zeitungsartikel; USA	BIP, Investitionen, privater Konsum	m	Topic-Modelling zur thematischen Zuordnung der Zeitungsartikel; Reduktion der Dimension mit Machine-Learning-Algorithmen; ähnliche oder bessere Prognoseperformance der Nachrichtendaten verglichen mit quantitativen Angaben
Eraslan und Götz (2020)	„Aktivitätsindex“; Deutschland	BIP	w	Wöchentlicher Aktivitätsindex konstruiert aus neun Zeitreihen (u.a. Stromverbrauch und Lkw-Maut) mittels Hauptkomponentenanalyse; Ableitung einer BIP-Schätzung
Fornaro (2020)	Lkw-Aufkommen, Stromverbrauch; Finnland	IP	m	Insbesondere Stromverbrauchsdaten geeignet für Nowcast
Janzen und Radulescu (2020)	Stromverbrauch; Schweiz	-	t	Abschätzung des wirtschaftlichen Einbruchs im Zuge der Corona-Krise; keine Prognoseübung
Lewis et al. (2020)	„Aktivitätsindex“; USA	BIP, IP, Beschäftigung	w	Wöchentlicher Aktivitätsindex konstruiert aus zehn Zeitreihen (u.a. Stromproduktion) mittels Hauptkomponentenanalyse; Index geeignet für Nowcast aller drei Zielgrößen

Götz und Knetsch (2019)	Google-Suchanfragen; Deutschland	BIP	m	Brückenmodelle inkl. kategorisierter Google-Suchanfragen; bessere Prognosen relativ zu umfragebasierten Indikatoren
Askitas und Zimmermann (2013)	Lkw-Aufkommen; Deutschland	IP	m	Maut-Index mit besseren Nowcasts relativ zu einfachen Zeitreihenmodellen
Vosen und Schmidt (2012)	Google-Trend Index; Deutschland	privater Konsum	m	Konstruktion eines Trendindex basierend auf Google-Such- anfragen; Mehrwert des Index relativ zu umfragebasierten Indikatoren

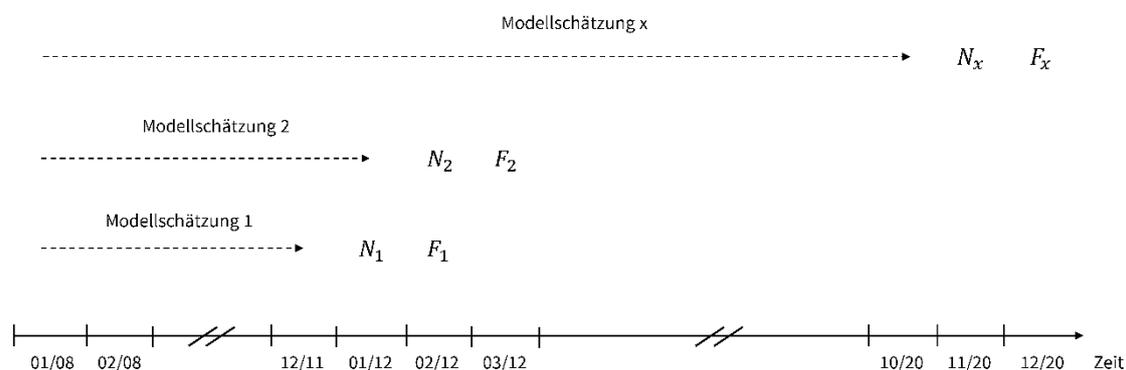
Abkürzungen: Bruttoinlandsprodukt (BIP), Industrieproduktion (IP), täglich (t), wöchentlich (w), monatlich (m). Studien in umgekehrt chronologischer Reihenfolge des Erscheinungsjahrs angeordnet. Quellen: Zusammenstellung des ifo Instituts.

5.2 Aufbau des Prognoseexperiments auf Monatsbasis

Die höchste verfügbare Frequenz bei Industrieproduktion, Auftragseingängen und der ifo Indikatoren sind Monatsdaten. Daher werden die hochfrequenten Stromverbrauchsdaten zunächst auf Monatsebene aggregiert, um gängige Prognosemodelle einsetzen zu können, die gleiche Frequenzen der Daten voraussetzen. In Abschnitt 2.1 haben wir diese Daten bereits präsentiert und deren Transformation diskutiert.

Zur Evaluation der prognostischen Eigenschaften der verschiedenen Indikatoren etablieren wir einen so genannten pseudo out-of-sample Prognoseansatz, der wie folgt strukturiert ist. Wir versetzen uns in die Situation eines Prognostikers in der Vergangenheit, der nur auf Informationen zurückgreifen kann, die zu einem bestimmten Zeitpunkt auch verfügbar gewesen sind. So konnte der Prognostiker, wenn er im Jahr 2018 Prognosen erstellen wollte, nicht die Ausprägungen der Konjunkturindikatoren für das Jahr 2019. Abbildung 27 zeigt schematisch den Aufbau des Prognoseexperiments. Für die erstmalige Schätzung der regressionsanalytischen Modelle (*Modellschätzung 1*) verwenden wir die Daten im Zeitraum Januar 2008 bis Dezember 2011. Dieser Zeitraum umfasst eine hinreichend große Anzahl an Beobachtungen, so dass die erste Modellschätzung auch vernünftige Ergebnisse generiert. Auf Basis dieser Schätzung berechnen wir eine Prognose für den laufenden Monat Januar 2012 (Nowcast, N_1) und den nächst folgenden Monat Februar 2012 (Forecast, F_1). Im Anschluss daran erweitern wir den Betrachtungszeitraum um einen Monat, schätzen die Modelle neu (*Modellschätzung 2*, Zeitraum: Januar 2008 bis Januar 2012) und errechnen abermals einen Nowcast und einen Forecast (N_2 , F_2). Dieses Vorgehen wiederholen wir bis ans Ende des hier betrachteten Zeitraums (*Modellschätzung x*; N_x , F_x). Prognostiziert wird die Verlaufsrate der saison- und kalenderbereinigten bayerischen Industrieproduktion, also die Veränderungsrate gegenüber dem Vormonat (vgl. Abschnitt 2.6).

Abbildung 27: Schematische Darstellung des Prognoseexperiments auf Monatsbasis



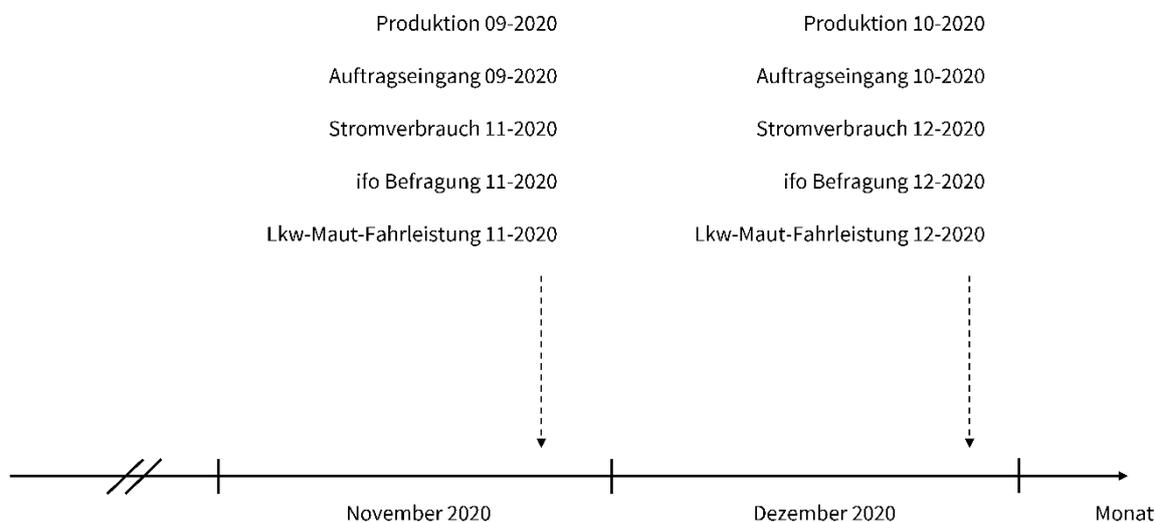
Anmerkung: Schematisch dargestellt ist der Ablauf des Prognoseexperiments basierend auf Monatsdaten. N steht als Abkürzung für den Nowcast und F repräsentiert den Forecast. Quellen: Darstellung des ifo Instituts.

Als Prognosemodelle verwenden wir zwei so genannte Indikatormodelle und einen Benchmark (Vergleichsmodell), gegenüber dem wir die Prognosegüte der einzelnen Indikatoren messen; im Anhang finden sich die konkreten mathematischen Repräsentationen. Die drei Modelle werden wie folgt spezifiziert:

- 1) **Indikatormodell 1:** In diesem Modell wird die Verlaufsrate der bayerischen Industrieproduktion erklärt durch eine Konstante (also die durchschnittliche Veränderungsrate der Industrieproduktion) und den kontemporären bzw. gleichlaufenden Wert eines einzelnen Indikators. Konkret bedeutet das: die Prognose für bspw. den Januar 2012 basiert auf dem zuletzt verfügbaren Wert des Indikators (z.B. das ifo Geschäftsklima im Verarbeitenden Gewerbe Bayerns für Januar 2012).
- 2) **Indikatormodell 2:** Da einige Indikatoren neben dem Gleichlauf auch Eigenschaften als Frühindikatoren aufweisen, erweitert das zweite Indikatormodell das Erste um weitere Verzögerungen der Indikatoren. Das bedeutet, dass Ausprägungen des Indikators aus der Vergangenheit die heutigen Werte der Industrieproduktion erklären und prognostizieren können. Konkret bedeutet das: die Prognose für bspw. den Januar 2012 basiert auf den zuletzt verfügbaren Werten des Indikators (z.B. das ifo Geschäftsklima im Verarbeitenden Gewerbe Bayerns für Januar 2012 und Dezember 2011). Die Wahl der optimalen Anzahl an Verzögerungen wird anhand des so genannten Akaike Informationskriteriums (AIC) bestimmt.
- 3) **Benchmark:** Als Vergleichsmodell spezifizieren wir ein so genanntes autoregressives Modell erster Ordnung. Hierbei wird die heutige Industrieproduktion erklärt durch eine Konstante und die Ausprägung der Industrieproduktion von gestern. Damit kann eine Prognose für bspw. Januar 2012 gewonnen werden aus der Beobachtung der Industrieproduktion vom Dezember 2011. Wenn demnach die Produktion von heute noch nicht bekannt ist, kann die einzige verfügbare Information – die Ausprägung von gestern – zur Prognose hergenommen werden.

Die Modelle werden jeweils so spezifiziert, dass der laufende und der folgende Monat als so genannte *direct-step* Prognose berechnet werden. Dabei beruht der Forecast nicht auf dem Nowcast, so dass sich eine Fehlprognose des laufenden Monats nicht auf die Performance für den folgenden Monat auswirkt. Stattdessen wird die Schätzung des Modells um zusätzliche Verzögerungen der Indikatoren in Höhe des Prognosehorizonts ergänzt (vgl. die Modellrepräsentation im Anhang). In jedem Iterationsschritt wird die Annahme getroffen, dass der Nowcast und der Forecast am Ende eines Monats berechnet werden. Aufgrund unterschiedlicher Publikationsverzögerungen stehen dabei nicht alle Indikatoren in vollem Umfang zur Verfügung. Abbildung 28 zeigt schematisch die Indikatorverfügbarkeit für die beiden Monate November und Dezember 2020.

Abbildung 28: Schematische Darstellung zur Indikatorverfügbarkeit für das Prognoseexperiment



Quellen: Darstellung des ifo Instituts.

Wie bereits angesprochen kann für den Nowcast und den Forecast auf den Stromverbrauch und die ifo Indikatoren des jeweiligen Monats zurückgegriffen werden; so liegen Ende November die Befragungsergebnisse und der Stromverbrauch bereits zeitnah vor. Gleiches gilt für den Lkw-Maut-Fahrleistungsindex. Anders verhält es sich bei den Auftragseingängen und der Industrieproduktion für Bayern, die erheblichen Publikationsverzögerungen unterliegen und damit nur eine eingeschränkte Einschätzung zur aktuellen konjunkturellen Lage erlauben. Für die beiden amtlichen Indikatoren lagen bspw. Ende November 2020 ausschließlich Angaben bis September 2020 vor. Diesem Umstand wird beim Prognoseexperiment explizit Rechnung getragen und nur jene Informationen verwendet, die dem Prognostiker zum jeweiligen Zeitpunkt vorlagen.

Die Evaluierung der durchschnittlichen Prognosegüte erfolgt mit dem in der Prognoseliteratur gängigsten Maß: der Wurzel des mittleren quadratischen Prognosefehlers (WMQPF); für die mathematische Repräsentation sei auf den Anhang verwiesen. Hierfür werden zunächst die Prognosefehler, definiert als Prognose der Industrieproduktion abzüglich ihrer Realisation, berechnet. Ein positives Vorzeichen beim Prognosefehler signalisiert eine Überschätzung, ein negatives Vorzeichen steht für eine Unterschätzung. Im Anschluss erfolgt eine Quadrierung der Prognosefehler, um große Fehlprognosen stärker zu bestrafen. Aus den quadrierten Werten wird im Anschluss ein Mittelwert über alle erstellten Prognosen gebildet und daraus die Quadratwurzel gezogen, was der WMQPF entspricht. Dieses Vorgehen wird für jeden Indikator und jedes Modell vorgenommen. Die Anzahl der zu evaluierenden Prognosen variiert dabei mit dem Prognosehorizont und beträgt 108 für den Nowcast und 107 für den Forecast. Zu Letzt wird die WMQPF der Indikatoren in Relation zum Prognosefehler des Benchmarks gesetzt, um die relative Prognosegüte abschätzen zu können. Sofern dieses Verhältnis einen Wert kleiner als Eins annimmt, ist der Indikator im Durchschnitt dem Benchmark überlegen. Bei einem Verhältnis größer als Eins liefert der

jeweilige Indikator keinen zusätzlichen Informationsgehalt für die Prognose der Zielgröße. Demnach sind besonders jene Indikatoren wertvoll für die Prognose, die einen geringen relativen Prognosefehler zum Benchmark aufweisen. Die relativen Prognosefehler lassen ebenfalls Vergleiche zwischen den Indikatoren zu, wobei grundsätzlich eine kleinere WMQPF mit einer höheren Treffsicherheit einhergeht.

5.3 Ergebnisse des Prognoseexperiments auf Monatsbasis

Die Prognoseergebnisse mit monatlich zur Verfügung stehender Indikatoren werden für zwei unterschiedliche Zeiträume betrachtet. Zum einen wird der Zeitraum der Jahre 2008 bis 2020 untersucht. Hierfür liegen Stromverbrauchsdaten zweier VNB, der N-ERGIE Netz GmbH und der SWM Infrastruktur GmbH & Co. KG, vor, so dass das Prognoseexperiment für diesen Zeitraum ausschließlich auf den Angaben dieser beiden Anbieter beruht. Zum anderen wird der Zeitraum 2015 bis 2020 auf Basis der Daten aller vier VNB evaluiert. Jedoch beschränkt sich die Aussagekraft der Indikatoren hier ausschließlich auf die Jahre 2019 bis 2020, da die Angaben für 2015 bis 2018 für die erstmalige Schätzung der Modelle herangezogen werden. Dieser Umstand muss bei der Interpretation der Ergebnisse unbedingt berücksichtigt werden, da die Anzahl der Beobachtungen hier sehr stark eingeschränkt ist. Den Abschluss dieses Abschnitts bildet eine Diskussion der Prognosefehler der Modelle im Zeitverlauf, da die Betrachtung der relativen Prognosefehler auf durchschnittlichen Werten beruht. Damit können Schwankungen der Prognosegüte identifiziert werden.

5.3.1 Durchschnittliche Ergebnisse für den Zeitraum 2008 bis 2020

Die durchschnittliche relative Prognosegüte für die Indikatoren im langen Evaluationszeitraum fasst Tabelle 6 zusammen. Im oberen Teil der Tabelle sind die Ergebnisse für den Nowcast und im unteren Teil der Tabelle die Ergebnisse für den Forecast abgebildet. Die zweite Spalte umfasst die Ergebnisse des ersten Indikatormodells; Resultate für das zweite Indikatormodell finden sich in der letzten Spalte. Je nach Modell und Prognosehorizont ist jener Indikator mit der besten durchschnittlichen Prognosegüte fett hervorgehoben. Die Werte in der Tabelle entsprechen den relativen Prognosefehlern, also dem Verhältnis der WMQPF des jeweiligen Indikators zur WMQPF des Vergleichsmodells.

