



Hamburgisches  
WeltWirtschafts  
Institut

Reihe Edition HWWI Band 6

Nowcast als Forecast  
Neue Verfahren der BIP-Prognose in Echtzeit

*Christina Heike Maaß*

In:

Neuvermessung der Datenökonomie

herausgegeben von Thomas Straubhaar

Seite 101–127

Hamburg University Press  
Verlag der Staats- und Universitätsbibliothek Hamburg  
Carl von Ossietzky

# Impressum

## BIBLIOGRAFISCHE INFORMATION DER DEUTSCHEN NATIONALBIBLIOTHEK

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen National- bibliografie; detaillierte bibliografische Daten sind im Internet über <https://portal.dnb.de> abrufbar.

## LIZENZ

Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt. Das Werk steht unter der Creative-Commons-Lizenz Namensnennung 4.0 International (CC BY 4.0, <https://creativecommons.org/licenses/by/4.0/legalcode.de>). Ausgenommen von der oben genannten Lizenz sind Teile, Abbildungen und sonstiges Drittmaterial, wenn anders gekennzeichnet.



ISSN 1865-7974

## ONLINE-AUSGABE

Die Online-Ausgabe dieses Werkes ist eine Open-Access-Publikation und ist auf den Verlagswebseiten frei verfügbar. Die Deutsche Nationalbibliothek hat die Online-Ausgabe archiviert. Diese ist dauerhaft auf dem Archivserver der Deutschen Nationalbibliothek (<https://portal.dnb.de>) verfügbar.

DOI <https://doi.org/10.15460/HUP.HWWI.6.212>

## ISBN

Print: 978-3-943423-91-4

EPUB: 978-3-943423-94-5

SATZ Hamburg University Press

COVERGESTALTUNG Hamburg University Press unter Verwendung eines Fotos von Free-Photos auf Pixabay (<https://pixabay.com/images/id-768432>)

DRUCK UND BINDUNG Books on Demand (Norderstedt)

## VERLAG

Hamburg University Press, Verlag der Staats- und Universitätsbibliothek Hamburg  
Carl von Ossietzky, Hamburg (Deutschland), 2021  
<https://hup.sub.uni-hamburg.de>

## Inhalt

- 7 **Vorwort**
- 9 **Einleitung**  
Datenwirtschaft: Was ist neu und anders?  
*Thomas Straubhaar*

## Teil 1: Das Produktivitätsparadox der Datenökonomie

- 29 **Die digitale Revolution: Der große Übergang in die Datenökonomie**  
*Henning Vöpel*
- 41 **Der Rückgang des Produktivitätsfortschritts: Worum geht es?**  
*Thomas Straubhaar*
- 61 **Das Produktivitätspuzzle – eine kritische Bewertung**  
*Felix Roth*
- 83 **Zwei Rätsel der Produktivität – eine empirische Beobachtung**  
*Henrique Schneider*

## Teil 2: Neue empirische Verfahren für die Datenökonomie

- 101 **Nowcast als Forecast**  
Neue Verfahren der BIP-Prognose in Echtzeit  
*Christina Heike Maaß*
- 129 **Textdaten**  
Anwendungen und Herausforderungen  
*Silke Sturm*

- 157 **Onlinedaten und Konsumententscheidungen**  
Voraussagen anhand von Daten aus Social Media und Suchmaschinen  
*Deniz Dilan Karaman Örsal*
- 173 **Implizite Motive in der politischen Kommunikation**  
*Niklas Scheffer, Silke Sturm und Zahurul Islam*
- 199 **Verfasserinnen und Verfasser**

# Nowcast als Forecast

## Neue Verfahren der BIP-Prognose in Echtzeit

*Christina Heike Maaß*

### Einleitung

(Finanz-)politische Entscheidungen werden meist nach Bewertung aktueller und zukünftig erwarteter ökonomischer Entwicklungen getroffen.<sup>1</sup> Dafür benötigen Entscheidungsträger:innen aus der (Wirtschafts-) Politik beziehungsweise aus den Zentralbanken möglichst aktuelle Konjunkturdaten, um bestmöglich Einfluss auf die gegenwärtige Wirtschaftslage ausüben zu können.<sup>2</sup> Da wichtige volkswirtschaftliche Kennzahlen wie das Bruttoinlandsprodukt (BIP) zumeist nur in mehrmonatigen Intervallen und mit Verzögerung veröffentlicht werden, ist der Großteil der etablierten Indikatoren in Zeiten beschleunigter wirtschaftlicher Veränderungen nicht mehr agil genug.<sup>3</sup> Deswegen befassen sich Ökonom:innen tiefgehend mit der Verbesserung des makroökonomischen Monitorings in Echtzeit, um ein Verfahren zu entwickeln, mit dem die Gegenwart und die nahe Vergangenheit prognostiziert werden können.<sup>4</sup>

Eine Prognose des gegenwärtigen Zustands beziehungsweise der nahen Zukunft oder Vergangenheit, am Rande der verfügbaren Daten, wird als „Nowcast“ bezeichnet.<sup>5</sup> Dieser Begriff setzt sich aus den englischen Wörtern *now* (jetzt) und *forecast* (Prognose) zusammen. Er bedeutet das Beobachten der aktuellen Wirtschaftslage in Echtzeit durch Prognose der Gegenwart, wobei die gegenwärtige

---

<sup>1</sup> Giannone/Reichlin/Small (2008), S. 665.

<sup>2</sup> BMWi (2019), S. 12; Giannone/Reichlin/Small (2008), S. 665; Cepni/Guney/Swanson (2020), S. 18.

<sup>3</sup> Aastveit et al. (2014), S. 48; Giannone/Reichlin/Small (2008), S. 665; Hauf/Stehrenberg/Zwick (2020), S. 52.

<sup>4</sup> Aastveit et al. (2014), S. 48; Stock/Watson (2017), S. 72.

<sup>5</sup> Armstrong (2004), S. 798; Bańbura et al. (2013), S. 196; Sachverständigenrat (2019), S. 54.

Prognose immer wieder aktualisiert wird.<sup>6</sup> Abstrakter formuliert, besteht beispielsweise der Nowcast des BIP-Wachstums eines Landes zum Zeitpunkt  $t$ , dargestellt durch die Variable  $y_t^Q$ , aus der orthogonalen Projektion dieser Variablen auf das Informationsset  $\Omega_v$ :

$$P[y_t^Q | \Omega_v] = E[y_t^Q | \Omega_v]$$

Das Informationsset enthält alle zum Zeitpunkt  $v$  verfügbaren Informationen, wobei  $v$  sich auf das Datum einer bestimmten Datenveröffentlichung bezieht. Dabei stellt  $E[\cdot | \Omega_v]$  den bedingten Erwartungswert dar.<sup>7</sup>

Datenökonomie und künstliche Intelligenz (KI) eröffnen auch für Prognosen der Wirtschaftsleistung neue Möglichkeiten. Als Datenquelle für die Erstellung tagesaktueller Vorhersagen eignet sich vor allem der mit der neuen Datenökonomie einhergehende Bereich Big Data, da diese Daten für eine Vielzahl von Aktivitäten in Echtzeit und in großen Mengen zur Verfügung stehen. Für die bestmögliche Analyse von Big Data im Bereich Nowcasting erweist sich dabei insbesondere die Anwendung von KI in Form des maschinellen Lernens (ML) als effizient, da die Methoden des ML die Komplexität und Größe dieser Datenart am besten verarbeiten.<sup>8</sup>

Abbildung 1 vermittelt einen ersten Eindruck von der Genauigkeit von Nowcasts. Für den Zeitraum 1.1.2019 bis 31.12.2020 wird der BIP-Nowcast der Federal Reserve Bank of New York<sup>9</sup> für die USA geplottet (dunkelgrau). Demgegenüber werden die tatsächlichen Wachstumsraten des US-amerikanischen BIP als hellgraue Punkte zum jeweiligen Ende des Quartals<sup>10</sup> dargestellt. Diese Werte stammen vom *Bureau of Economic Analysis* (BEA)<sup>11</sup> der US-Regierung. Es wird ersichtlich, dass der Nowcast die BIP-Entwicklung auch im Verlauf der Coronapandemie (seit Mitte März 2020) relativ gut abbildet. Die Abweichungen in dieser unsicheren Periode sind allerdings um einiges deutlicher als vorher. Eine genauere Beschreibung der Grafik erfolgt im weiteren Verlauf dieses Beitrags.

---

<sup>6</sup> Federal Reserve Bank of New York (2019), S. 66.

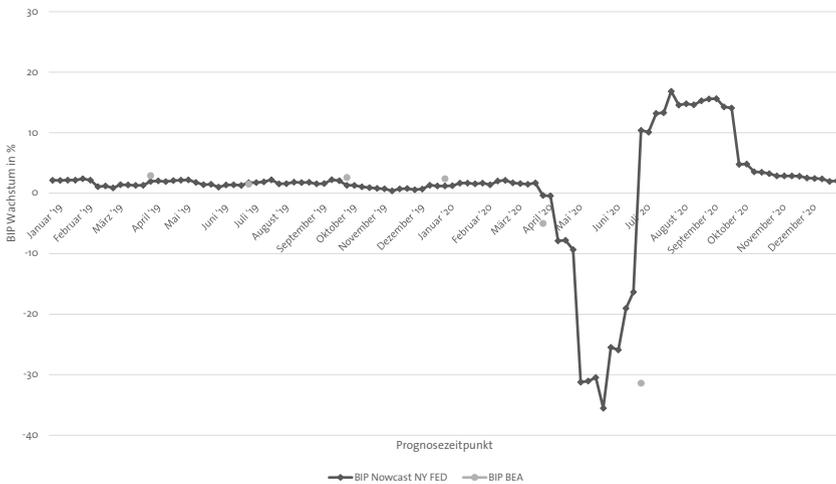
<sup>7</sup> Bańbura/Giannone/Reichlin (2011), S. 196.

<sup>8</sup> Varian (2014), S. 6.

<sup>9</sup> Federal Reserve Bank of New York (2020).

<sup>10</sup> Zum Verständnis dessen auf welches Quartal sich das tatsächliche BIP des Bureau of Economic Analysis (BEA) bezieht, wird das tatsächliche BIP am Ende des jeweiligen Quartals anstelle am Tag der tatsächlichen Veröffentlichung (einige Wochen später) dargestellt.

<sup>11</sup> BEA (2020).



Anmerkung: NY FED = Federal Reserve Bank of New York, BEA = Bureau of Economic Analysis.

Abb. 1: US-BIP-Wachstum: NY-FED-Nowcast versus BEA 01/19–12/20  
 Quelle: Eigene Darstellung, basierend auf BEA (2020) und Federal Reserve Bank of New York (2020).

Dieser Beitrag bietet einen Überblick über die gegenwärtige Nowcast-Literatur und untersucht die Möglichkeiten und Grenzen der Erstellung (tages-) aktueller Prognosen (sogenannter Nowcasts) der gegenwärtigen Wirtschaftslage mit Big Data und ML. Zum Vergleich der verschiedenen Prognosequalitäten wird das statistisch-empirische Kriterium Wurzel der mittleren Fehlerquadratsumme (*root mean square error* [RMSE]) angelegt.<sup>12</sup>

Im folgenden Abschnitt werden zunächst die Eigenschaften des Nowcasts genauer beschrieben und anschließend „herkömmliche“ Anwendungsmöglichkeiten dieser Methode erläutert. Der nächste Abschnitt geht darauf ein, was unter dem Begriff Big Data verstanden wird sowie welche Datenquellen aus dem Bereich Big Data stammen, und umreißt die Herangehensweise von Verfahren des maschinellen Lernens. Anschließend werden Möglichkeiten und Grenzen des Nowcasts mit Big Data und maschinellem Lernen diskutiert. Schließlich werden die Ergebnisse dieses Beitrags zusammengefasst und es wird ein Ausblick auf potenzielle zukünftige Entwicklungen gegeben.

<sup>12</sup> Pons (2000), S. 54.