Insgesamt bestätigen die Prognoseergebnisse die hypothesierte Prognosegüte auf Basis der Kreuzkorrelationen: die bayerischen Stromverbrauchsdaten haben einen hohen prognostischen Gehalt im Falle des Nowcast. Die relativen Prognosefehler liegen bei 0,70 (Modell 1) und 0,74 (Modell 2), was einer Verbesserung der Prognosegüte gegenüber dem Benchmark um durchschnittlich 30% bzw. 26% entspricht.

Tabelle 6: Relative Prognosegüte der Indikatoren, Evaluationszeitraum 2008 bis 2020

Indikator	Modell 1	Modell 2
<i>Nowcast</i>		
Stromverbrauch Bayern ^a	0,70	0,74
Auftragseingang Verarbeitendes Gewerbe Bayern	0,97	1,06
ifo Geschäftslage Verarbeitendes Gewerbe Bayern	0,84	0,89
ifo Geschäftsklima Verarbeitendes Gewerbe Bayern	0,76	0,81
ifo Geschäftserwartungen Verarbeitendes Gewerbe Bayern	0,76	0,80
ifo Produktionstätigkeit Verarbeitendes Gewerbe Bayern	0,85	0,91
ifo Produktionspläne Verarbeitendes Gewerbe Bayern	0,75	0,80
Stromverbrauch Deutschland	0,82	0,83
Lkw-Maut-Fahrleistungsindex	0,72	0,80
<i>Forecast</i>		
Stromverbrauch Bayern ^a	1,01	1,01
Auftragseingang Verarbeitendes Gewerbe Bayern	1,04	1,10
ifo Geschäftslage Verarbeitendes Gewerbe Bayern	1,08	1,10
ifo Geschäftsklima Verarbeitendes Gewerbe Bayern	1,01	1,05
ifo Geschäftserwartungen Verarbeitendes Gewerbe Bayern	0,98	1,02
ifo Produktionstätigkeit Verarbeitendes Gewerbe Bayern	1,05	1,08
ifo Produktionspläne Verarbeitendes Gewerbe Bayern	1,02	1,07
Stromverbrauch Deutschland	1,02	1,04
Lkw-Maut-Fahrleistungsindex	1,01	1,06

Anmerkung: Prognosefehler der Indikatoren dargestellt in Relation zum autoregressiven Benchmark-Modell für die bayerische Industrieproduktion (WMQPF Nowcast: 4,9 Prozentpunkte; WMQPF Forecast: 4,2 Prozentpunkte). Fett hervorgehobene Prognosefehler zeigen den jeweils besten Indikator an. Der Evaluationszeitraum umfasst die Jahre 2008 bis 2020, wobei die Prognosefehler auf den Jahren 2012 bis 2020 beruhen. a) Angaben zum Stromverbrauch auf Basis der beiden VNB N-ERGIE Netz GmbH und SWM Infrastruktur GmbH & Co. KG. Quellen: Berechnungen des ifo Instituts.

Den regionalen ifo Indikatoren wurde bereits für Baden-Württemberg, Sachsen und Ostdeutschland eine hohe Prognosegüte attestiert (vgl. Lehmann 2020, Lehmann und Wohlrabe 2017, Lehmann und Wohlrabe 2015), die Ergebnisse in Tabelle 6 bestätigen diese Schlussfolgerung auch für Bayern. Die beiden besten ifo Indikatoren sind die ifo Produktionspläne und das ifo Geschäftsklima im Verarbeitenden Gewerbe Bayerns. Dabei liegen beide Indikatoren mit 0,75 bzw. 0,80 und 0,76 bzw. 0,81 nur knapp hinter den bayerischen Stromverbrauchsdaten, was trotz der qualitativen Natur der ifo Indikatoren einer hohen Prognosegüte entspricht. Der Auftragseingang liefert insgesamt ähnliche Ergebnisse wie das Benchmark-Modell, was aufgrund der erheblichen Publikationsverzögerungen nicht stark verwundert. Der Stromverbrauch Deutschlands produziert

zwar geringere Prognosefehler als der Benchmark, kann jedoch mit dem prognostischen Gehalt der bayerischen Stromverbrauchsdaten nicht mithalten. Das Ergebnis für den Lkw-Maut-Fahrleistungsindex ist hingegen interessant, da er ähnliche durchschnittliche Prognosefehler wie die ifo Indikatoren produziert, aber die Stromverbrauchsdaten der bayerischen VNB nicht schlägt. Die Prognoseverbesserung der bayerischen Stromverbrauchsdaten gegenüber dem Lkw-Maut-Fahrleistungsindex beträgt dabei – je nach Modell – 3% bzw. 8%. Aus diesem Grund erscheint die Auswertung und Extraktion der Stromverbrauchsdaten für Bayern wertvolle zusätzliche Informationen zu liefern.

Bei der Prognose des folgenden Monats (Forecast) verlieren alle Indikatoren und sind mit Ausnahme der ifo Geschäftserwartungen im bayerischen Verarbeitenden Gewerbe (0,98) nicht besser als das Benchmark-Modell. Der relative Prognosefehler der Stromverbrauchsdaten beläuft sich in beiden Indikatormodellen auf 1,01. Beide Prognosehorizonte verdeutlichen, dass die bayerischen Stromverbrauchsdaten einen hohen prognostischen Gehalt im Gleichlauf mit der Industrieproduktion aufweisen, die Vorlaufeigenschaften aber eher schwach ausgeprägt sind.

Hinter den Angaben in Tabelle 6 stehen absolute Prognosefehler, welche bei der Betrachtung nicht unberücksichtigt bleiben dürfen. Da die Aussagen für beide Modelle äquivalent sind, beschränken wir uns im Folgenden auf die Diskussion der Ergebnisse aus Modell 1. Das Benchmark-Modell lag beim Nowcast um durchschnittlich 4,9 Prozentpunkten daneben, für den Forecast beträgt der Wert 4,2 Prozentpunkte. Der relative Prognosefehler der Stromverbrauchsdaten i.H.v. 0,70 entspricht einer WMQPF von 3,5 Prozentpunkten; für den Forecast entspricht die WMQPF der Stromverbrauchsdaten in etwa jener für das Benchmark-Modell. Die relativen Prognosefehler der beiden besten ifo Indikatoren im Falle des Nowcast entsprechen rund 3,7 Prozentpunkten in absoluter Höhe. Im Falle des Forecasts entspricht die WMQPF der ifo Geschäftserwartungen 4,1 Prozentpunkte.¹ Somit muss trotz der sehr guten relativen Prognoseperformance mit größeren absoluten Prognosefehlern in Phasen wie bspw. tiefen Rezessionen gerechnet werden. Dieses Thema wird nochmals in dem Abschnitt aufgegriffen, welcher sich den monatlichen Prognosefehlern im Zeitverlauf widmet.

5.3.2 Durchschnittliche Ergebnisse für den Zeitraum 2015 bis 2020

Die Prüfung der Prognosetauglichkeit im vorherigen Abschnitt beruhte ausschließlich auf den Angaben zweier VNB. Beide Anbieter verteilen in etwa 60% des gesamten Stroms in Bayern, welcher durch die vier VNB Ende 2020 insgesamt zur Verfügung gestellt wurde. Daher fehlt ein nicht unerheblicher Teil des Stromverbrauchs, welcher u.U. die bayerische Produktionsentwicklung erklären und damit das Ergebnis des Prognoseexperiments verändern kann. In diesem Abschnitt werden deshalb die Stromverbrauchsdaten aller vier VNB auf ihre Prognosetauglichkeit geprüft.

¹ Die großen Prognosefehler sind maßgeblich durch die kräftigen Ausschläge der Industrieproduktion im Frühjahr 2020 getrieben. Bei Nichtberücksichtigung des Jahres 2020 liegt die WMQPF des Benchmarks bei 1,7 Prozentpunkten (Nowcast) bzw. 1,8 Prozentpunkten (Forecast).

Jedoch kann aufgrund der Datenverfügbarkeit ein solches Vorgehen nur ab dem Jahr 2015 realisiert werden. Dies ist insofern kritisch, da standardmäßige Zeitreihenmodelle zur Schätzung der Parameter einen hinreichend langen Zeitraum benötigen. Zudem kann durch den kurzen Zeitraum die Evaluierung der Prognosegüte der Indikatoren nur für einen sehr spezifischen Zeitabschnitt erfolgen, was die Verallgemeinerung der Ergebnisse erheblich erschwert. Daher interpretieren wir im Folgenden die Prognoseergebnisse für den kurzen Zeitraum ausschließlich qualitativ und unter Zuhilfenahme der Ergebnisse für den langen Zeitraum sowie den Umstand, dass beide Stromreihen hochgradig miteinander korreliert sind (vgl. Abschnitt 2.6).

Das Prognoseexperiment für den kurzen Zeitraum ist dabei analog zur Vorgehensweise auf Basis der langen Zeitreihen gestaltet. Die erste Schätzung der Modelle wurde auf den Zeitraum Januar 2015 bis Dezember 2018 festgelegt. Aufgrund der Kürze der Zeitreihe der vier VNB können insgesamt nur 24 Nowcast und 23 Forecasts evaluiert werden. Daher erstrecken sich die Prognosen über die Jahre 2019 und 2020, so dass die Gesamtergebnisse stark durch die Performance in der ersten Corona-Welle getrieben sein könnten. Dies muss bei der Interpretation unbedingt berücksichtigt werden. Tabelle 7 fasst die Prognoseergebnisse für den kurzen Zeitraum zusammen.

Für den kurzen Zeitraum bleiben die Aussagen zum Nowcast aus dem vorhergehenden Abschnitt und die sich ergebende Indikatorrangfolge weitestgehend erhalten. Die bayerischen Stromverbrauchsdaten sowie die ifo Geschäftserwartungen und das ifo Geschäftsklima im bayerischen Verarbeitenden Gewerbe liefern die geringsten relativen Prognosefehler. Aber auch der Lkw-Maut-Fahrleistungsindex hat einen hohen prognostischen Gehalt für die bayerische Industrieproduktion. Mit Blick auf den Forecast sind die Vorlaufeigenschaften einiger ifo Indikatoren erneut von besonderem Wert, wobei hier erneut die ifo Geschäftserwartungen – ergänzt um das ifo Geschäftsklima – im bayerischen Verarbeitenden Gewerbe eine sehr gute Prognoseleistung aufweisen. Nur der Lkw-Maut-Fahrleistungsindex schneidet in beiden Modellen noch ein wenig besser ab, was aber maßgeblich auf die tiefen Einschnitte im Zuge der ersten Corona-Welle zurückzuführen ist. Zusätzlich scheint es so, dass die Stromverbrauchsdaten aller vier VNB nunmehr das Benchmark-Modell schlagen können. Dies kann aber entweder auf den speziellen Zeitraum oder auf die Verfügbarkeit der Daten aller VNB zurückzuführen sein. Leider lässt der kurze Zeitraum keine Schlussfolgerungen diesbezüglich zu. Wünschenswert aus prognostischer Sicht wäre aber natürlich Letzt genannter Aspekt.

Die Prognoseexperimente auf Monatsbasis haben gezeigt, dass die bayerischen Stromverbrauchsdaten einen hohen prognostischen Gehalt für die bayerische Industrieproduktion aufweisen und neben den ifo Befragungsindikatoren als zusätzliche Informationsquelle herangezogen werden können. Besonders die Prognoseperformance im Falle des Nowcast und die zeitnahe Verfügbarkeit der Stromverbrauchsdaten lassen eine zeitnahe Einschätzung zur aktuellen konjunkturellen Situation in Bayern zu. Da die Daten der VNB aber durch ihre hochfrequente Messung (15-Minuten-Takt) einen zusätzlichen Vorteil gegenüber anderen Konjunkturindikatoren aufweisen, soll in Abschnitt 5.4 geprüft werden, ob die höhere Frequenz das eben beschriebene

gute Prognoseergebnis noch verbessern oder zumindest halten kann und damit eine noch frühere Einschätzung zur aktuellen Konjunkturlage erlaubt. Dafür wird von der Monatsebene abstrahiert und der Blick auf die Wochenebene gelegt. Zuvor wird aber die Prognosegüte der bayerischen Stromverbrauchsdaten im Zeitverlauf näher analysiert, um Phasen mit besserer bzw. schlechterer Treffsicherheit der bayerischen Stromverbrauchsdaten zu identifizieren.

Tabelle 7: Relative Prognosegüte der Indikatoren, Evaluationszeitraum 2015 bis 2020

Indikator	Modell 1	Modell 2
<i>Nowcast</i>		
Stromverbrauch Bayern ^a	0,60	0,68
Auftragseingang Verarbeitendes Gewerbe Bayern	0,83	0,94
ifo Geschäftslage Verarbeitendes Gewerbe Bayern	0,76	0,74
ifo Geschäftsklima Verarbeitendes Gewerbe Bayern	0,60	0,70
ifo Geschäftserwartungen Verarbeitendes Gewerbe Bayern	0,59	0,72
ifo Produktionstätigkeit Verarbeitendes Gewerbe Bayern	0,72	0,86
ifo Produktionspläne Verarbeitendes Gewerbe Bayern	0,62	0,72
Stromverbrauch Deutschland	0,65	0,69
Lkw-Maut-Fahrleistungsindex	0,57	0,74
<i>Forecast</i>		
Stromverbrauch Bayern ^a	0,92	0,98
Auftragseingang Verarbeitendes Gewerbe Bayern	1,00	1,21
ifo Geschäftslage Verarbeitendes Gewerbe Bayern	0,96	1,01
ifo Geschäftsklima Verarbeitendes Gewerbe Bayern	0,90	0,93
ifo Geschäftserwartungen Verarbeitendes Gewerbe Bayern	0,89	0,96
ifo Produktionstätigkeit Verarbeitendes Gewerbe Bayern	0,96	1,01
ifo Produktionspläne Verarbeitendes Gewerbe Bayern	0,92	1,07
Stromverbrauch Deutschland	0,92	0,95
Lkw-Maut-Fahrleistungsindex	0,88	0,92

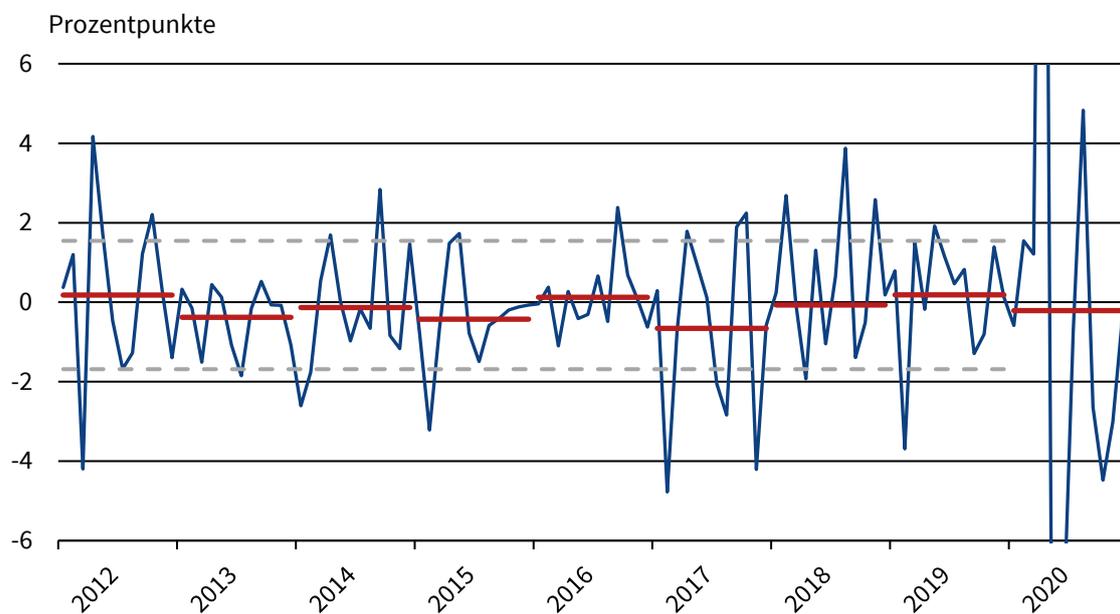
Anmerkung: Prognosefehler der Indikatoren dargestellt in Relation zum autoregressiven Benchmark-Modell für die bayerische Industrieproduktion (WMQPF Nowcast: 11,7 Prozentpunkte; WMQPF Forecast: 9,1 Prozentpunkte). Fett hervorgehobene Prognosefehler zeigen den jeweils besten Indikator an. Der Evaluationszeitraum umfasst die Jahre 2015 bis 2020, wobei die Prognosefehler auf den Jahren 2019 und 2020 beruhen. a) Angaben zum Stromverbrauch auf Basis aller vier Verteilnetzbetreiber. Quellen: Berechnungen des ifo Instituts.