## Tagesaktuelle Prognosen – Nowcasts

Nowcasts sind Prognosen der Gegenwart. Sie unterscheiden sich von anderen Prognoseverfahren jedoch nicht nur dadurch, dass sie anstelle der Zukunft die gegenwärtige Lage prognostizieren, sondern auch durch die Asynchronität der verwendeten Datenreihen. Die verschiedenen Indikatoren, auf Grundlage derer ein Nowcast erstellt wird, werden zu unterschiedlichen Zeitpunkten und mit unterschiedlichen Frequenzen veröffentlicht – manche Variablen werden monatlich veröffentlicht, andere wöchentlich oder sogar täglich –, sodass der zugrundeliegende Datensatz unausgewogen ist.<sup>13</sup> Da für einen Nowcast immer die aktuellsten Kennzahlenwerte genutzt werden, ist der Zeitpunkt der letzten verfügbaren Beobachtung in jeder Datenserie verschieden. Daher hat der Gesamtdatensatz, das Informationsset  $\Omega$ , eine spezielle Struktur, die sich „gezackte Kante“ (*ragged beziehungsweise jagged edge*) nennt.

Des Weiteren wird für die Erstellung eines Nowcasts nicht nur eine Prognose angefertigt, sondern eine ganze Reihe von Prognosen. Die erste Vorhersage wird mit nur ganz wenigen Informationen angefertigt. Sobald neue Daten vorliegen, wird die vorherige Schätzung aktualisiert und ein neuer, präziserer Nowcast erstellt. Es wird also eine Sequenz von Projektionen  $E[y_t^0 | \Omega_v]$ ,  $E[y_t^0 | \Omega_{v+1}]$  angefertigt, bei der  $v$ ,  $v + 1$  sich auf die Zeitpunkte aufeinanderfolgender Datenveröffentlichungen beziehen. Normalerweise liegen diese Zeitpunkte dicht beieinander und ändern sich. Deswegen hat  $v$  eine hohe Frequenz und ist unregelmäßig verteilt. Die neueren Prognosen enthalten dabei sowohl mehr Informationen als auch Revisionen vorheriger Daten. Der bestehende Nowcast ändert sich nur, wenn die neue Prognose von der alten abweicht, da unerwartete Informationen, sogenannte *News*, veröffentlicht wurden.<sup>14</sup> Allerdings geht Nowcasting weit über einzelne Prognosen für einen bestimmten Zeitraum hinaus. Ziel ist es viel mehr, einen Rahmen zu entwickeln, der in Echtzeit den Fluss an Datenveröffentlichungen lesen kann.<sup>15</sup> Deswegen ist Nowcasting nicht nur gleichzeitiges Forecasting, da die Nutzung und das Timing gleichzeitiger Daten bedeutend andere Komponenten mit sich bringen als vorab Forecasting.<sup>16</sup>

---

<sup>13</sup> Giannone/Reichlin/Small (2008), S. 666; Bańbura/Giannone/Reichlin (2011), S. 196.

<sup>14</sup> Bańbura/Giannone/Reichlin (2011), S. 196–197.

<sup>15</sup> Bańbura et al. (2013), S. 207.

<sup>16</sup> Castle/Fawcett/Hendry (2009), S. 87.

Nowcasts können für sämtliche niederfrequenten Variablen angefertigt werden, die mit einiger Verzögerung veröffentlicht werden, für die jedoch höherfrequente, frühzeitigere Daten verfügbar sind.<sup>17</sup> Ursprünglich wurden Nowcasts hauptsächlich in der Meteorologie zur minutengenauen Prognose von Gewittern verwendet.<sup>18</sup> In den letzten Jahren ist die Relevanz dieses Verfahrens jedoch auch in der Ökonomie deutlich gestiegen. Dies zeigt sich beispielsweise an den verstärkten Aktivitäten statistischer Ämter, Institute und Zentralbanken.<sup>19</sup>

Man benötigt Nowcasts in den Wirtschaftswissenschaften, da wichtige volkswirtschaftliche Kennzahlen wie das BIP nur vierteljährlich berechnet werden und erste offizielle BIP-Schätzungen des vergangenen Quartals in vielen Ländern erst vier (USA) bis sechs (Eurozone) Wochen nach Ende des Quartals veröffentlicht werden. Somit muss in der Eurozone bis circa Mitte Mai (beziehungsweise Ende April für eine Schnellschätzung) gewartet werden, um erste Prognosen für das aktuelle Jahr zu erhalten.<sup>20</sup> Aufgrund des immensen volkswirtschaftlichen Interesses am Wirtschaftswachstum liegt der Schwerpunkt dieses Kapitels auf der Prognose des BIP.

Um das gegenwärtige BIP zu prognostizieren, werden früher beziehungsweise häufiger als das BIP veröffentlichte Variablen verwendet, im Idealfall sogar Echtzeitdaten.<sup>21</sup> Zum Beispiel wird die Industrieproduktion der Eurozone im Januar schon Mitte März veröffentlicht. Dieser Indikator misst einen wichtigen Bestandteil des BIP und ist von großer Bedeutung für dessen kurzfristige Entwicklung.<sup>22</sup> Für Deutschland sind außerdem beispielsweise Auftragseingänge im Verarbeitenden Gewerbe, Produktion im Produzierenden Gewerbe oder der ifo Geschäftsklimaindex wichtige Frühindikatoren.<sup>23</sup> Diese Kennzahlen zählen zu den „harten“ Faktoren. Noch kurzfristigere, möglicherweise aber auch ungenauere Informationen kann man „weichen“ Faktoren wie aktuellen Umfragerwerten entnehmen. Werte für BIP-Erwartungen werden häufig schon vor Ende des betreffenden Monats veröffentlicht. Zusätzlich können auch sämtliche an-

---

<sup>17</sup> Bańbura/Giannone/Reichlin (2011), S. 194.

<sup>18</sup> siehe Deutscher Wetterdienst (2020) und World Meteorological Organization (2017).

<sup>19</sup> Siehe Deutsche Bundesbank (2020); Federal Reserve Bank of New York (2020); ifo Institut (2021); Statistisches Bundesamt (2020).

<sup>20</sup> Bańbura/Giannone/Reichlin (2011), S. 193–194; Bańbura et al. (2013), S. 196.

<sup>21</sup> Bańbura et al. (2013), S. 196; Cepni/Guney/Swanson (2020), S. 18.

<sup>22</sup> Bańbura/Giannone/Reichlin (2011), S. 193.

<sup>23</sup> BMWi (2019), S. 12.

deren Datenveröffentlichungen von Bedeutung sein und die Märkte beeinflussen,<sup>24</sup> beispielsweise Finanzmarktdaten wie Zinsen, Aktien- oder Wechselkurse sowie nachfrageseitige Variablen wie der Stromverbrauch. Darüber hinaus eignet sich für die Erstellung tagesaktueller Nowcasts insbesondere die Verarbeitung großer Informationsmengen im Bereich Big Data wie Social-Media-Aktivitäten oder Mobilfunkdaten. Diese Daten können theoretisch in Echtzeit in aktuelle Prognosen einfließen. Möglichkeiten und Grenzen dieses Ansatzes werden in einem nachfolgenden Abschnitt dieses Beitrags diskutiert.

Technisch gesehen wurden beim Nowcast des BIP-Wachstums im gegenwärtigen Quartal ursprünglich häufig einfache, kleinmaßstäbige Modelle verbunden, sogenannte Brückengleichungen (*bridge equations*). Dabei werden die kleinen Modelle genutzt, um die Informationen, die in einer oder mehreren monatlichen erklärenden Schlüsselvariablen (zum Beispiel Werte für die Industrieproduktion oder Umfrageergebnisse) enthalten sind, mit der vierteljährlichen Wachstumsrate des BIP zu koppeln, die nach den monatlichen Daten veröffentlicht wird.<sup>25</sup> Anhand eines Gleichungssystems wird eine Verbindung zwischen der zu prognostizierenden Variablen und den erklärenden Variablen hergestellt. Dabei wird überbrückt, dass die Daten alle zu unterschiedlichen Zeitpunkten veröffentlicht werden.<sup>26</sup>

Allerdings werden für Nowcasts idealerweise komplexere Modelle verwendet, bei denen auch die Kommentierung und Interpretation der überarbeiteten Schätzungen berücksichtigt wird. Mit den komplexeren Modellen wird die Veränderung des BIP nicht nur quantitativ prognostiziert, sondern es wird auch qualitativ bestimmt, welche Faktoren hauptsächlich verantwortlich sind. Dafür muss die gemeinsame Dynamik der monatlichen Inputvariablen und der vierteljährlichen Zielvariablen in einem einheitlichen Rahmen modelliert werden.<sup>27</sup> Prinzipiell kann dafür jedes dynamische Modell verwendet werden, das mit verschiedenen Frequenzen und fehlenden Daten umgehen kann und die gemeinsame Dynamik der erklärenden und der Zielvariablen abbilden kann.<sup>28</sup> In der Praxis werden häufig Faktormodelle oder vektorautoregressive Modelle (VAR-Modelle) verwendet.<sup>29</sup>

---

<sup>24</sup> Bańbura/Giannone/Reichlin (2011), S. 193–194.

<sup>25</sup> Giannone/Reichlin/Small (2008), S. 666.

<sup>26</sup> Deutsche Bundesbank (2018), S. 19–20.

<sup>27</sup> Bańbura/Giannone/Reichlin (2011), S. 194.

<sup>28</sup> Bańbura/Giannone/Reichlin (2011), S. 212.

<sup>29</sup> Sachverständigenrat (2019), S. 54; Deutsche Bundesbank (2018), S. 15.

Als statistisch-empirische Kriterien für den Vergleich und die Bewertung der Prognosegüte verschiedener Verfahren werden traditionell der mittlere absolute Fehler (*mean absolute error* = MAE), die Wurzel der mittleren Fehlerquadratsumme (*root mean square error* [RMSE]) und Theils U angelegt.<sup>30</sup> Da in den für diesen Beitrag relevanten Papieren überwiegend der RMSE angegeben wird, wird nachfolgend die Güte der verschiedenen Nowcasts anhand dieses Kriteriums bewertet. Der RMSE<sup>31</sup> wird durch die Abweichung der prognostizierten Werte von der Realität berechnet. Diese Abweichung wird quadriert, um negative und positive Differenzen gleich zu bewerten, es wird der Mittelwert gebildet und die Quadratwurzel gezogen. Im Verlauf des Beitrags wird daher immer wieder auf den RMSE eingegangen, um einen Überblick über die Prognosegüte der verschiedenen Ansätze zu erhalten. Am Ende des Beitrags werden alle RMSE in einer Tabelle einander gegenübergestellt.

## Anwendungsmöglichkeiten von Nowcasts

Nowcasts sind für eine Vielzahl volkswirtschaftlicher Themengebiete relevant, wie Gesundheit, Produktion beziehungsweise Produktivität, Konsumentenverhalten und Wirtschaftswachstum. Bei der Formalisierung der Problemstellungen wird im traditionellen Sinne sowohl auf Partialmodelle wie Brückengleichungen und MIDAS-Typ-Gleichungen als auch auf gemeinsame Modelle wie Faktormodelle und Gemischte-Frequenz-VAR-Modelle zurückgegriffen. Eine Besonderheit der VAR-Modelle ist, dass die verwendeten Variablen von ihren vergangenen Werten sowie den vergangenen Werten der anderen Variablen abhängen.<sup>32</sup>

In einem frühen Standardwerk zur Problematik der zeitverzögerten Berichterstattung<sup>33</sup> untersuchte Jerald Lawless im Jahr 1994 die Berichterstattung bei meldepflichtigen Krankheiten. Anhand eines stationären *Maximum-Likelihood*-Verfahrens mit multinominalem Modell sowie eines nichtstationären *Random-Effects*-Modells konnte er Trends in der verzögerten Berichterstattung iden-

<sup>30</sup> Pons (2000), S. 54.

<sup>31</sup> Berechnung:  $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2}$ ,  $y_i$  = tatsächliche Werte,  $f_i$  = prognostizierte Werte (Gupta/Minai 2019), S. 372.