5.3.3 Monatliche Prognosefehler im Zeitverlauf

Bei der in den vorhergehenden Abschnitten betrachteten Prognosegüte handelte es sich um Durchschnittswerte über den gesamten Prognosezeitraum. Jedoch muss die Prognosegüte des Stromverbrauchs nicht unbedingt konstant über die Jahre ausfallen, sondern kann – je nach Konjunkturlage – im Zeitverlauf schwanken. Daher werden im Folgenden die Prognosefehler auf Basis des Stromverbrauchs im Zeitverlauf näher begutachtet. Abbildung 29 zeigt zunächst die Prognosefehler für den Nowcast auf Basis des Prognoseexperiments für die Jahre 2012 bis 2020; der bayerische Stromverbrauch für diesen Zeitraum basiert auf den Angaben zweier VNB.

Abbildung 29: Nowcast-Prognosefehler des bayerischen Stromverbrauchs, zwei VNB

Abweichung der Prognose von der Realisation

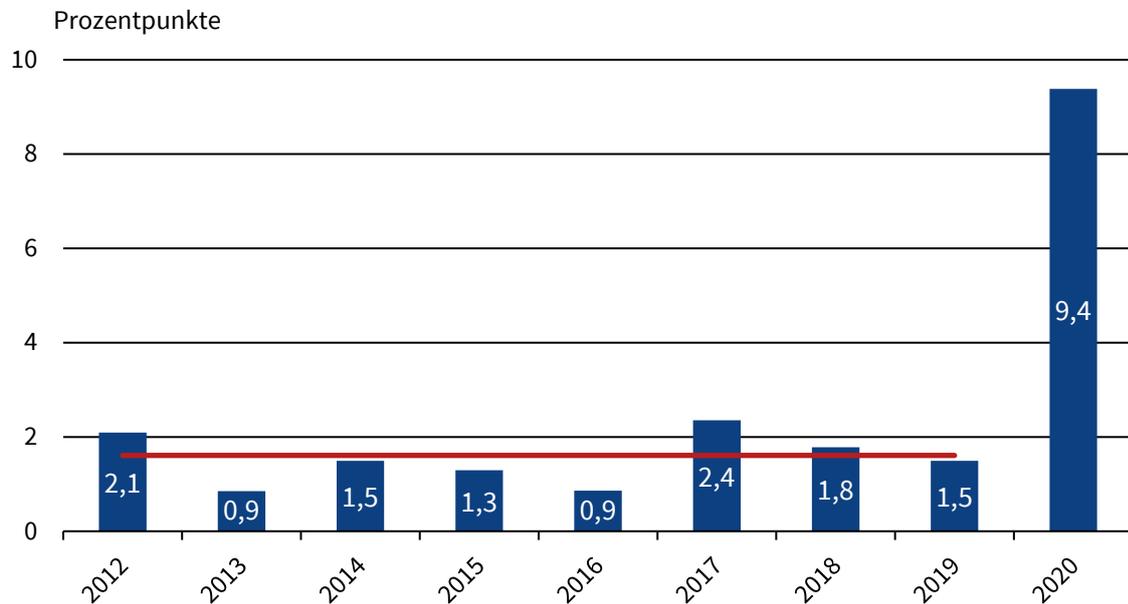


Anmerkung: Jahresspezifische mittlere Prognosefehler in rot und Standardabweichung der Prognosefehler für die Jahre 2012 bis 2019 in grau. Quellen: Berechnungen des ifo Instituts. © ifo Institut

Die roten Linien repräsentieren die jahresspezifischen mittleren Prognosefehler und die grauen Linien begrenzen die durchschnittliche Schwankungsbreite der Prognosefehler, gemessen an der Standardabweichung der Jahre 2012 bis 2019. Insgesamt zeigt sich eine recht homogene Prognosegüte im Zeitverlauf. Die jahresspezifischen mittleren Prognosefehler liegen, mit wenigen Ausnahmen, immer nahe Null. Für eine stark schwankende Reihe wie die Industrieproduktion kann das Ergebnis durchaus als sehr treffsicher bezeichnet werden. Im Corona-Jahr 2020 nimmt die Prognosegüte der Stromverbrauchsdaten naturgemäß ab, was sich in einem deutlich größeren Wert der WMQPF widerspiegelt (vgl. Abbildung 30).

Abbildung 30: Nowcast-Prognosegüte nach einzelnen Jahren auf Basis zweier VNB

Wurzel des mittleren quadratischen Prognosefehlers



Anmerkung: Durchschnittlicher Prognosefehler der Jahre 2012 bis 2019 in rot (1,6 Prozentpunkte).

Quellen: Berechnungen des ifo Instituts.

© ifo Institut

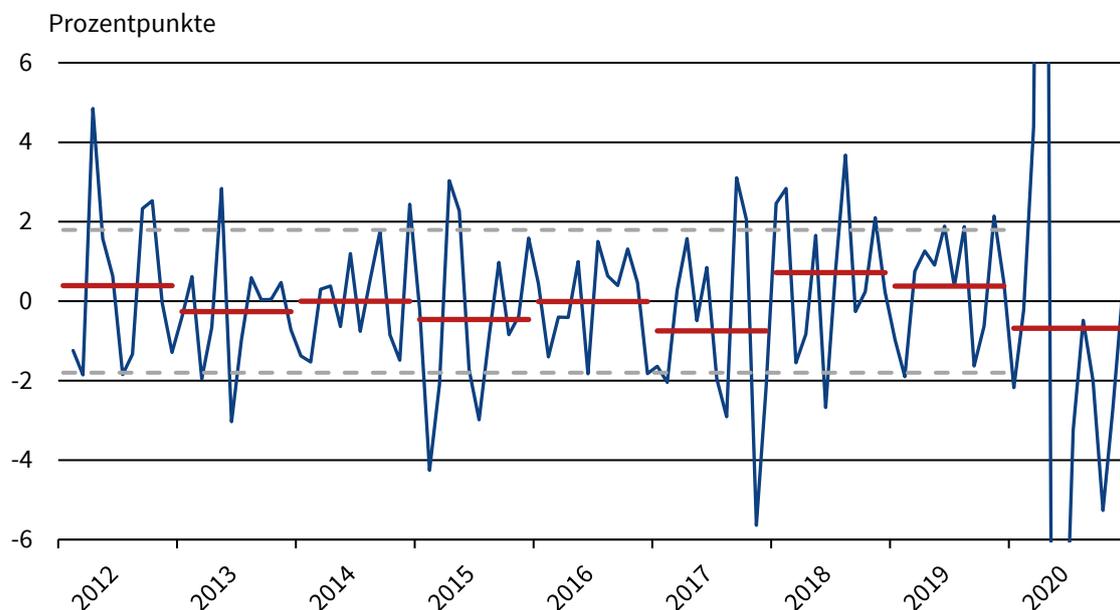
In den Jahren 2012 bis 2019 liegt die durchschnittliche Wurzel des mittleren quadratischen Prognosefehlers bei 1,6 Prozentpunkten und variiert in diesen Jahren zwischen 0,9 und 2,4 Prozentpunkten. Im Jahresdurchschnitt 2020 steigt die WMQPF des Nowcasts dann aber kräftig auf 9,6 Prozentpunkte an, wenngleich die bayerischen Stromverbrauchsdaten im April 2020 den Einbruch der Produktion und im Mai 2020 das Wiederhochfahren mit jeweils kräftigen Raten anzeigten. So lag der Nowcast im April 2020 bei -6,2% und die Prognose für Mai 2020 bei 4,3%. Dennoch waren die Schwankungen der Industrieproduktion historisch so einmalig (April 2020: -32,0%, Mai 2020: 20,2%), dass selbst die Stromverbrauchsdaten mit überdurchschnittlichen Prognosefehlern auskommen müssen.¹

Die Prognosegüte des Forecasts weist ein ähnliches Muster im Zeitverlauf wie der Nowcast auf, wenngleich die Schwankung und die jahresdurchschnittlichen Mittelwerte etwas größer ausfallen (vgl. Abbildung 31). Aber auch hier gilt die Aussage, dass das Ergebnis für die Jahre 2012 bis 2019 angesichts der starken Schwankungen der Industrieproduktion als treffsicher bezeichnet werden kann. Die jahresspezifischen, mittleren Prognosefehler liegen auch beim Forecast mit Stromverbrauchsdaten nahe Null und variieren zwischen -0,7 und 0,4 Prozentpunkten.

¹ An der Stelle muss erneut auf die Bereinigung der Daten hingewiesen werden. Seitens der amtlichen Statistik gibt es kein Vorbild zur Saison- und Kalenderbereinigung von Stromverbrauchsdaten und auch die bayerische Industrieproduktion wird von offizieller Seite nur in Ursprungswerten ausgewiesen. Daher kann nicht ausgeschlossen werden, dass ein Teil des Prognosefehlers der Stromverbrauchsdaten auf die Saison- und Kalenderbereinigung zurückgeht.

Abbildung 31: Forecast-Prognosefehler des Stromverbrauchs, zwei VNB

Abweichung der Prognosen von der Realisation



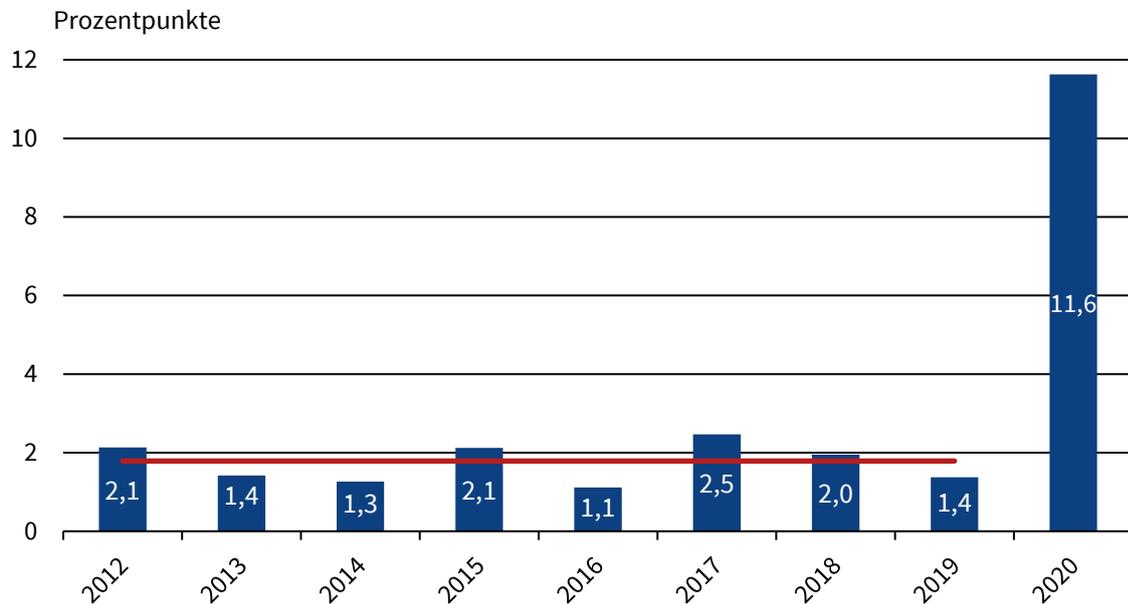
Anmerkung: Jahresspezifische mittlere Prognosefehler in rot und Standardabweichung der Prognosefehler für die Jahre 2012 bis 2019 in grau. Quellen: Berechnungen des ifo Instituts. © ifo Institut

Analog zum Nowcast nimmt auch die Forecast Prognosegüte im Corona-Jahr 2020 naturgemäß ab (vgl. Abbildung 32). Die WMQPF liegt im Jahr 2020 bei 11,6 Prozentpunkten. Im Durchschnitt der Jahre 2012 bis 2019 beträgt die Wurzel des mittleren quadratischen Prognosefehlers 1,8 Prozentpunkte und variiert zwischen 1,1 und 2,5 Prozentpunkten.

Zuletzt soll nochmals der Vergleich zwischen den bayerischen Stromverbrauchsdaten basierend auf den Angaben zweier VNB mit jenen aller vier VNB angestellt werden. Aber auch dieser Vergleich muss mit Vorsicht interpretiert werden, da das Prognoseexperiment basierend auf allen vier VNB nur auf einer sehr geringen Anzahl an Beobachtungen basiert und nur die Jahre 2019 und 2020 umfasst. Die Forecast Prognosegüte des Stromverbrauchs aller vier VNB ist in beiden Jahren identisch zum Stromverbrauch basierend auf zwei VNB. Beim Nowcast hingegen beträgt die Wurzel des mittleren quadratischen Prognosefehlers für das Jahr 2019 aller vier VNB 1,1 Prozentpunkte verglichen mit 1,5 Prozentpunkten basierend auf den Angaben zweier VNB (vgl. Abbildung 30). Im Corona-Jahr 2020 nimmt die WMQPF der vier VNB jedoch einen größeren Wert an (9,9 Prozentpunkte ggü. 9,4 Prozentpunkten). Ob dies ein Ausdruck für eine bessere oder schlechtere Prognosegüte ist, kann jedoch mit den vorliegenden Daten nicht beurteilt werden.

Abbildung 32: Forecast-Prognosegüte nach einzelnen Jahren auf Basis zweier VNB

Wurzel des mittleren quadratischen Prognosefehlers



Anmerkung: Durchschnittlicher Prognosefehler der Jahre 2012 bis 2019 in rot (1,8 Prozentpunkte).

Quellen: Berechnungen des ifo Instituts.

© ifo Institut

5.4 Prognoseexperimente auf Wochenbasis

Die Ergebnisse aus Abschnitt 5.3 beruhen auf einem Prognoseexperiment, welches jeweils am Ende eines Monats durchgeführt wird. Mittels dieser Annahme wird unterstellt, dass eine Vielzahl an Informationen bereits vollständig vorliegen und für die Prognose genutzt werden können (bspw. die komplette Stromverbrauchsmenge für den untersuchten Monat oder der ifo Geschäftsklimaindex für das Verarbeitende Gewerbe Bayerns). Jedoch bieten die Stromverbrauchsdaten insbesondere die Möglichkeit, die höherfrequente Messung und die damit frühzeitig zur Verfügung stehenden Informationen für die Prognose nutzbar zu machen. Im folgenden Abschnitt wird hiervon explizit Gebrauch gemacht und das Prognoseexperiment aus dem vorhergehenden Abschnitt entsprechend angepasst bzw. verändert. Einerseits werden unterschiedliche Informationsstände innerhalb eines Monats simuliert, d.h. das Prognoseexperiment aus dem vorhergehenden Abschnitt wird entweder am Ende der ersten, zweiten oder dritten Woche des Monats durchgeführt und berücksichtigt nur jene Informationen, die zu den jeweiligen Zeitpunkten vorliegen. Zweitens werden die unterschiedlichen Frequenzen der Größen (monatlich bei der Industrieproduktion und wöchentlich beim Stromverbrauch) gemeinsam modelliert mithilfe von so genannten MIDAS-Modellen (Mixed-data sampling). Für beide Anpassungen des Prognoseexperimentes ist es notwendig, die Aufbereitung der Rohdaten an der einen oder anderen Stelle zu

modifizieren, was im folgenden Abschnitt beschrieben wird. Bevor die durchschnittlichen Ergebnisse auf Wochenbasis sowie im Zeitverlauf präsentiert werden, erfolgen kurze Beschreibungen der unterschiedlichen Informationsstände innerhalb eines Monats sowie der MIDAS-Modelle.

5.4.1 Notwendige Anpassungen bei der Datenaufbereitung

Bereits die Saison- und Kalenderbereinigung monatlicher Größen, für die keine entsprechenden Bezugsgrößen aus der amtlichen Statistik vorliegen, war eine Herausforderung und es bedurfte einer sensiblen Vorgehensweise bei der Extraktion der konjunkturellen Grunddynamik (vgl. Abschnitt 2.6). Die Bereinigung höherfrequenter Daten ist selbst für die amtliche Statistik in Deutschland bzw. Europa Neuland, so dass bspw. den bereinigten Tagesdaten des Lkw-Maut-Fahrleistungsindex vom Statistischen Bundesamt eher ein „experimenteller“ Charakter beigegeben wird (vgl. Hauf et al. 2020). Derzeit fehlt es vor allem an einer europäischen Leitlinie, wie und mit welchen Empfehlungen Tagesdaten saison- und kalenderbereinigt werden sollten (vgl. Cox et al. 2020). Daher kann sich aktuell nur an der methodischen Vorgehensweise des Statistischen Bundesamts zur Bereinigung der täglichen Lkw-Maut-Fahrleistung orientiert werden.