<sup>32</sup> Deutsche Bundesbank (2018), S. 18.

<sup>33</sup> Englisch: „*occured but not reported events*“.

tifizieren und somit bessere Prognosen bezüglich des Verlaufs von Krankheiten erstellen.<sup>34</sup> Dies ist insbesondere bei plötzlichen Ausbrüchen essentiell.<sup>35</sup>

Deswegen spielt das Nowcasting tatsächlicher Infiziertenzahlen auch in der aktuellen COVID-19-Pandemie eine große Rolle. Auch die Registrierung neuer SARS-CoV-2-Infektionen erfolgt oftmals zeitverzögert, da einerseits Infektions- und Meldedatum nicht übereinstimmen und andererseits das tatsächliche Infektionsdatum nicht bekannt beziehungsweise nicht zu bestimmen ist. Um trotzdem möglichst genaue Prognosen des aktuellen Verlaufs der Krankheit treffen zu können, können die fehlenden Informationen bezüglich des tatsächlichen Infektionsdatums mit einem Nowcast geschätzt werden.<sup>36</sup> Nur wenn eine genaue Prognose der aktuellen Infektionszahlen vorliegt, kann ein eindeutiger Zusammenhang zwischen Ursache, zum Beispiel einer Veränderung der Coronaregeln, und Wirkung, beispielsweise höheren oder niedrigeren Infektionszahlen, hergestellt werden. Das Robert Koch-Institut (RKI) schätzt daher fehlende Datenpunkte basierend auf den statistischen Zusammenhängen der verfügbaren Daten (sogenannte multiple Imputation), um den Zeitpunkt der Erkrankung an SARS-CoV-2 zu schätzen und das aktuelle Infektionsgeschehen besser beurteilen zu können.<sup>37</sup>

Abgesehen von medizinischen Studien sind Nowcasts der gegenwärtigen Wirtschaftsleistung von großer Bedeutung und Gegenstand verschiedener Forschungsarbeiten. Aktuelle Veröffentlichungen untersuchen überwiegend Nowcasts, die in Pseudo-Echtzeit erstellt wurden. Es wird also simuliert, was ein Nowcast im jeweiligen Zeitraum prognostiziert hätte. Dafür werden nur Daten verwendet, die zum jeweiligen Prognosezeitpunkt verfügbar waren. Die erhaltenen Prognosen können dann direkt mit den tatsächlichen Werten verglichen werden. Dabei werden verschiedene Herangehensweisen gewählt.

In einer der neuesten Studien ermitteln Cepni/Guney/Swanson BIP-Nowcasts basierend auf Datensätzen ökonomischer Indikatoren des Informationsdienstleisters Bloomberg. Für fünf Schwellenländer (Brasilien, Indonesien, Mexiko, Südafrika, Türkei) werden dynamische Faktormodelle durch makroökonomische Unsicherheits- und Überraschungsfaktoren erweitert, die die intensiven globalen

---

<sup>34</sup> Lawless (1994).

<sup>35</sup> Höhle / An der Heiden (2014).

<sup>36</sup> Günther et al. (2020).

<sup>37</sup> An der Heiden / Hamouda (2020).

Verflechtungen der Volkswirtschaften abbilden.<sup>38</sup> Die Überraschungsfaktoren bestehen aus Abweichungen der Erwartungen professioneller Prognostiker von der Realität, die Unsicherheitsfaktoren enthalten Werte aus der Wirtschafts-, Handels- und Geldpolitik sowie Migration.<sup>39</sup> Cepni/Guney/Swanson kommen zu dem Ergebnis, dass unterschwellige Unsicherheits- und Überraschungsfaktoren einen signifikanten vorhersagenden Inhalt für die Wachstumsprognose von Schwellenländern haben.<sup>40</sup> Somit kann die Messung von Unsicherheit für eine genaue Vorhersage nützlich sein. Der RMSE ihres autoregressiven Standardmodells liegt je nach Land und den drei verwendeten Nowcast-Zeitpunkten zwischen 0,85 und 2,34. Außerdem zeigen sie, dass der Prognosegehalt bei der Konstruktion der Schrumpfungstypfaktoren mit LASSO, adaptivem LASSO, bayesianischem LASSO und adaptivem bayesianischem LASSO verbessert ist (niedrigerer RMSE).<sup>41</sup>

Im Gegensatz dazu berücksichtigen Aastveit et al. Prognoseunsicherheiten als Wahrscheinlichkeitsverteilung in sogenannten Dichte-Nowcasts des US-amerikanischen BIP.<sup>42</sup> Diese Nowcasts bestehen aus einem System von Brückengleichungsmodellen, Faktormodellen und vektorautoregressiven Modellen. Dafür verwenden Aastveit et al. mehr als 100 monatliche Indikatoren wie Finanzmarktdaten, Verbraucherpreise und Umfragewerte von der Federal Reserve Bank in St. Louis. Die verschiedenen Dichte-Nowcasts werden zunächst zu drei Nowcasts je Modellklasse und schließlich zu einem Gesamt-Nowcast kombiniert. Die Prognosen werden mit jeder Datenveröffentlichung besser und der kombinierte Nowcast liefert gemäß dem von den Autoren verwendeten *log score*<sup>43</sup> die besten Prognosen.<sup>44</sup>

Nowcasts des BIP in der Eurozone im Jahr 2008 finden sich in Bańbura/Giannone/Reichlin.<sup>45</sup> Datengrundlage sind 26 „wichtige“ Indikatoren aus der Eurozone mit höchstens monatlicher Frequenz. Die Autoren vergleichen die Nowcasts eines dynamischen Faktormodells mit denen eines univariaten nai-

---

<sup>38</sup> Cepni/Guney/Swanson (2020), S. 33.

<sup>39</sup> Cepni/Guney/Swanson (2020), S. 19.

<sup>40</sup> Cepni/Guney/Swanson (2020), S. 32.

<sup>41</sup> Cepni/Guney/Swanson (2020).

<sup>42</sup> Aastveit et al. (2014).

<sup>43</sup> Der *log score* ist der Logarithmus einer Wahrscheinlichkeitsdichtefunktion, die an der Stelle des prognostizierten Ergebnisses ausgewertet wird und somit eine Maßzahl für die Passform der Dichtefunktion angibt. Aastveit et al. (2014), S. 51.

<sup>44</sup> Aastveit et al. (2014), 48 und 59.

<sup>45</sup> Bańbura/Giannone/Reichlin (2011).

ven Random-Walk-Modells. Während das dynamische Faktormodell zu Beginn der Prognoseperiode einen RMSE von 0,28 aufweist, der im Laufe des Quartals auf 0,18 sinkt, liegt der RMSE des Random-Walk-Modells vergleichsweise konstant bei etwas über 0,30. Des Weiteren ergibt ihre Analyse, dass weiche Faktoren wie Umfrageergebnisse zu Beginn eines Quartals hohen Erklärungsgehalt haben. Im weiteren Verlauf des Quartals, mit der Veröffentlichung harter Faktoren, sinkt ihre Bedeutung jedoch.<sup>46</sup>

Bañbura/Giannone/Modugno/Reichlin erstellen Nowcasts für das US-amerikanische BIP in Echtzeit.<sup>47</sup> Dabei verwenden sie an dem Tag, an dem sie eine Prognose erstellen, alle bis dahin vorliegenden Daten der interessierenden Variablen. Der Echtzeitdatensatz basiert auf Werten des Informationsdienstleisters Bloomberg und wird anhand von Daten der Federal Reserve Bank in St. Louis evaluiert. In diesem Paper werden sowohl gemeinsame Modelle – ein Faktormodell mit täglichen Daten, ein analoges Modell mit monatlicher Frequenz sowie ein kleines Faktormodell mit fünf „harten“ Indikatoren<sup>48</sup> – als auch Brückengleichungen als Partialmodell verwendet. Die Autoren finden heraus, dass tagesaktuelle Finanzdaten nur einen geringen Erklärungsgehalt haben und stattdessen monatliche Veröffentlichungen der Werte makroökonomischer Variablen entscheidend sind.<sup>49</sup> Das Brückengleichungsmodell hat den höchsten RMSE zwischen 0,58 und 0,66, gefolgt von dem Modell mit den fünf harten Faktoren (RMSE zwischen 0,45 und 0,63). Eine noch höhere Prognosegüte weist das Modell mit täglicher Frequenz auf (RMSE zwischen 0,45 und 0,60) und den niedrigsten RMSE zwischen 0,43 und 0,57 erzielt das Faktormodell mit monatlichen Daten.<sup>50</sup>

Abgesehen von diesen akademischen Publikationen beschäftigen sich diverse Zentralbanken und (Forschungs-)Institute mit der Entwicklung eigener Nowcasts. Dabei bedienen sie sich sowohl herkömmlicher ökonomischer Indikatoren als auch hochfrequenter Big-Data-Datensätze. Beispielsweise veröffentlicht die Federal Reserve Bank of New York ihren wöchentlich aktualisierten

---

<sup>46</sup> Bañbura/Giannone/Reichlin (2011), S. 198, 205, 209 und 210.

<sup>47</sup> Bañbura et al. (2013).

<sup>48</sup> Reales BIP, Industrieproduktion, verfügbares Realeinkommen, Einzelhandelsumsatz und Beschäftigung.

<sup>49</sup> Bañbura et al. (2013), S. 214 sowie 218-219.

<sup>50</sup> Bañbura et al. (2013), S. 217.

New York Fed Staff Nowcast<sup>51</sup> zur Entwicklung des BIP in den USA.<sup>52</sup> Bei dieser Prognose verwendet sie ein dynamisches Faktormodell.<sup>53</sup> Abbildung 1 zeigt zwischen Januar 2019 und Dezember 2020 den Verlauf der Nowcasts gegenüber den tatsächlichen BIP-Werten, die ein paar Wochen nach Ablauf des jeweiligen Quartals veröffentlicht werden. Bereits vor Ende des ersten Quartals 2020 weist der Nowcast eine Abwärtstendenz auf, die sich nach Veröffentlichung der tatsächlichen BIP-Entwicklung und dem Fortschreiten der COVID-19-Pandemie deutlich verstärkt. Das zweite Quartal 2020 wird durch den Nowcast ziemlich gut vorhergesagt, insbesondere in Anbetracht der sehr unsicheren Lage. Die Erholung im dritten Quartal 2020 wurde deutlich niedriger prognostiziert als sie tatsächlich ausgefallen ist. Die Prognose für das vierte Quartal ist im positiven, einstelligen Bereich. Die New Yorker Zentralbank erwartet für das Ende des Jahres ein BIP-Wachstum zwischen 2 und 5 %. Das tatsächliche BIP-Wachstum gemäß BEA wurde erst nach dem Druck dieses Artikels veröffentlicht. Es bleibt festzuhalten, dass der Nowcast der New Yorker Zentralbank auch im sehr unruhigen Jahr 2020 gute Ergebnisse geliefert hat.

Auch die Federal Reserve Bank of Atlanta prognostiziert mit ihrem GDP-Now Nowcast anhand von Brückengleichungen das US-amerikanische BIP. Dabei werden die ersten Schätzungen des aktuellen Quartals ungefähr einen Monat nach Ablauf des vorherigen Quartals erstellt.<sup>54</sup> Die *out of sample* Prognosegüte des GDPNow-Modells einen Tag vor der Veröffentlichung der ersten BIP-Schätzung liegt bei einem RMSE von 1,15. 85 Tage vor der Veröffentlichung liegt er noch bei durchschnittlich 2,2.<sup>55</sup>

Für die EU und die Eurozone veröffentlicht Eurostat seit 2016 BIP-Schnellschätzungen 30 Tage ( $t + 30$ ) nach Quartalsende.<sup>56</sup> Diese Prognose besteht aus den jeweiligen  $t + 30$  Prognosen verschiedener Mitgliedsländer sowie von Eurostat angefertigten Schätzungen des BIP-Wachstums der Länder mit fehlenden Daten. Für diese werden mit Hilfe der Daten für die ersten beiden Monate des Quartals mehrere Nowcasts angefertigt. Darin werden normalerweise die Wachstumsraten des Industrieproduktionsindex, des deflationierten Einzel-

---

<sup>51</sup> Abrufbar unter <https://www.newyorkfed.org/research/policy/nowcast.html>.