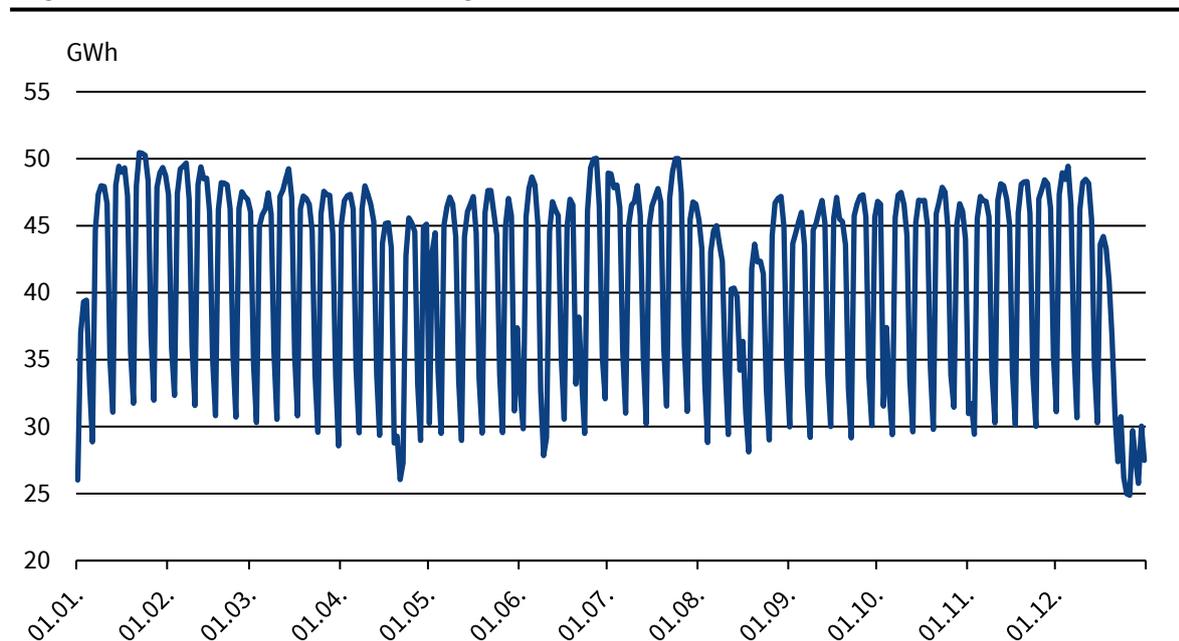
Zunächst werden die von den VNB zur Verfügung gestellten Rohdaten zum Stromverbrauch in 15-Minuten-Taktung zu Tagesdaten aggregiert. Dabei wird ein Großteil der Tages-Nacht-Schwankung im Stromverbrauch ausgeschaltet. Im Anschluss kommt – analog zum Vorgehen beim Lkw-Maut-Fahrleistungsindex – das von Cleveland et al. (1990) vorgeschlagene, LOESS-basierte Dekompositionsverfahren STL zum Einsatz.¹ Damit wird, unter Berücksichtigung aller übrigen Einflüsse, eine Zeitreihe additiv in ihre Saison- und Trendkomponente zerlegt. Das Verfahren bietet die Möglichkeit, wiederkehrende Schwankungen unterschiedlicher Periodizität zu modellieren. Für die bayerischen Stromverbrauchsdaten wurden Schwankungen innerhalb eines Tages und innerhalb einer Woche modelliert und die Originaldaten um diese Einflüsse bereinigt.

Im Anschluss an die Bereinigung der Tagesdaten erfolgte die Aggregation auf Wochenfrequenz mit Beginn des 01.01.2012 und unter der Annahme einer 7-Tage-Woche. Diese Annahme dürfte zum einen gerechtfertigt sein, da die Stromverbrauchsdaten ausschließlich Großkunden umfassen, die wohl auch an Sonntagen ihre Produktionstätigkeit nicht oder nur geringfügig herunterfahren. Zum anderen zeigen exemplarisch die Stromverbrauchsdaten für das Jahr 2019 zwar einen niedrigeren Verbrauch an Sonn- und Feiertagen an, welcher aber keinesfalls auf null zurückfällt (vgl. Abbildung 33).

¹ Die Abkürzung STL steht hierbei für „seasonal and trend decomposition using Loess“; LOESS bezeichnet eine Regressionsmethode und steht für „locally weighted scatterplot smoothing“. Die Bereinigung und Aufbereitung der Daten erfolgt mit der Statistik-Software EViews 12.

Abbildung 33: Tagesstromverbrauch für das Jahr 2019

Täglicher Stromverbrauch, Ursprungswerte



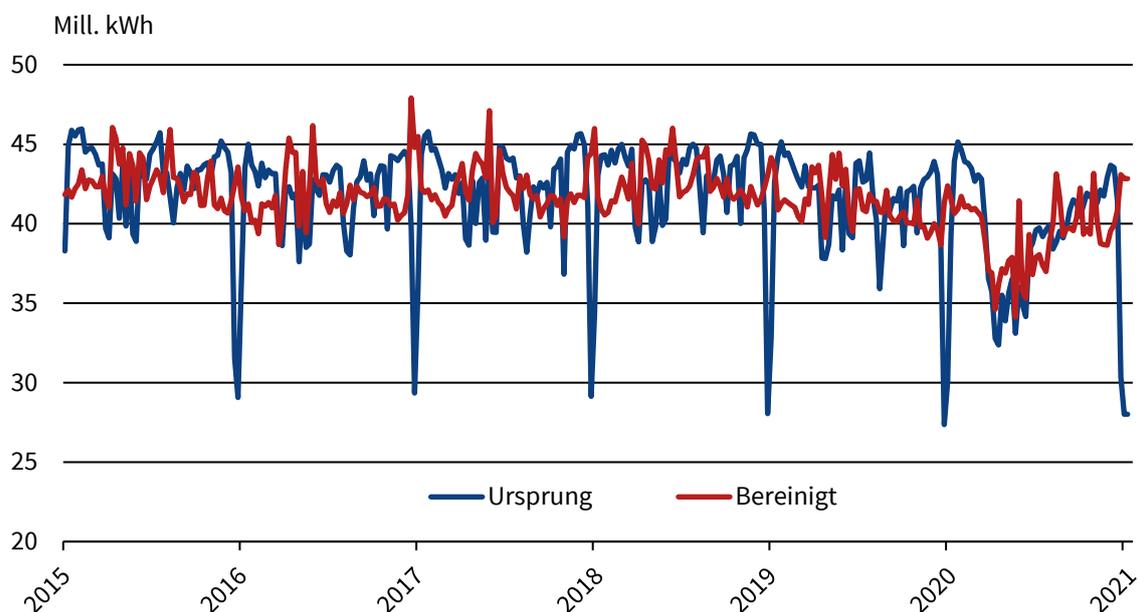
Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH (LVN), N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG; Darstellung des ifo Instituts.

© ifo Institut

Die Aggregation auf Wochenebene ist mit erheblich größeren Problemen verbunden als die Aggregation von Tages- auf Monatsbasis oder von Monats- auf Jahresbasis, da die Woche über die Tage Montag bis Sonntag definiert ist und innerhalb eines Monats nicht einer einheitlichen Struktur folgt. Vielmehr ist die Woche ein rollierendes Konstrukt. Somit beginnt die erste Woche eines jeden Monats innerhalb eines Jahres nur in wenigen Fällen mit einem Montag. Dies ist besonders am Jahresanfang und am Jahresende kritisch, da der Stromverbrauch hier auf Tagesebene auf einem deutlich niedrigeren Niveau liegt als im Rest des Jahres. Sofern hier ein bis zwei Tage aufgrund der Wochenstruktur in der Summation des Stromverbrauchs fehlen bzw. auf die vorherige oder nachfolgende Woche verschoben sind, kann es zu erheblichen Sprüngen und damit Zuwachsraten kommen. Um dies zu verhindern, werden die Wochen nicht als Summe der Tage ausgewiesen, sondern als deren Durchschnitt. Damit sollte das Problem des rollierenden Konstrukts etwas abgemildert werden. Jedoch kann dieses Vorgehen eine exakte Darstellung und damit Zuordnung auf die Monate verzerren; bei der Beschreibung des Prognoseexperiments wird darauf eingegangen, wie diese Verzerrung berücksichtigt wurde. Abbildung 34 zeigt den wöchentlichen Stromverbrauch seit dem Jahr 2015, getrennt nach Ursprungswerten der VNB und nach Bereinigung. Trotz der Bereinigung bleibt der Stromverbrauch auf Wochenbasis recht volatil, was wohl der Aggregationsebene geschuldet ist. Jedoch werden auch hier die Produktionseinschränkungen und damit einhergehend ein niedriger Stromverbrauch im Zuge der ersten Corona-Welle im Frühjahr 2020 deutlich sichtbar.

Abbildung 34: Stromverbrauch auf Wochenbasis seit 2015

Durchschnittlicher wöchentlicher Stromverbrauch, Ursprungs- und bereinigte Werte



Quellen: Bayernwerk Netz GmbH, LEW Verteilnetz GmbH (LVN), N-ERGIE Netz GmbH, SWM Infrastruktur GmbH & Co. KG; Berechnungen und Darstellung des ifo Instituts.

© ifo Institut

5.4.2 Unterschiedliche Informationsstände innerhalb eines Monats

Das Prognoseexperiment auf Monatsbasis beruhte auf der Annahme, dass dieses am Ende des jeweiligen Monats durchgeführt wird und damit alle Wochenangaben zum Stromverbrauch vorliegen. Um jedoch die Wochenfrequenz in einem ersten Schritt effizienter auszunutzen, werden nachfolgend drei unterschiedliche Informationsstände innerhalb eines Monats simuliert. So wird das Prognoseexperiment entweder am Ende der ersten, zweiten oder dritten Woche durchgeführt; vereinfachend wird angenommen, dass ein Monat aus vier Wochen besteht und damit der Prognosezeitpunkt am Ende der vierten Woche dem Prognoseexperiment aus Abschnitt 5.2 entspricht. Bei jedem Prognosezeitpunkt stehen daher entweder nur die Stromverbrauchsdaten der ersten, der ersten beiden oder der ersten drei Wochen des Monats zur Verfügung und können zur Prognose herangezogen werden. Um die Modelle auf Monatebene weiterhin verwenden zu können, werden die jeweiligen Wochendaten als Monatsrepräsentant deklariert. Eine schematische Darstellung der Informationsstände zeigt Abbildung 35.

Abbildung 35: Schematische Darstellung der unterschiedlichen Datenstände innerhalb eines Monats

		Datenstand					
		(1)	(2)	(3)	...	(106)	(107)
Monate	01/12	M	M	M	...	M	M
	02/12	W 1/2/3	M	M	...	M	M
	03/12		W 1/2/3	M	...	M	M
	...			W 1/2/3	...	M	M
	11/20					W 1/2/3	M
	12/20						W 1/2/3

Anmerkung: Die Angaben zum Stromverbrauch liegen je nach Datenstand entweder für den vollen Monat (M) oder die ersten ein, zwei oder drei Wochen (W 1/2/3) innerhalb eines Monats vor. Quellen: Darstellung des ifo Instituts.

Im schematischen Beispiel liegen bei Datenstand (1) der Monatswert (M) für Januar 2012 vor und entweder – je nach simulierten Informationsstand – der Stromverbrauch der ersten Woche (W1), der ersten beiden Wochen (W2) oder der ersten drei Wochen (W3) des Februars 2012. Bei Datenstand (2) liegen die Monatswerte für Januar und Februar 2012 sowie einer der drei Monatsrepräsentanten für März 2012 vor. Der Aufbau der Daten wird analog diesem Vorgehen bis zum Ende des Evaluationszeitraums fortgeführt. Im Anschluss daran wurden erneut Wachstumsraten zum Vormonat berechnet, wobei der jeweils letzte Wert eines Datenstandes der Veränderungsrate des jeweiligen Wochendurchschnitts gegenüber dem Vormonat entspricht. Steht bspw. nur der Stromverbrauch der ersten Märzwoche 2012 zur Verfügung, wird die Veränderungsrate dieser Wochenangabe gegenüber dem Vormonat (Februar 2012) berechnet. Aufgrund der Annahme, dass die unterschiedlichen Wochenwerte als Monatsrepräsentanten deklariert sind, können die bereits eingeführten Prognosemodelle aus Abschnitt 5.2 erneut verwendet werden. Damit ist die Vergleichbarkeit mit den Prognoseergebnissen auf Monatsbasis gewährleistet. Ein Unterschied besteht jedoch bei der Länge der zur Verfügung stehenden Zeitreihen, da die Auswertungsmodalitäten bei einem VNB zwischen Wochen- und Monatsbasis variieren. Der längere Zeitraum umfasst auf Wochenbasis nunmehr die Jahre 2012 bis 2020; auf Monatsbasis liegen die Daten für die Jahre 2008 bis 2020 vor. Der kürzere Zeitraum, für welchen Angaben aller vier VNB vorliegen, bleibt hingegen unverändert und umfasst weiterhin die Jahre 2015 bis 2020.

5.4.3 Grundzüge des Mixed-data sampling (MIDAS) Ansatzes

Die bisher zur Anwendung gekommenen Prognosemodelle konnten nur Daten handhaben, die einer gleichen Frequenz folgen. Daher mussten die Stromdaten vorher zunächst aggregiert werden, was meist mit einem Informationsverlust einhergeht. Modellklassen, die explizit gemischte

Frequenzen modellieren können, sind daher von besonderem Interesse für die vorliegende Anwendung. Eine solche Klasse sind die Mixed-data sampling (MIDAS) Regressionsmodelle. Hierbei werden Regressionsmodelle zwischen Größen unterschiedlicher Frequenz (bspw. Wochen- und Monatswerte beim Stromverbrauch) mittels einer Gewichtungsfunktion bzw. einem Lag Polynom spezifiziert, um insbesondere die Anzahl der zu schätzenden Parameter zu verringern (vgl. Ghysels et al. 2004).¹ Im Anhang findet sich die mathematische Repräsentation der hier eingesetzten MIDAS-Modelle. Wohlrabe (2009b) liefert eine anschauliche Zusammenfassung.

Für das vorliegende Prognoseexperiment wird das MIDAS Regressionsmodell wie folgt spezifiziert. Als Gewichtungsfunktion bzw. Lag Polynom, welches die Wochen- mit den Monatswerten in Einklang bringt, findet das einfache Almon-Lag-Polynom dritter Ordnung seine Anwendung (siehe Anhang); diese Form des Polynoms ergab die beste Anpassung des Modells an die Daten. Zudem wird das Almon-Lag-Polynom häufiger in der akademischen Literatur verwendet (bspw. in Marcellino und Schumacher 2010 zur Prognose des deutschen BIP). Wohlrabe (2009a) zeigt außerdem in einer Simulationsstudie, dass die Unterschiede für die Prognoseleistung zwischen einem Almon-Lag-Polynom und Gewichten basierend auf einer Beta-Funktion eher minimal sind. Die Maximalanzahl der Verzögerungen der wöchentlichen Stromdaten wird auf zehn festgelegt, d.h. die Industrieproduktion eines laufenden Monats t wird durch die wöchentlichen Stromverbrauchsdaten des laufenden und vergangenen Monats ($t, t - 1$) sowie durch die letzten beiden Wochen des Monats $t - 2$ erklärt. Insgesamt gehen in das Modell daher die Stromverbrauchsdaten der letzten 2,5 Monate ein. Die Wahl der Maximalanzahl der Verzögerungen wurde durch das Bayesianische Informationskriterium (BIC) abgesichert, welches auch Wohlrabe (2009a) zur Auswahl vorschlägt. Diverse Spezifikationen mit einer unterschiedlichen Anzahl an Verzögerungen kamen insgesamt zu schlechteren Prognoseergebnissen als die im Folgenden ausgewiesenen.

Die MIDAS Regressionsmodelle erfordern ein konstantes Mischungsverhältnis der Frequenzen, d.h. eine gewisse Anzahl an höherfrequenten Beobachtungen definiert die niedrigere Frequenz. So ist ein Jahr immer definiert als 12 Monate und ein Quartal besteht immer aus 3 Monaten. Im ersten Fall beträgt das Mischungsverhältnis daher zwölf und im zweiten Fall drei. Die Wochen-Monats-Relation ist hingegen nicht konstant, d.h. ein Monat besteht nicht immer aus einer fixen Anzahl an Wochen. Um die Modelle jedoch anwenden zu können, wurde die Annahme gesetzt, dass ein Monat immer explizit 4 Wochen umfasst. Sofern einige Monate gar fünf Wochen aufweisen, wurden „überschüssige“ Beobachtungen zu einer repräsentativen Woche mittels Durchschnittsbildung zusammengefasst. Dadurch kann es natürlich zu Verzerrungen kommen, gerade wenn besonders volatile Tage einmal in den laufenden und ein anderes Mal in den kommenden Monat fallen. Da die Saison- und Kalenderbereinigung jedoch Tages- und Wochenmuster gefiltert hat, sollte die Verzerrung zumindest zu einem gewissen Grade abgemildert worden sein.

¹ Für eine detaillierte Übersicht zu Modellen mit gemischten Frequenzen sei auf die Dissertation von Wohlrabe (2009a) verwiesen.

Die Schätz- und Prognosespezifikationen der MIDAS-Modelle sind analog zum Prognoseexperiment auf Monatsbasis gehalten.¹ Für den langen Zeitraum wird das MIDAS Modell erstmals für den Zeitraum Januar 2012 bis Dezember 2015 spezifiziert; für den kurzen Zeitraum erfolgt die erste Modellschätzung auf Basis der Daten von Januar 2015 bis Dezember 2018. Im Anschluss an die Berechnung des Now- und Forecasts wird der Schätzzeitraum um einen Monat erweitert, die Modelle neu spezifiziert und neuerliche Prognosen berechnet. Zudem erlaubt die MIDAS-Modellklasse auf Wochenbasis eine Evaluation der Prognosegüte innerhalb eines Monats – analog zur Vorgehensweise aus Abschnitt 5.4.2. Die Prognosegüte wird erneut mit der WMQPF bestimmt und mit dem Vergleichsmodell aus Abschnitt 5.2 verglichen.

5.4.4 Durchschnittliche Prognosefehler auf wöchentlicher Datenbasis

Die Ergebnisse des Prognoseexperiments mit unterschiedlichen Informationsständen innerhalb eines Monats sowie der MIDAS Regressionsmodelle auf Basis des Stromverbrauchs zweier VNB sind in Tabelle 8 dargestellt.

Tabelle 8: Wöchentliche relative Prognosegüte des Stromverbrauchs, Zeitraum 2012 bis 2020

Zeitpunkt	Modell 1	Modell 2	MIDAS
<i>Nowcast</i>			
Datenstand Woche 1	0,73	0,79	0,85
Datenstand Woche 2	0,72	0,79	0,85
Datenstand Woche 3	0,75	0,83	0,85
Datenstand Monatsende	0,64	0,72	0,84
<i>Forecast</i>			
Datenstand Woche 1	0,95	0,97	1,11
Datenstand Woche 2	0,95	0,98	1,03
Datenstand Woche 3	0,96	0,99	1,03
Datenstand Monatsende	0,95	0,95	1,03

Anmerkung: Prognosefehler des Stromverbrauchs dargestellt in Relation zum autoregressiven Benchmark-Modell für die bayerische Industrieproduktion (WMQPF Nowcast: 6,9 Prozentpunkte; WMQPF Forecast: 5,7 Prozentpunkte). Der Evaluationszeitraum umfasst die Jahre 2012 bis 2020, wobei die Prognosefehler auf den Jahren 2016 bis 2020 beruhen. Die Datenstände bilden unterschiedliche Prognosesituationen ab, wobei entweder der Stromverbrauch für den vollen Monat oder die ersten ein, zwei bzw. drei Wochen vorliegt. Angaben zum Stromverbrauch auf Basis der drei VNB LEW Verteilnetz GmbH, N-ERGIE Netz GmbH und SWM Infrastruktur GmbH & Co. KG. Quellen: Berechnungen des ifo Instituts.

¹ Die Prognosen wurden mit der MIDAS Matlab Toolbox Version 2.3 von Ghysels und Mitarbeitern durchgeführt, welche unter folgendem Link heruntergeladen werden kann: <https://de.mathworks.com/matlabcentral/fileexchange/45150-midas-matlab-toolbox>.

Insgesamt zeigt sich, dass die Nowcast-Prognosegüte innerhalb eines Monats mit einem höheren Informationsgehalt zunimmt. Die Ausnahme bilden die relativen Prognosefehler der dritten Woche. Maßgeblich hierfür ist aber die Prognoseperformance im Jahr 2020, welches im folgenden Abschnitt 5.4.5 näher beschrieben ist. Unabhängig davon liefern die Stromverbrauchsdaten auf Wochenebene bereits sehr frühzeitig verlässliche Informationen über die Entwicklung der bayerischen Industrieproduktion. So liegt der relative Prognosefehler beim Nowcast zum Datenstand am Ende der ersten Woche je nach Modell zwischen 0,73 und 0,85, was einer Verbesserung gegenüber dem Benchmark von 27% bzw. 15% entspricht. Mit Datenstand Woche 2 variiert der relative Prognosefehler zwischen 0,72 und 0,85; in Woche 3 liegt die Spanne zwischen 0,75 und 0,85. Die Prognosegüte beim Forecast variiert, mit Ausnahme der MIDAS-Modelle, nur geringfügig innerhalb des Monats. Die relativ besten Prognosen werden mit vollem Informationsstand am Ende des Monats erreicht.

Der Vergleich zwischen den Modellen basierend auf unterschiedlichen Informationsständen und den MIDAS Regressionsmodellen offenbart, das Letztere relativ gesehen etwas schlechter abschneiden als die Indikatormodelle. Zwei mögliche Erklärungen sind hier denkbar. Erstens könnte die hohe Volatilität der Wochendaten zusammen mit deren expliziter Modellierung die Prognosegüte etwas senken. Auch hier ist es möglich, dass die Saison- und Kalenderbereinigung der Wochendaten einen Einfluss auf die Prognosegüte hat. Da die Bereinigung von höherfrequenten Daten statistisches und akademisches Neuland ist, kann u.U. die bereits jetzt schon beobachtete hohe Prognosegüte nochmals verbessert werden. Zweitens könnte auch die Gewichtung des Lag-Polynoms bzw. die grundlegende Spezifikation der Gewichtungsfunktion im MIDAS-Modell das Prognoseergebnis beeinflussen. Jedoch wurden verschiedene Spezifikationen und Gewichtungsfunktionen ausprobiert und herausgefunden, dass die hier gewählte Spezifikation die höchste, durchschnittliche Prognosegüte liefert.

Abschließend sind in Tabelle 9 die relativen Prognosefehler für den kürzeren Zeitraum, aber auf Basis aller vier VNB präsentiert. Analog zu den Ausführungen für den längeren Evaluationszeitraum steigt die Prognosegüte innerhalb eines Monats mit Zunahme der verfügbaren Informationen an. Die Ausnahme bildet hier erneut Woche 3, was jedoch abermals auf die Prognoseleistung im Corona-Jahr 2020 zurückzuführen ist und im folgenden Abschnitt diskutiert wird.

Die Prognoseergebnisse auf Wochenebene unterstreichen nochmals die Resultate auf Monatsbasis: die bayerischen Stromverbrauchsdaten haben einen hohen prognostischen Gehalt für die hiesige Industrieproduktion. Darüber hinaus entpuppt sich die schnelle Verfügbarkeit der Stromverbrauchsdaten und deren hohe Frequenz als weiterer Pluspunkt, da bereits Informationen zum Stromverbrauch am Ende der ersten Woche ausreichend sind, um sehr zuverlässige Prognosen für die Produktion der bayerischen Industrie zu formulieren. Insgesamt sind damit die bayerischen Stromverbrauchsdaten eine wertvolle Ergänzung zu den bereits zur Verfügung stehenden und guten Konjunkturindikatoren des ifo Instituts.

Tabelle 9: Wöchentliche relative Prognosegüte des Stromverbrauchs, Zeitraum 2015 bis 2020

Zeitpunkt	Modell 1	Modell 2	MIDAS
<i>Nowcast</i>			
Datenstand Woche 1	0,70	0,74	0,82
Datenstand Woche 2	0,69	0,72	0,84
Datenstand Woche 3	0,71	0,75	0,84
Datenstand Monatsende	0,60	0,68	0,79
<i>Forecast</i>			
Datenstand Woche 1	0,92	0,94	1,07
Datenstand Woche 2	0,92	0,94	1,06
Datenstand Woche 3	0,93	0,95	1,07
Datenstand Monatsende	0,92	0,98	1,05

Anmerkung: Prognosefehler des Stromverbrauchs dargestellt in Relation zum autoregressiven Benchmark-Modell für die bayerische Industrieproduktion (WMQPF Nowcast: 11,7 Prozentpunkte; WMQPF Forecast: 9,1 Prozentpunkte). Der Evaluationszeitraum umfasst die Jahre 2015 bis 2020, wobei die Prognosefehler auf den Jahren 2019 und 2020 beruhen. Die Datenstände bilden unterschiedliche Prognosesituationen ab, wobei entweder der Stromverbrauch für den vollen Monat oder die ersten ein, zwei bzw. drei Wochen vorliegt. Angaben zum Stromverbrauch auf Basis aller vier Verteilnetzbetreiber. Quellen: Berechnungen des ifo Instituts.

5.4.5 Wochenergebnisse im Zeitverlauf

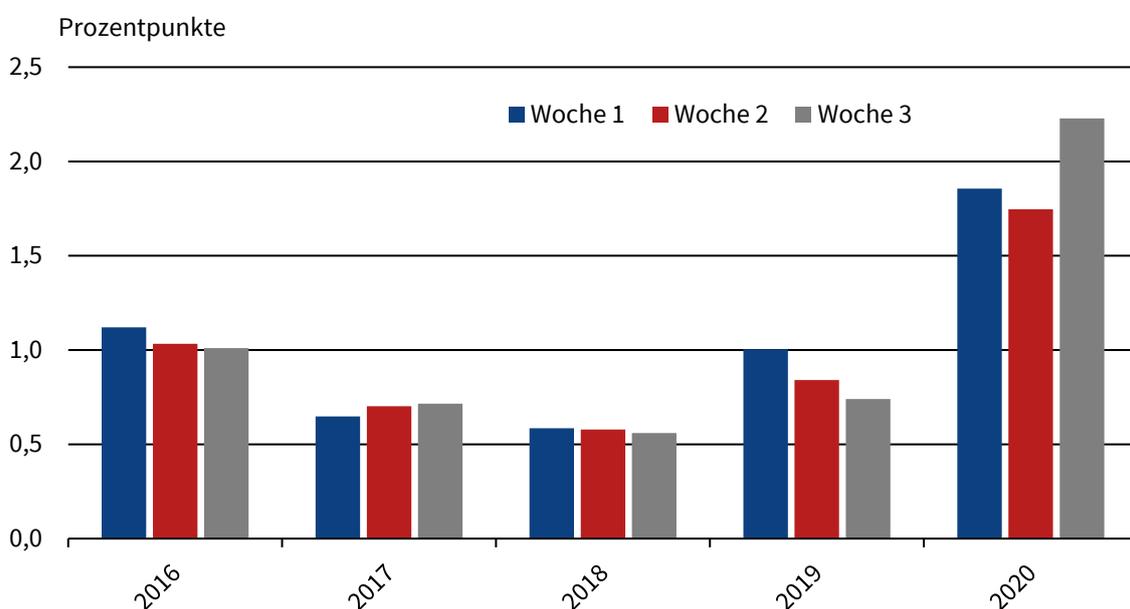
Die bisher präsentierten Ergebnisse zur Prognosegüte auf Wochenebene stellten lediglich auf die durchschnittliche Prognoseleistung im gesamten Evaluationszeitraum ab. Jedoch werden dadurch Schwankungen im Prognosegehalt über die Zeit hinweg unterdrückt. Im Folgenden wird die Entwicklung der Prognosegüte innerhalb eines Monats und für einzelne Jahre untersucht. Hierfür haben wir in einem ersten Schritt die Abweichungen der Prognosefehler eines Datenstands (z.B. am Ende von Woche 1) von den Prognosefehlern am Ende des Monats berechnet. Um die Saldierung positiver und negativer Abweichungen zu vermeiden, wurden die Abweichungen zwischen den Prognosefehlern in absoluten Werten ausgedrückt. Der letzte Schritt umfasste dann die Berechnung jahresspezifischer, durchschnittlicher Abweichungen zwischen den Informationsständen und den Fehlern auf Basis der Angaben für den vollständigen Monat.

Abbildung 36 zeigt die durchschnittlichen, absoluten Abweichungen für den Nowcast und die Jahre 2016 bis 2020. Hier bestätigt sich das Bild aus Abschnitt 5.4.4: die Prognosefehler werden absolut gesehen kleiner, je mehr Informationen zur Verfügung stehen. In der Abbildung ist das daran zu erkennen, dass die roten Balken kleiner als die blauen Balken sind und die Grauen wiederum kleiner als die Roten. Jedoch bilden die Jahre 2017 und 2020 die Ausnahme. Während die Abweichungen im Jahr 2017 je nach Datenstand noch recht gleich ausfallen, zeigt sich eine deutliche Verschlechterung der Prognose im Jahr 2020 mit dem Wechsel von Woche 2 auf Woche 3. Dies ist zudem auch die Erklärung dafür, warum die relativen Prognosefehler im Durchschnitt

aller betrachteten Jahre (vgl. Tabelle 8 und Tabelle 9) im Wechsel auf den Datenstand von der zweiten auf die dritte Woche zunimmt. Maßgeblich hierfür sind wenige Monate im Laufe des Jahres 2020, in welchen der Prognosefehler mit Datenstand Woche 3 deutlich ansteigt. Die Vermutung liegt auch hier nahe, dass u.U. die Bereinigung der saisonalen und kalendarischen Einflüsse sowie die Annahme eines 4-Wochen-Monats das Ergebnis verzerren könnten. Sofern die Stromverbrauchsdaten für Bayern auch in Zukunft regelmäßig zur konjunkturellen Beobachtung eingesetzt werden, sollte die Bereinigung ggf. auch mit den offiziellen statistischen Institutionen in Deutschland besprochen bzw. abgestimmt werden.

Abbildung 36: Abweichungen der Nowcast-Prognosefehler innerhalb eines Monats

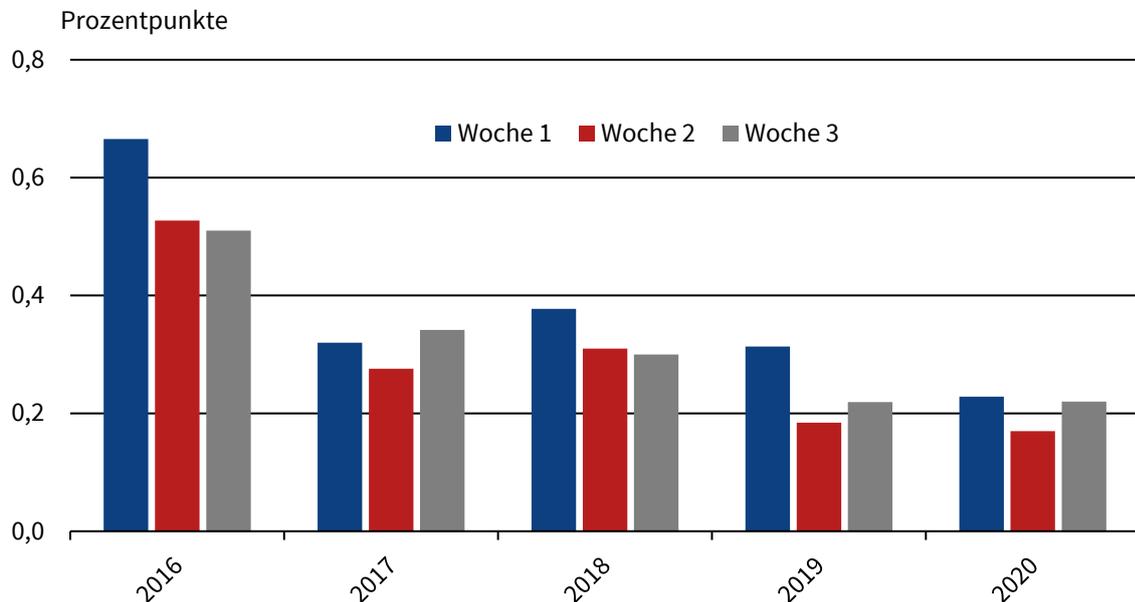
Absolute, durchschnittliche Abweichungen



Anmerkung: Abweichungen zwischen den wöchentlichen Prognosefehlern und den Prognosefehlern zum Informationsstand am Ende des Monats. Quellen: Berechnungen des ifo Instituts. © ifo Institut

Für die Abweichungen der Forecast-Prognosefehler zeigt sich ein etwas heterogenes Bild als beim Nowcast (vgl. Abbildung 37). Nur für die Jahre 2016 und 2018 zeigt sich eine durchschnittliche Verbesserung der Prognoseleistung innerhalb des Monats. Mit mehr Informationen zum Stromverbrauch sinken die absoluten, durchschnittlichen Abweichungen kontinuierlich zwischen dem Datenstand am Ende der ersten hin zur dritten Woche. In den verbleibenden drei Jahren steigen die Abweichungen der Prognosefehler zwischen zweiter und dritter Woche wieder etwas an, wenngleich auch nicht in erheblichem Umfang.