<sup>52</sup> Bok et al. (2018), S. 616.

<sup>53</sup> Federal Reserve Bank of New York (2019), S. 69.

<sup>54</sup> Federal Reserve Bank of Atlanta (2020).

<sup>55</sup> Higgins (2014, 25 und 28).

<sup>56</sup> Eurostat (2019).

handels und des Umsatzes von Dienstleistungen anhand der Gewichtungen der volkswirtschaftlichen Gesamtrechnung des jeweiligen Landes verarbeitet. Anhand dieser Indikatoren sowie von vergangenen BIP-Werten und des Indikators für die wirtschaftliche Stimmung werden dann autoregressive Modelle mit verteilter Verzögerung (*autoregressive distributed lag* [ADL]) oder Modelle autoregressiver integrierter gleitender Mittelwerte mit exogenen Variablen (*autoregressive integrated moving average with exogenous variables* [ARIMAX]) geschätzt. Dieses Ergebnis geht mit in die Prognose für die gesamte EU beziehungsweise Eurozone ein.<sup>57</sup> Der RMSE für die Quartalsschätzung für den Zeitraum 2012 bis 2015 liegt in der EU bei 0,06 bis 0,08. In der Eurozone ist er minimal höher (0,07 bis 0,10).<sup>58</sup> Dieser Wert ist allerdings nur schwer mit den anderen vergleichbar, da es sich um eine Aggregation verschiedener Modellprognosen der einzelnen Länder handelt und somit kein eindeutiges Modell zugrunde liegt.

Viele große europäische Länder wie Frankreich, Italien, Spanien, Belgien und Österreich veröffentlichen diese frühe Eurostat-Schätzung ihres BIP bereits.<sup>59</sup> Für Deutschland publiziert das statistische Bundesamt seit dem zweiten Quartal 2020 eine BIP-Flash-Schnellschätzung, die ebenfalls 30 Tage ( $t + 30$ ) nach Ablauf des Quartals zur Verfügung steht. Außerdem arbeitet es intern an einem BIP-Nowcast, der bereits zehn Tage ( $t + 10$ ) nach Quartalsende erste Prognosen liefern könnte.<sup>60</sup> Das betreffende Verfahren beruht auf Modellen autoregressiver integrierter gleitender Mittelwerte (ARIMA).<sup>61</sup> Während der BIP-Flash  $t + 30$  qualitativ sehr hochwertige Ergebnisse liefert, ist der BIP-Nowcast  $t + 10$  zwar vielversprechend, aber noch deutlich anfälliger für Ungenauigkeit.<sup>62</sup>

Im November 2020 gab auch das ifo Institut bekannt, in Zukunft seine BIP-Schnellschätzung ifoCAST regelmäßig zusammen mit der Konjunkturprognose zu veröffentlichen. Für diesen Nowcast wurden zunächst aus über 300 Indikatoren mittels ML die passendsten ausgewählt. Anhand dieser wird zweimal monatlich ein dynamisches Faktormodell mit bayesianischen Methoden für das aktuelle Quartal geschätzt. Das neue Quartal wird ab Veröffentlichung der detaillierten Ergebnisse der Volkswirtschaftlichen Gesamtrechnung des

---

<sup>57</sup> Doody/Kokkinen/Wouters (2016), S. 13–14 und 16–17.

<sup>58</sup> Doody/Kokkinen/Wouters (2016), S. 25–26.

<sup>59</sup> Dickopf/Janz/Mucha (2019), S. 48.

<sup>60</sup> Dickopf/Janz/Mucha (2019), S. 48; Statistisches Bundesamt (2020).

<sup>61</sup> Dickopf/Janz/Mucha (2019), S. 50.

<sup>62</sup> Dickopf/Janz/Mucha (2019), S. 56.

Vorquartals geschätzt – also ab 55 Tagen nach Quartalsende. Die Prognosegüte des ifoCAST ist mit einem RMSE von 0,32 recht gut.<sup>63</sup>

Abgesehen davon entwickelt die Deutsche Bundesbank einen wöchentlichen Aktivitätsindex, mit dem sich die realwirtschaftliche Aktivität in Deutschland mit geringstmöglicher Zeitverzögerung bestimmen lässt. Er wird anhand eines *Expectation-Maximization-Algorithmus* berechnet und setzt sich aus hochfrequenten Indikatoren mit hohem Erklärungsgehalt aus den verschiedenen Wirtschaftsbereichen sowie dem BIP des vergangenen Quartals und der monatlichen Industrieproduktion zusammen.<sup>64</sup> Aktuelle Werte sind bei der Deutschen Bundesbank online abrufbar.<sup>65</sup>

Insgesamt werden für Nowcasts viele verschiedene Indikatoren verwendet. Zumeist liegt den Prognosen eine ganze Reihe von Kennzahlen bezüglich Leistungsbilanz, Beschäftigung, Finanzmärkten, Produktion und Konsum sowie unterschiedliche Umfragen zugrunde. Ein tiefergehender Vergleich der jeweils genutzten Kennzahlen würde den Umfang dieser Arbeit überschreiten und ist für einen ersten Überblick über verschiedene Nowcasting-Verfahren nicht entscheidend.

## Big Data und Maschinelles Lernen

Auf Big Data basierende Datensätze wecken seit ein paar Jahren auch verstärkt das Interesse von Ökonom:innen. Verschiedene Studien zeigen, dass mit Big Data erstellte Prognosen besser als die herkömmlichen Prognosen sind, beispielsweise bei der Vorhersage des privaten Konsums<sup>66</sup> oder des BIP-Wachstums.<sup>67</sup> Dabei unterscheidet sich Big Data von herkömmlichen Daten durch enormes Volumen, hohe Geschwindigkeit, große Vielfalt, geringe Richtigkeit (im Sinne von Unsicherheiten in den Daten) und hohen Wert der Daten.<sup>68</sup> In anderen Worten stellt Big Data jenes Informationsgut dar, das durch sein großes Volumen sowie

---

<sup>63</sup> Lehmann/Reif/Wollmershäuser (2020), S. 31–32 und 38.