Abbildung 37: Abweichungen der Forecast-Prognosefehler innerhalb eines Monats

Absolute, durchschnittliche Abweichungen

Anmerkung: Abweichungen zwischen den wöchentlichen Prognosefehlern und den Prognosefehlern zum Informationsstand am Ende des Monats. Quellen: Berechnungen des ifo Instituts.

© ifo Institut

Erneut kann darüber spekuliert werden, welche Gründe dahinterstecken. Einerseits ist die Prognoseperformance der Stromverbrauchsdaten beim Forecast nur geringfügig besser als der Benchmark, so dass – unabhängig vom Datenstand – der Vorlauf des Stromverbrauchs nur schwach ausgeprägt ist. Andererseits könnte auch hier die Saison- und Kalenderbereinigung der Daten das Ergebnis beeinflussen. Die Wochendaten des bayerischen Stromverbrauchs sind bspw. sogar noch volatiler als der Lkw-Maut-Fahrleistungsindex, welcher beim Forecast ein besseres Ergebnis lieferte (vgl. Abschnitt 5.3). Daher ist es denkbar, dass ein etwas glatterer Verlauf der Stromverbrauchsdaten das ohnehin schon gute Prognoseergebnis sogar noch verbessern könnten. Gleiches gilt natürlich auch für die bayerische Industrieproduktion, für die ebenfalls kein saison- und kalenderbereinigtes Aggregat seitens der amtlichen Statistik veröffentlicht wird.

5.4.6 Vergleich der Prognosegüte mit anderen hochfrequenten Indikatoren

Neben den bayerischen Stromverbrauchsdaten stehen uns ebenfalls zwei weitere, hochfrequente Konjunkturindikatoren zur Verfügung: die Stromverbrauchsdaten für Deutschland und der Lkw-Maut-Fahrleistungsindex. Daher soll im Folgenden die wöchentliche Prognosegüte des Stromverbrauchs in Bayern der Treffsicherheit dieser beiden Indikatoren gegenübergestellt werden. Dabei wird sich bei diesem Vergleich auf Modell 1 sowie den MIDAS-Ansatz beschränkt, da Modell 2 de facto die gleichen Ergebnisse liefert wie Modell 1. Tabelle 10 stellt die wöchentliche relative Prognosegüte der drei hochfrequenten Indikatoren gegenüber.

Tabelle 10: Wöchentliche relative Prognosegüte hochfrequenter Indikatoren, Zeitraum 2012 bis 2020

Zeitpunkt	Modell 1			MIDAS		
	S-BY	S-DEU	Maut	S-BY	S-DEU	Maut
<i>Nowcast</i>						
Datenstand Woche 1	0,73	0,75	0,76	0,85	0,84	0,94
Datenstand Woche 2	0,72	0,75	0,75	0,85	0,87	0,90
Datenstand Woche 3	0,75	0,76	0,74	0,85	0,88	0,90
Datenstand Monatsende	0,64	0,74	0,65	0,84	0,85	0,87
<i>Forecast</i>						
Datenstand Woche 1	0,95	0,97	0,98	1,11	1,08	1,14
Datenstand Woche 2	0,95	0,97	0,97	1,03	1,02	1,10
Datenstand Woche 3	0,96	0,97	0,97	1,03	1,06	1,10
Datenstand Monatsende	0,95	0,96	0,94	1,03	1,06	1,09

Anmerkung: Prognosefehler dargestellt in Relation zum autoregressiven Benchmark-Modell für die bayerische Industrieproduktion (WMQPF Nowcast: 6,9 Prozentpunkte; WMQPF Forecast: 5,7 Prozentpunkte). Der Evaluationszeitraum umfasst die Jahre 2012 bis 2020, wobei die Prognosefehler auf den Jahren 2016 bis 2020 beruhen. Die Datenstände bilden unterschiedliche Prognosesituationen ab, wobei die Indikatoren entweder für den vollen Monat oder die ersten ein, zwei bzw. drei Wochen vorliegen. Angaben zum bayerischen Stromverbrauch auf Basis der drei VNB LEW Verteilnetz GmbH, N-ERGIE Netz GmbH und SWM Infrastruktur GmbH & Co. KG. Stromverbrauchsdaten für Bayern und Deutschland entsprechend abgekürzt: S-BY, S-DEU. Quellen: Berechnungen des ifo Instituts.

Für den Nowcast liefern alle drei Indikatoren bei der Anwendung des ersten Modells ähnlich gute Prognoseergebnisse je nach Informationsstand innerhalb eines Monats, wenngleich die bayerischen Stromverbrauchsdaten (S-BY) immer etwas kleinere durchschnittliche Prognosefehler generieren als die deutschen Stromverbrauchsdaten (S-DEU) sowie der Lkw-Maut-Fahrleistungsindex (Maut). Ein analoges Bild für den Nowcast liefert der MIDAS-Ansatz, wobei die Unterschiede zwischen den Stromverbrauchsdaten und dem Lkw-Maut-Fahrleistungsindex hier ausgeprägter ausfallen.

Bei der Betrachtung des Forecasts bestätigen sich die Erkenntnisse des Nowcast. Insgesamt sind die Prognoseleistungen der Indikatoren nur etwas besser als jene des Benchmark-Modells, sofern Modell 1 betrachtet wird. Auch hier produzieren die bayerischen Stromverbrauchsdaten die relativ geringsten Prognosefehler. Im Falle des MIDAS-Ansatzes können die hochfrequenten Konjunkturindikatoren allesamt das Benchmark-Modell – unabhängig vom Datenstand innerhalb des Monats – im Durchschnitt nicht schlagen.

Der abschließende Vergleich bestätigt die positiven Ergebnisse der vorherigen Abschnitte: die bayerischen Stromverbrauchsdaten liefern einen Mehrwert für die Prognose der bayerischen Industrieproduktion. Welche Schlussfolgerungen sich daraus für die angewandte Prognosearbeit an wirtschaftlichen Kennziffern für Bayern ergeben, wird im folgenden Unterabschnitt erörtert.

5.5 Schlussfolgerungen für die angewandte Prognose

Bei der Erstellung von Prognosen einzelner wirtschaftlicher Kennziffern verfolgt das ifo Institut den Ansatz, eine Vielzahl potentiell zur Verfügung stehender Indikatoren gleichzeitig zu nutzen und spezifiziert seine zum Einsatz kommenden Modelle entsprechend. So wird bspw. die BWS einzelner Wirtschaftsbereiche mittels so genannter Kombinationsansätze bzw. Pooling-Methoden prognostiziert (vgl. Carstensen et al. 2009). Der am häufigsten zum Einsatz kommende Kombinationsansatz ist dabei der Mittelwert der einzelnen Prognosen. Für das deutsche BIP hat sich mittlerweile ein dynamisches Faktormodell durchgesetzt, welches die Basis für die zweimal im Monat automatisch veröffentlichten Prognosen im Rahmen von ifoCAST darstellt (vgl. Lehmann et al. 2020).¹ Dabei wird die Vielzahl an Indikatoren reduziert auf einen einzelnen Faktor. Ein bekannter Vertreter der Faktormodelle ist die Hauptkomponentenanalyse.

Die Nutzung mehrerer Indikatoren hat den Vorteil, unterschiedliche prognostische Signale gleichzeitig zu berücksichtigen. So kommt es bei der angewandten Prognose regelmäßig vor, dass eine Vielzahl von Indikatoren eine deutliche Beschleunigung der Wirtschaftsleistung nahelegen, während andere wichtige Indikatoren eher eine gemächliche Gangart anzeigen oder gar – im Extremfall – einen Rückgang. Es ist dann die Aufgabe des Anwenders bzw. der Anwenderin, aus diesen unterschiedlichen Signalen die wahrscheinlichste Prognose abzuleiten. In der akademischen Literatur hat sich bspw. der (gewichtete) Mittelwert oder Median der Einzelprognosen als recht treffsicher erwiesen (vgl. Drechsel und Maurin 2011, Lehmann und Wohlrabe 2015). Demzufolge ist es sinnvoll immer auf eine Vielzahl von Indikatoren gleichzeitig zu schauen. Somit wird der Indikatorsatz für Bayern durch einen weiteren, sehr guten Indikator ergänzt: die Stromverbrauchsdaten. Nunmehr steht für Bayern auch ein brauchbarer, hochfrequenter Konjunkturindikator zur Verfügung, der die monatlichen ifo Indikatoren mit ihrer hohen Treffsicherheit und ihren Vorlaufeigenschaften sinnvoll ergänzt. Damit wird das Prognoserisiko, welches sich durch die exklusive Fokussierung auf einen einzelnen Indikator ergibt, merklich gesenkt und dürfte in der Praxis zu geringeren Prognosefehlern führen.

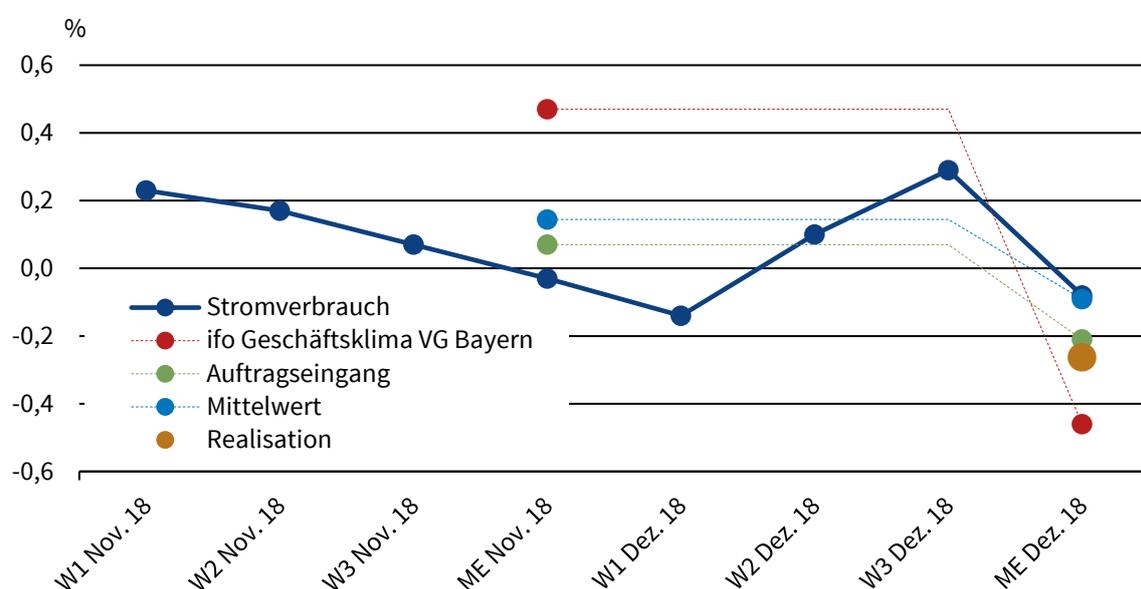
Die hochfrequente Natur der bayerischen Stromverbrauchsdaten ermöglicht es zudem, eine automatisierte und mechanische Prognoseerstellung innerhalb eines Monats durchzuführen. Je nach Informationsstand (Ende der ersten, zweiten oder dritten Woche bzw. am Monatsende) kann abgelesen werden, zu welcher Prognose der bayerischen Industrieproduktion der vorliegende Datenstand führt. Exemplarisch ist der Prognoseverlauf für die Monate Dezember 2018 und Juli 2019 in Abbildung 38 und Abbildung 39 dargestellt. Die horizontale Achse bildet dabei den Informationsstand ab, welcher entweder auf einem entsprechenden Wochenwert beruht (W1, W2, W3) oder das Monatsende (ME) repräsentiert. So können bspw. für den Dezember 2018 auf Basis der wöchentlichen Stromverbrauchsdaten acht Prognosen formuliert werden: in den ersten drei Wochen oder am Monatsende November 2018, was dem Forecast entspricht, oder im

¹ Regelmäßige Prognoseupdates zum deutschen BIP finden sich unter: <https://www.ifo.de/ifoCAST>.

Verlauf des Dezembers 2018, was den Nowcast darstellt. Hinzu kommen je zwei Prognosen am Monatsende auf Basis der ausschließlich auf Monatebene veröffentlichten Indikatoren wie bspw. dem ifo Geschäftsklima Verarbeitendes Gewerbe Bayern oder die Auftragseingänge; diese Prognosen werden bis zur nächsten Veröffentlichung dieser Indikatoren nicht automatisch angepasst, weshalb die jeweils beiden Punkte mit einer gestrichelten, horizontalen Linie verbunden sind und erst am Monatsende eine neue Ausprägung annehmen. Darüber hinaus können die Prognosen der einzelnen Indikatoren zu einer Zahl verdichtet werden, was im vorliegenden Falle durch den einfachen Mittelwert aller Prognosen dargestellt ist.

Abbildung 38: Exemplarischer Prognoseverlauf für Dezember 2018

Punktprognosen für die bayerische Industrieproduktion, Dezember 2018



Anmerkung: Mittelwert aller zur Verfügung stehenden Indikatoren und nicht ausschließlich der drei gezeigten. Quellen: Berechnungen des ifo Instituts.

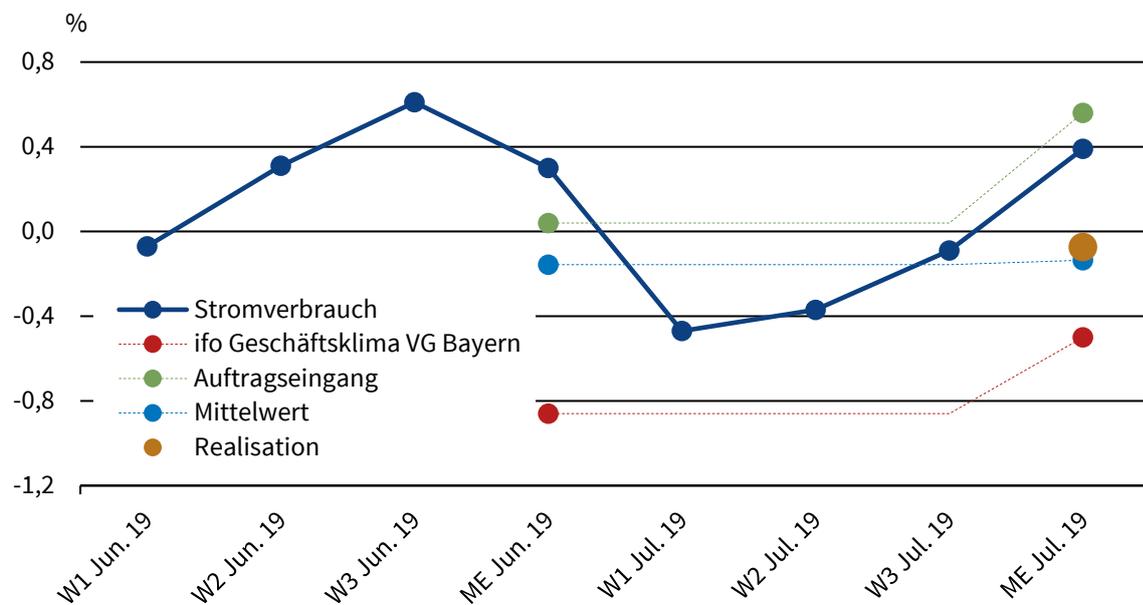
© ifo Institut

Im Verlauf des Novembers 2018 hat sich die Prognose auf Basis der Stromverbrauchsdaten sukzessive verschlechtert – von 0,23% in der ersten Novemberwoche bis hin zu -0,14% in der ersten Dezemberwoche. Nach zwei anschließenden Verbesserungen wurde am Monatsende Dezember 2018 ein Rückgang von 0,08% prognostiziert. Die übrigen, exemplarischen Indikatoren wie der Auftragseingang und das ifo Geschäftsklima Verarbeitendes Gewerbe Bayern legten zunächst einen Anstieg der Produktion am Monatsende November 2018 (Forecast) nahe. Mit der Veröffentlichung des Dezemberwerts hingegen drehten die Prognosen auf Basis beider Indikatoren deutlich ins Minus (Nowcast); eine analoge Entwicklung ist für den Mittelwert beobachtbar. Am Ende wird Abbildung 38 durch die tatsächliche Realisation der bayerischen Industrieproduktion (oranger Punkt, -0,26%) ergänzt, so dass unmittelbar die Prognosefehler abgelesen werden können und die Prognoseperformance über die Zeit verdeutlicht wird.

Der zweite exemplarische Verlauf ist für den Juli 2019 dargestellt (vgl. Abbildung 39). Hier hat sich die Prognose auf Basis der bayerischen Stromverbrauchsdaten sukzessive verbessert, bevor es zu einer deutlichen Abwärtsrevision in der ersten Juliwoche 2019 kam. Mit Verbesserung des Stromverbrauchs innerhalb des Juli 2019 hat sich auch die Prognose wieder erholt. Im Beispiel für Juli 2019 zeigt sich exemplarisch, dass die Mittelwertprognose in der Tat das Prognoserisiko verringern kann, da sie am Monatsende Juli mit -0,14% sehr nah an der Realisation (-0,07%) lag. Die Betrachtung der Mittelwertprognosen über den gesamten Zeitraum bestätigt diesen Eindruck. Wird bspw. eine gewichtete Mittelwertprognose verwendet, welche den schlechteren Indikatoren ein niedrigeres Gewicht beimisst als besseren, beträgt der relative Fehler im Vergleich zum bayerischen Stromverbrauch für den Nowcast 0,90 und 0,89 für den Forecast. Damit führt eine gewichtete Durchschnittsbetrachtung auch für Bayern zur Senkung des Prognoserisikos.

Abbildung 39: Exemplarischer Prognoseverlauf für Juli 2019

Punktprognosen für die bayerische Industrieproduktion, Juli 2019



Anmerkung: Mittelwert aller zur Verfügung stehenden Indikatoren und nicht ausschließlich der drei gezeigten. Quellen: Berechnungen des ifo Instituts.

© ifo Institut

Die exemplarischen Verläufe für die Monate Dezember 2018 und Juli 2019 könnten zukünftig auch für eine automatisierte Konjunkturberichterstattung für die Industrie des Freistaats Bayern dienen oder den Input für ein Konjunkturdashboard darstellen, welches die aktuelle Konjunkturlage in Bayern näher beleuchtet. Die hochfrequente Natur der Stromverbrauchsdaten lässt bspw. Prognosen auf wöchentlicher Basis zu, die durch andere Indikatoren am Monatsende ergänzt werden. Ob tägliche Prognosen sinnvoll sind, müsste zunächst geprüft werden. Jedoch nimmt die Schwankungsanfälligkeit der Daten erheblich zu, je höher die Frequenz gewählt wird. Dies könnte die konjunkturelle Grundtendenz in den Stromverbrauchsdaten erheblich verwässern und die eigentlich hohe Prognosekraft spürbar verzerren.

6 Fazit und Schlussfolgerungen

Die hochfrequenten Stromverbrauchsdaten der bayerischen Verteilnetzbetreiber sind vor dem Hintergrund der in diesem Abschlussbericht präsentierten Ergebnisse insgesamt eine sehr vielversprechende Datenquelle zur Wirtschafts- und Konjunkturanalyse auf regionaler Ebene. Zum einen sind die aggregierten Stromverbrauchsdaten dazu geeignet, die konjunkturellen Ausschläge der bayerischen Industrieproduktion zu datieren. So werden besonders die schweren und tiefen Rezessionen sowie die sich anschließenden Erholungsphasen zuverlässig vom Stromverbrauch angezeigt. Zum anderen weisen die bayerischen Stromverbrauchsdaten eine hohe Prognose-tauglichkeit für die Vorhersage der Industrieproduktion Bayerns sowohl auf Monats- als auch Wochenbasis auf. Der Stromverbrauch stellt daher einen brauchbaren Indikator für die industrielle Entwicklung in Bayern dar und ist damit eine wertvolle Ergänzung zu den bereits vorhandenen qualitativen Umfrageindikatoren des ifo Instituts.

Bei der Untersuchung der Energieeffizienz finden sich rein deskriptiv Brüche im Zeitverlauf der aggregierten Stromverbrauchsdaten nach Verteilnetzbetreiber, was auf die Einführung energiepolitischer Maßnahmen wie bspw. die Energieeffizienzrichtlinie zurückgeführt werden könnte. Der Vergleich der Nachfragespitzen in Bayern mit jenen aus Deutschland insgesamt offenbart, dass insbesondere die Nachfragespitzen am Morgen zwischen beiden Betrachtungseinheiten auseinanderfallen. Somit könnte die Vermeidung von Systemspitzen das Gleichgewicht des Netzes insgesamt verbessern. Zudem scheint es einen positiven Zusammenhang zwischen dem Stromverbrauch und der Konzentration von Luftschadstoffen zu geben, so dass Nachfragesteuerung und die Erhöhung der Energieeffizienz auch zu einer möglichen Verbesserung der Luftqualität beitragen könnten.

Unter der Maßgabe der präsentierten Ergebnisse kann insgesamt festgehalten werden, dass eine fortlaufende Auswertung und Verwendung der bayerischen Stromverbrauchsdaten einen erheblichen Mehrwert generiert. Jedoch wäre es lohnenswert, den Detailgrad der Auswertungen zu erhöhen und die Datenaufbereitung mit amtlichen Institutionen feiner abzustimmen. So wären einerseits bspw. disaggregiertere Daten (z.B. anonymisierte Informationen über die Endabnehmer, Firmenzugehörigkeit zu einem gewissen Wirtschaftsbereich etc.) der Verteilnetzbetreiber wünschenswert, um eindeutige – und vielleicht sogar kausale – Schlussfolgerungen bei der Frage der Energieeffizienz zu formulieren. Gleiches gilt für die Untersuchungen zur Nachfragesteuerung, bei welcher der Preis als Steuerungselement eine zentrale Rolle einnimmt. Für die Prognose und Zyklendatierung wäre es andererseits wichtig, mit der amtlichen Statistik in Deutschland zusammenzuarbeiten, um die Saison- und Kalenderbereinigung sowohl der Stromverbrauchsdaten als auch der bayerischen Industrieproduktion zu verbessern. Insbesondere bei neuen, alternativen Datenquellen besteht hier noch erheblicher Forschungsbedarf, der auf der regionalen Ebene noch ausgeprägter ausfallen dürfte. Das ifo Institut hat hier neues akademischen Terrain betreten und es ist durchaus denkbar, dass das sehr gute Prognoseergebnis der Stromverbrauchsdaten durch solche Anpassungen noch verbessert werden kann.

Für die angewandte Prognose haben unsere Ergebnisse ebenfalls Implikationen. Nun stehen auf wöchentlicher und monatlicher Ebene eine Vielzahl guter Konjunkturindikatoren für den Freistaat Bayern zur Verfügung. Diese Informationen könnten für eine automatisierte Konjunkturberichterstattung der bayerischen Industrie oder als Input für ein Konjunkturdashboard dienen, welches regelmäßig die konjunkturelle Situation im Verarbeitenden Gewerbe Bayerns näher beleuchtet. Darüber hinaus wäre es ebenfalls denkbar, weitere alternative Datenquellen zu untersuchen, um ggf. ein umfassendes gesamtwirtschaftliches Bild für den Freistaat Bayern zu zeichnen und den Blick nicht nur ausschließlich auf die hiesige Industrie zu fokussieren.

Literaturverzeichnis

- Aastveit, K. A., Fastbø, T. M., Granziera, E., Sæterhagen Paulsen, K. und K. Næss Torstensen (2020): Nowcasting Norwegian household consumption with debit card transaction data, Norges Bank Working Paper No. 17/2020.
- Abberger, K. und W. Nierhaus (2007): Das ifo Geschäftsklima und Wendepunkte der deutschen Konjunktur, ifo Schnelldienst 60 (3), S. 26-31.
- Agora Energiewende (2021): Zukünftige Anforderungen an eine energiewendegerechte Netzkostenallokation, Impuls, 224/11-I-2021/DE, Berlin.
- Anderson, S. T. und R. G. Newell (2004): Information programs for technology adoption: the case of energy-efficiency audits, Resource and Energy Economics 26 (1), S. 27–50.
- Arnold, K. und T. Janssen (2016): Demand side management in industry: necessary for a sustainable energy system or a backward step in terms of improving efficiency? eceee Industrial Summer Study Proceedings, 3-022-16, S. 339–350.
- Askatas, N. und K. F. Zimmermann (2013): Nowcasting business cycles using Toll data, Journal of Forecasting 32 (4), S. 299-306.
- Bauer, A., Leiss, F. und K. Wohlrabe (2021): Konjunkturumfrage Bayern Dezember 2020, abgerufen unter dem Link: https://www.stmwi.bayern.de/fileadmin/user_upload/stmwi/E-Paper/catalogs/Konjunkturtest_dez_2020/pdf/complete.pdf.
- Bénabou, R. und J. Tirole (2011): Laws and Norms, NBER Working Paper No. 17579.
- Borenstein, S. (2015): A Microeconomic Framework for Evaluating Energy Efficiency Rebound and Some Implications, The Energy Journal 36 (1), S. 1–21.
- Bry, G. und C. Boschan (1971): Cyclical Analysis of Time Series: Selected Procedures and Computer Programs, National Bureau of Economic Research, New York.
- Bundesministerium für Wirtschaft und Energie (2019): Zweiter Fortschrittsbericht zur Energiewende: Die Energie der Zukunft, Berichtsjahr 2017 – Kurzfassung, Berlin.
- Carstensen, K., Henzel, S., Mayr, J. und K. Wohlrabe (2009): IFOCAST: Methoden der ifo-Kurzfristprognose, ifo Schnelldienst 62 (23), S. 15-28.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E. und I. Terpenning (1990): STL: A Seasonal-Trend Decomposition Procedure Based on Loess, Journal of Official Statistics 6 (1), S. 3-33.

- Cox, M., Berghausen, M., Linz, S., Fries, C. und J. Völker (2018): Digitale Prozessdaten aus der Lkw-Mauterhebung – Neuer Baustein der amtlichen Statistik, WISTA – Wirtschaft und Statistik 6/2018, S. 11-32.
- Cox, M., Triebel, J., Linz, S., Fries, C., Flores, L. F., Lorenz, A., Ollech, D., Dietrich, A., LeCrone, J. und K. Webel (2020): Täglicher Lkw-Maut-Fahrleistungsindex aus digitalen Prozessdaten der Lkw-Mauterhebung, WISTA – Wirtschaft und Statistik 4/2020, S. 63-76.
- Deutsche Energie-Agentur (2018): Impulse zur Weiterentwicklung der Netzentgeltsystematik: Industrielles Verbrauchsverhalten im Rahmen der Energiewende netzdienlich gestalten, Ergebnispapier der Taskforce Netzentgelte, Berlin.
- Drechsel, K. und L. Maurin (2011): Flow of Conjunctural Information and Forecast of Euro Area Activity, Journal of Forecasting 30 (3), S. 336-354.
- Eicke, A., Ruhnau, O. und L. Hirth (2021): Electricity balancing as a market equilibrium: An instrument-based estimation of supply and demand for imbalance energy, Energy Economics 102, 105455.
- Ellingsen, J., Larsen, V. und L. A. Thorsrud (2020): News Media vs. FRED-MD for Macroeconomic Forecasting, CESifo Working Paper No. 8639.
- Eraslan, S. und T. Götz (2020): An unconventional weekly economic activity index for Germany, Deutsche Bundesbank Technical Paper No. 02/2020.
- Europäische Kommission (2016): Saubere Energie für alle Europäer, Mitteilung der Kommission an das Europäische Parlament, den Rat, den Wirtschafts- und Sozialausschuss, den Ausschuss der Regionen und die Europäische Investitionsbank, COM(2016) 860 final, Brüssel.
- Europäische Union (2018a): Förderung der Nutzung von Energie aus erneuerbaren Quellen, Richtlinie (EU) 2018/2001 des Europäischen Parlaments und des Rates vom 11. Dezember 2018, Amtsblatt der Europäischen Union L328/82, Brüssel.
- Europäische Union (2018b): Änderung der Richtlinie 2012/27/EU zur Energieeffizienz, Richtlinie (EU) 2018/2002 des Europäischen Parlaments und des Rates vom 11. Dezember 2018, Amtsblatt der Europäischen Union L328/210, Brüssel.
- Expertenkommission (2019): Stellungnahme zum zweiten Fortschrittsbericht der Bundesregierung für das Berichtsjahr 2017, Expertenkommission zum Monitoring-Prozess „Energie der Zukunft“, Berlin, Münster, Stuttgart 2019.
- Fornaro, P. (2020): Nowcasting Industrial Production Using Unconventional Data Sources, ETLA Working Papers No. 80.

- Ghysels, E., Santa-Clara, P. und R. Valkanov (2004): The MIDAS Touch: Mixed Data Sampling Regression Models, mimeo, abgerufen unter dem Link: <https://rady.ucsd.edu/faculty/directory/valkanov/pub/docs/midas-touch.pdf>.
- Gillingham, K. und K. Palmer (2014): Bridging the Energy Efficiency Gap: Insights for Policy from Economic Theory and Empirical Analysis, *Review of Environmental Economics and Policy* 8 (1), S. 18-38.
- Götz, T. und T. Knetsch (2019): Google data in bridge equation models for German GDP, *International Journal of Forecasting* 35 (1), S. 45-66.
- Haas, C. und K. Kempa (2018): Directed Technical Change and Energy Intensity Dynamics: Structural Change vs. Energy Efficiency, *The Energy Journal* 39 (4), S. 127-151.
- Harding, D. und A. Pagan (2002): Dissecting the cycle: a methodological investigation, *Journal of Monetary Economics* 49 (2), S. 365-381.
- Harding, D. und A. Pagan (2003): A comparison of two business cycle dating methods, *Journal of Economic Dynamics & Control* 27 (9), S. 1681-1690.
- Hauf, S., Stehrenberg, S. und M. Zwick (2020): EXDAT – Experimentelle Daten und Methoden für eine innovative Statistik, *WISTA – Wirtschaft und Statistik* 4/2020, S. 51-62.
- Hendricks, B. E., Neilson, J. J., Shakespeare, C. und C. D. Williams (2021): Anticipatory effects around proposed regulation: Evidence from Basel III, *Ross School of Business Paper No. 1213*.
- Janzen, B. und D. Radulescu (2020): Electricity Use as a Real-Time Indicator of the Economic Burden of the COVID-19-Related Lockdown: Evidence from Switzerland, *CESifo Economic Studies* 66 (4), S. 303-321.
- Krzikalla, N., Achner, S. und S. Brühl (2013): Möglichkeiten zum Ausgleich fluktuierender Einspeisungen aus Erneuerbaren Energien, Studie im Auftrag des Bundesverbandes Erneuerbare Energien, Aachen.
- Lehmann, R. (2020): The Forecasting Power of the ifo Business Survey, *CESifo Working Paper No. 8291*.
- Lehmann, R., Leiss, F., Litsche, S., Sauer, S., Weber, M., Weichselberger, A. und K. Wohlrabe (2019): Mit den ifo-Umfragen regionale Konjunktur verstehen, *ifo Schnelldienst* 72 (9), S. 45-49.
- Lehmann, R., Reif, M. und T. Wollmershäuser (2020): ifoCAST: Der neue Prognosestandard des ifo Instituts, *ifo Schnelldienst*, 73 (11), S. 31-39.

- Lehmann, R. und K. Wohlrabe (2015): Forecasting GDP at the Regional Level with many Predictors, German Economic Review 16 (2), S. 226-254.
- Lehmann, R. und K. Wohlrabe (2017): Boosting and Regional Economic Forecasting: The Case of Germany, Letters in Spatial and resource Sciences 10 (2), S. 161-175.
- Lemoine, D. (2017): Green Expectations: Current Effects of Anticipated Carbon Pricing, The Review of Economics and Statistics 99 (3), S. 499-513.
- Lewis, D., Mertens, K. und J. H. Stock (2020): U.S. Economic Activity During the Early Weeks of the SARS-Cov-2 Outbreak, NBER Working Paper No. 26954.
- Linz, S., Fries, C. und J. Völker (2018): Saisonbereinigung der Konjunkturstatistiken mit X-12-ARIMA und mit X13 in JDemetra+, WISTA – Wirtschaft und Statistik 4/2018, S. 59-80.
- Logenthiran, T., Srinivasan, D. und T. Z. Shun (2012): Demand Side Management in Smart Grid Using Heuristic Optimization, IEEE Transactions on Smart Grid 3 (3), S. 1244-1252.
- Lourenço, N. und A. Rua (2021): The Daily Economic Indicator: tracking economic activity daily during the lockdown, Economic Modelling 100, 105500.
- Marcellino, M. und C. 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), S. 518-550.
- Nierhaus, W. und J.-E. Sturm (2020): Methoden der Konjunkturprognose. In: Sauer, S. und K. Wohlrabe (Hrsg.) (2020): ifo Handbuch der Konjunkturumfragen, Kapitel 9.2, S. 223-241.
- Palensky, P. und D. Dietrich (2011): Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads, IEEE Transactions on Industrial Informatics 7 (3), S. 381-388.
- Prognos, Öko-Institut und Wuppertal Institut (2021): Klimaneutrales Deutschland 2045: Wie Deutschland seine Klimaziele schon vor 2050 erreichen kann, Studie im Auftrag von Stiftung Klimaneutralität, Agora Energiewende und Agora Verkehrswende, Berlin / Wuppertal 2021, abrufbar unter: https://static.agora-energiewende.de/fileadmin/Projekte/2021/2021_01_DE_KNDE2045/KNDE2045_Langfassung.pdf.
- Projektgruppe Gemeinschaftsdiagnose (2018): Deutsche Wirtschaft im Boom – Luft wird dünner, Gemeinschaftsdiagnose Frühjahr 2018, München, abrufbar unter: https://gemeinschaftsdiagnose.de/wp-content/uploads/2018/04/GD_F18_Langfassung_20180420.pdf.
- Sauer, S. (2020): ifo Konjunkturumfragen: Ein Überblick über die verfügbaren Zeitreihen, ifo Schnelldienst 73 (2), S. 45-48.

- Sauer, S. und K. Wohlrabe (Hrsg.) (2020): ifo Handbuch der Konjunkturumfragen, ifo Beiträge zur Wirtschaftsforschung 88, München 2020.
- Schirwitz, B. (2009): A comprehensive German business cycle chronology, *Empirical Economics* 37 (2), S. 287-301.
- Schirwitz, B., Seiler, C. und K. Wohlrabe (2009a): Regionale Konjunkturzyklen in Deutschland – Teil I: Die Datenlage, *ifo Schnelldienst* 62 (13), S. 18-24.
- Schirwitz, B., Seiler, C. und K. Wohlrabe (2009b): Regionale Konjunkturzyklen in Deutschland – Teil II: Die Zyklendatierung, *ifo Schnelldienst* 62 (14), S. 24-31.
- Schirwitz, B., Seiler, C. und K. Wohlrabe (2009c): Regionale Konjunkturzyklen in Deutschland – Teil II: Die Konvergenz, *ifo Schnelldienst* 62 (15), S. 23-32.
- Statistisches Bundesamt (Hrsg.) (2007): Gliederung der Klassifikation der Wirtschaftszweige, Ausgabe 2008 (WZ 2008), Wiesbaden 2007.
- Statistisches Bundesamt (Hrsg.) (2017): Volkswirtschaftliche Gesamtrechnungen, Vierteljährliche Inlandsproduktberechnung nach ESVG 2010, Methoden und Grundlagen Ausgabe 2017, Fachserie 18 Reihe S. 31, Wiesbaden 2017.
- Vosen, S. und T. Schmidt (2012): A monthly consumption indicator for Germany based on Internet search query data, *Applied Economics Letters* 19 (7), S. 683-687.
- Wohlrabe, K. (2009a): *Forecasting with Mixed-frequency Time Series Models*, Inaugural-Dissertation an der Ludwig-Maximilians-Universität München.
- Wohlrabe, K. (2009b): Makroökonomische Prognosen mit gemischten Frequenzen, *ifo Schnelldienst* 62 (21), S. 22-33.
- Yue, H., Worrell, E. und W. Crijns-Graus (2021): Impacts of regional industrial electricity savings on the development of future coal capacity per electricity grid and related air pollution emissions – A case study for China, *Applied Energy* 282 (B), 116241.
- Zhang, S., Worrell, E. und W. Crijns-Graus (2015): Evaluating co-benefits of energy efficiency and air pollution abatement in China's cement industry, *Applied Energy* 147, S. 192–213.

Datenquellen

AG Energiebilanzen (Hrsg.) (2020): Energieintensität in Deutschland – Ausgewählte Kennziffern als Zeitreihe von 1990 bis 2019 (Stand November 2020), abrufbar unter: <https://ag-energiebilanzen.de/38-0-Effizienzindikatoren.html>.

AG Energiebilanzen e.V. (Hrsg.) (2021): Energieverbrauch in Deutschland im Jahr 2020, abrufbar unter: <https://ag-energiebilanzen.de>.

Arbeitskreis Volkswirtschaftliche Gesamtrechnungen (VGR) der Länder (Hrsg.) (2020): Bruttoinlandsprodukt, Bruttowertschöpfung in den Ländern der Bundesrepublik Deutschland 1991 bis 2019, Berechnungsstand: August 2019/Februar 2020, Reihe 1, Länderergebnisse Band 1, Stuttgart 2020.

Bayerisches Landesamt für Statistik (Hrsg.) (2021a): Index der Produktion für das Verarbeitendes Gewerbe in Bayern im Dezember 2020 (sowie Bergbau und Gewinnung von Steinen und Erden), Basisjahr 2015, Statistische Berichte E I 2 m 12/2020, Fürth 2021.

Bayerisches Landesamt für Statistik (Hrsg.) (2021b): Index des Auftragseingangs für das Verarbeitendes Gewerbe in Bayern im Dezember 2020, Basisjahr 2015, Statistische Berichte E I 3 m 12/2020, Fürth 2021.

Bundesnetzagentur (Hrsg.) (2021): SMARD – Strommarktdaten für Deutschland, Daten abrufbar unter folgenden Link: <https://www.smard.de/home>.

European Network of Transmission System Operators for Electricity (ENTSO-E) (Hrsg.) (2021): Monthly Hourly load values 2006-2015, abrufbar unter dem folgenden Link: <https://www.entsoe.eu/data/power-stats>.

Anhang

Bry-Boschan-Algorithmus

Der monatliche Datierungsalgorithmus nach Bry und Boschan (1971) sowie die Erweiterung auf Quartalsdaten (BBQ) nach Harding und Pagan (2002) basieren auf den folgenden einfachen, mathematischen Entscheidungsregeln. Ein lokaler Hochpunkt zum Zeitpunkt t („peak“, P_t) einer ökonomischen Kenngröße y_t ist definiert als:

$$P_t = \{(y_{t-k}, \dots, y_{t-2}, y_{t-1}) < y_t > (y_{t+1}, y_{t+2}, \dots, y_{t+k})\}.$$

Demnach gilt die heutige Ausprägung der ökonomischen Kenngröße als lokaler Hochpunkt – gegeben zusätzlich spezifizierter Regeln – sofern die k vorherigen und nachfolgenden Ausprägungen unter dem heutigen Niveau liegen. Analog zum Hochpunkt ist der lokale Tiefpunkt zum Zeitpunkt t („trough“, T_t) der ökonomischen Kenngröße y_t definiert als:

$$T_t = \{(y_{t-k}, \dots, y_{t-2}, y_{t-1}) > y_t < (y_{t+1}, y_{t+2}, \dots, y_{t+k})\}.$$

Somit liegt ein lokaler Tiefpunkt vor, wenn die heutige Ausprägung der ökonomischen Kenngröße unter den k vorherigen und nachfolgenden Ausprägungen liegt. In unserem Falle spezifizieren wir $k = 2$ Quartale für beide Wendepunkte. Zusätzlich definieren wir, dass Auf- und Abschwünge mindestens zwei Quartale andauern müssen und ein kompletter Zyklus über mindestens fünf Quartale definiert ist („censoring rules“).

Maß der Phasenüberlappung

Das Maß der Phasenüberlappung nach Harding und Pagan (2002), auch Konkordanzindex (C) genannt, misst den Zeitanteil, in dem zwei datierte Kenngrößen sich in der gleichen Konjunkturphase befinden. Wir verwenden die formale Definition nach Schirwitz et al. (2009c, S. 27),

$$C_{I,IP} = \frac{1}{T} \sum_{t=1}^T [S_{I,t}S_{IP,t} + (1 - S_{I,t})(1 - S_{IP,t})],$$

wobei $S_{I,t} = 1$ gilt, wenn Indikator I sich zum Zeitpunkt t im Aufschwung befindet; $S_{I,t} = 0$ entspricht demzufolge dem Abschwung. Verglichen werden die Phasen des jeweiligen Indikators immer mit jenen der Industrieproduktion (IP). Sofern alle Ausprägungen identisch sind, nimmt das Maß der Überlappung den Wert Eins an. Sind die Phasen des Indikators und der Industrieproduktion diametral zueinander, entspricht das Maß der Phasenüberlappung dem Wert Null.

Prognosemodelle

Für das Prognoseexperiment werden zwei Indikatormodelle (1) und (2) sowie ein Benchmark (3) spezifiziert. Die mathematische Repräsentation der drei Modelle lautet folgendermaßen:

$$y_t^k = c_{1,h}^k + \beta_1 x_{t-h}^k + \varepsilon_{1,t-h}^k, \quad (1)$$

$$y_t^k = c_{2,h}^k + \sum_{i=0}^2 \gamma_i x_{t-i-h}^k + \varepsilon_{2,t-h}^k, \quad (2)$$

$$y_t = c_{3,h} + \alpha_1 y_{t-1-h} + \varepsilon_{3,t-h}. \quad (3)$$

Die Verlaufsrate der bayerischen Industrieproduktion ist dargestellt als y_t^k (in %) und einen der $k = 9$ Indikatoren (z.B. der Stromverbrauch) repräsentiert x_t^k . Der Prognosehorizont ist angegeben durch h , wobei $h = 0$ für den Nowcast und $h = 1$ für den Forecast steht. Die modell- und indikatorspezifischen Konstanten sind durch c^k dargestellt; der übliche Fehlerterm ist ε_t^k . Die Parameter der Modelle ($c, \beta_1, \gamma_i, \alpha_1$) werden mit der Methode der Kleinsten Quadrate geschätzt.

MIDAS-Modelle

Für das Prognoseexperiment auf Wochenbasis kommt das einfachste MIDAS-Modell zum Einsatz (vgl. Wohlrabe 2009b). Die allgemeine mathematische Repräsentation lautet wie folgt:

$$y_t = \delta_{0,h} + \delta_{1,h} B(L^{1/m}; \theta_h) x_{t-h}^{(m)} + \varepsilon_{4,t-h}^{(m)}. \quad (4)$$

Hierbei wird die bayerische Industrieproduktion y_t (in %) auf Monatsebene gemessen und der Stromverbrauch x_t (in %) auf Wochenbasis, wobei die Zeitangabe t für die Monate steht. Da beide Größen in unterschiedlichen Frequenzen vorliegen, werden die wöchentlichen Stromverbrauchsdaten und deren Verzögerungen mittels einer allgemeinen Gewichtungsfunktion $B(L^{1/m}; \theta_h)$ modelliert. Hierbei bezeichnet $L^{1/m}$ das Lag Polynom mit Exponent $1/m$. Im vorliegenden Fall steht m für das Mischungsverhältnis der unterschiedlichen Frequenzen und nimmt den Wert $m = 4$ an, da ein Monat – vereinfacht angenommen – aus vier Wochen besteht. Die Gewichtungsfunktion nimmt die folgende Form an, $B(L^{1/m}; \theta_h) = \sum_{k=0}^K B(k; \theta_h) L^{k/m}$, wobei k die jeweilige Verzögerung (bzw. das jeweilige Lag) der Stromverbrauchsdaten angibt (mit einer Maximalanzahl an Verzögerungen von K Wochen). Das Polynom der Gewichtungsfunktion wird mit dem Vektor an Parametern θ_h spezifiziert (für diverse Spezifikationen vgl. Wohlrabe 2009a). Der Prognosehorizont ist erneut mit h angegeben und analog zu den Indikatormodellen definiert. Die modellspezifische Konstante ist durch $\delta_{0,h}$ angegeben und der übliche Fehlerterm mit $\varepsilon_{4,t}$. Die Parameter werden mit der nichtlinearen Methode der Kleinsten Quadrate geschätzt.

Zur Konkretisierung der MIDAS-Modelle wird im Folgenden ein Beispiel angegeben mit $m = 4$ (Kombination aus Monats- und Wochenangaben) und einer Maximalanzahl an Verzögerungen von $K = 4$. Das MIDAS-Modell nimmt bei dieser Konstellation die folgende Form an:

$$y_t = \delta_{0,h} + \delta_{1,h} \left[B(0; \theta_h) x_{t-h-0/4}^{(4)} + B(1; \theta_h) x_{t-h-1/4}^{(4)} + B(2; \theta_h) x_{t-h-2/4}^{(4)} + B(3; \theta_h) x_{t-h-3/4}^{(4)} + B(4; \theta_h) x_{t-h-4/4}^{(4)} \right] + \varepsilon_{4,t-h}^{(4)}.$$

Für den Nowcast ($h = 0$) entspricht das MIDAS-Modell dem folgenden Ausdruck:

$$y_t = \delta_{0,0} + \delta_{1,0} \left[B(0; \theta_0) x_t^{(4)} + B(1; \theta_0) x_{t-1/4}^{(4)} + B(2; \theta_0) x_{t-2/4}^{(4)} + B(3; \theta_0) x_{t-3/4}^{(4)} + B(4; \theta_0) x_{t-1}^{(4)} \right] + \varepsilon_{4,t}^{(4)}.$$

In diesem Modell wird die Industrieproduktion Bayerns im Monat t bestimmt durch die vier Wochenwerte innerhalb des gleichen Monats ($x_{t-0/4} = x_t, x_{t-1/4}, x_{t-2/4}, x_{t-3/4}$) und den Wert der vierten Woche des vergangenen Monats ($x_{t-4/4} = x_{t-1}$). Sofern eine höhere Maximalanzahl an Verzögerungen zugelassen oder der ein anderer Prognosehorizont betrachtet wird, passt sich das Modell entsprechend der obenstehenden Konventionen an.

Almon-Lag-Polynom dritter Ordnung

Als Gewichtungsfunktion $B(k; \theta_h)$ für das MIDAS Regressionsmodell wird ein Almon-Lag-Polynom spezifiziert. Das Almon-Lag-Polynom P -ter Ordnung ist durch folgenden Ausdruck gegeben,

$$B(k; \theta_h) = \sum_{p=0}^P \theta_{p,h} k^p,$$

mit $\theta_{p,h}$ als Parameter der Gewichtungsfunktion, die sich je nach Prognosehorizont voneinander unterscheiden. Somit bekommt jede Verzögerung des Stromverbrauchs ein eigenes Gewicht, welches wiederum abhängig ist von allen Gewichtsparametern der Polynomfunktion. Das Testen unterschiedlicher Ordnungen ergab, dass ein Polynom dritter Ordnung ($P = 3$) die beste Anpassung an die Daten liefert. Damit ergibt sich folgendes Almon-Lag-Polynom:

$$B(k; \theta_h = [\theta_{0,h}, \theta_{1,h}, \theta_{2,h}, \theta_{3,h}]) = \sum_{p=0}^3 \theta_{p,h} k^p = \theta_{0,h} + \theta_{1,h} k + \theta_{2,h} k^2 + \theta_{3,h} k^3$$

Beispielhaft sind im Folgenden die Gewichte zweier Verzögerungen dargestellt. Dem kontemporenen Wert des Stromverbrauchs wird das Gewicht $B(0; \theta_h) = \theta_{0,h}$ zugeordnet. Die erste Verzögerung erhält entsprechend das Gewicht $B(1; \theta_h) = \theta_{0,h} + \theta_{1,h} + \theta_{2,h} + \theta_{3,h}$. Die drei Parameter der Gewichtungsfunktion werden in jedem Rechenschritt neu bestimmt.

Beurteilung der Prognosegüte

Zur Beurteilung der Prognosegüte wird das gängigste Maß in der Prognoseliteratur verwendet: die Wurzel des mittleren quadratischen Prognosefehlers (WMQPF). Die mathematische Repräsentation für den Prognosehorizont h lautet wie folgt:

$$WMQPF_h^k = \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{y}_{t,h}^k - y_t^k)^2}.$$

Zunächst wird der Prognosefehler eines Indikators oder Modells quadriert $(\hat{y}_{t,h}^k - y_t^k)^2$ und anschließend ein Mittelwert aus der Gesamtanzahl der Prognosen T berechnet. Die Anzahl variiert mit dem Prognosehorizont und beträgt 108 im Falle des Nowcast und 107 für den Forecast.

Für den Benchmark B wird ein analoges Vorgehen gewählt. Um die Prognosegüte der Indikatoren abschließend beurteilen zu können, werden deren mittlere Prognosefehler ins Verhältnis zur WMQPF des Benchmarks gesetzt:

$$\frac{WMQPF_h^k}{WMQPF_h^B}.$$

Dieser relative Prognosefehler gibt uns Auskunft darüber, ob ein Indikator im Durchschnitt eine höhere Prognosegüte aufweist als der Benchmark. Sofern das Verhältnis einen Wert kleiner Eins annimmt, ist der Indikator der simplen Fortschreibung der zu prognostizierenden Größe vorzuziehen. Liegt der Wert über Eins, liefert der Indikator für die Prognose keinen zusätzlichen Informationsgehalt (im Vergleich zum Letzt bekannten Wert der Zielgröße). Eine analoge Vorgehensweise wird auch bei den MIDAS-Modellen gewählt und deren Prognosefehler in Relation zum Benchmark gesetzt.