<sup>64</sup> Deutsche Bundesbank (2020).

<sup>65</sup> Abrufbar unter <https://www.bundesbank.de/de/statistiken/konjunktur-und-preise/woechentlicher-aktivitaetsindex>.

<sup>66</sup> Siehe Vosen/Schmidt (2011b).

<sup>67</sup> Siehe Woloszko (2017).

<sup>68</sup> Jin et al. (2015), S. 59.

seine große Geschwindigkeit und Vielfalt spezielle Technologien und analytische Verfahren erfordert, um es in (ökonomischen) Wert zu verwandeln.<sup>69, 70</sup> Dies liegt darin begründet, dass diese Daten unstrukturierter sind und höhere Dimensionen aufweisen, sodass das Ordnen der Daten und das Reduzieren der Dimensionen sehr komplex ist.<sup>71</sup> Daher ist die Nutzung von Big Data in vielerlei Hinsicht nicht mit der Nutzung herkömmlicher Daten vergleichbar.

Moderne Big-Data-Datensätze sind häufig in Echtzeit verfügbar und es gibt Daten zu vielen neuen Bereichen.<sup>72</sup> Ihre wichtigste Quelle sind im Internet erzeugte Daten. Dabei sind insbesondere Social-Media-Daten von großer Bedeutung.<sup>73</sup> Darüber hinaus kann Big Data auch aus Finanzmarktdaten, E-Commerce- und Scannerdaten, Mobilfunkdaten, Geolokalisierungsdaten, Such-(maschinen-)daten, Text- und Mediendaten, sensorischen Daten oder Transportdaten bestehen.<sup>74</sup> Praktisch jede elektronisch erfasste Handlung kann als Datengrundlage verwendet werden, was eine Fülle von Möglichkeiten für tagesaktuelle Prognosen eröffnet.

Aufgrund der besonderen Eigenschaften aktueller (Big-Data-)Datenströme, wie deren Größe und Komplexität, sollten für die Analyse von Big Data andere Methoden als die klassischen statistischen Verfahren verwendet werden.<sup>75</sup> Da herkömmliche Verfahren Daten in ein Modell einpassen, das den Zusammenhang zwischen Dateneingabe und -ausgabe möglichst gut beschreibt, kann das jeweilige Modell nicht besser sein als der angenommene Zusammenhang zwischen den Variablen selbst.<sup>76</sup> Die großen Datensätze ermöglichen jedoch flexiblere Beziehungen als einfache lineare Modelle. Diese können durch Techniken des maschinellen Lernens effektiv modelliert werden.<sup>77</sup> Bei diesen Verfahren muss keine Annahme über die funktionelle Beziehung der Variablen getroffen werden, sondern ein Algorithmus bestimmt die Funktion, die den

---

<sup>69</sup> „Big Data represents the Information assets characterized by such a High Volume, Velocity and Variety to require specific Technology and Analytical Methods for its transformation into Value.“ Mauro/Greco/Grimaldi (2015), S. 103.

<sup>70</sup> Mauro/Greco/Grimaldi (2015), S. 103.

<sup>71</sup> Einav/Levin (2014b), S. 1.

<sup>72</sup> Einav/Levin (2014b), S. 1.

<sup>73</sup> Campos Vázquez/López-Araiza B. (2020), 129; Einav/Levin (2014b), S. 1.

<sup>74</sup> Garboden (2020), S. 8–18; Einav/Levin (2014b), S. 1.

<sup>75</sup> Varian (2014), S. 4 und 6.

<sup>76</sup> Jung/Patnam/Ter-Martirosyan (2018), S. 4.

<sup>77</sup> Varian (2014), S. 3.

Zusammenhang zwischen den Variablen am besten darstellt.<sup>78</sup> Anstelle einer linearen oder logistischen Regression erweisen sich nicht-lineare Verfahren wie Klassifikations- und Regressionsbäume, *Random Forests* oder bestrafte Regressionen (*penalized regressions*) wie LASSO, LARS und elastische Netze als besser geeignet.<sup>79</sup>

Das Vorgehen beim ML besteht aus zwei Elementen: (1) einer Lernmethode, bei der anhand von Daten die bestmögliche Einpassung der Inputvariablen bestimmt wird, und (2) einem Algorithmus, der die Beziehung zwischen Input und Output modelliert<sup>80</sup>. Eine Besonderheit des ML ist dabei der Fokus auf die Daten anstelle von Theorie.<sup>81</sup> Bei diesem Verfahren kann also mit einem *measurement without theory* nur auf Grundlage von Daten die Veränderung makroökonomischer Kennzahlen prognostiziert werden. Anschließend kann ML dann im Prinzip auch auf die zugrundeliegende Theorie schließen. Dies geschieht indem basierend auf den Ergebnissen der Algorithmen die richtige beziehungsweise best passende Theorie gesucht wird. Da mit Systemen des ML mehr und verschiedenartigere Informationen verarbeitet werden können, kann die Realität besser abgebildet und können somit potenziell bessere Prognosen erstellt werden.<sup>82</sup>

Allerdings kann bei der Anwendung mit Big Data die Vielzahl an vorhandenen Informationen zu einem sogenannten *overfitting* führen. Dabei werden Modelle durch unnötig viele erklärende Variablen zu komplex. Das Ergebnis ist, dass das Modell mit dem vorliegenden Datensatz sehr genaue Ergebnisse liefert, bei *out of sample*-Schätzungen allerdings schlecht abschneidet. Dies kann durch Bestrafung übermäßig komplexer Modelle, eine Unterteilung des Datensatzes in Training, Test und Validierung sowie eine k-fache Kreuzvalidierung<sup>83</sup> umgangen werden.<sup>84</sup>

Aufgrund des enormen Potenzials von ML werden auch bei der Prognose des BIP im Zuge der Digitalisierung anstelle von herkömmlichen Verfahren vermehrt algorithmierte Computersimulationen verwendet.<sup>85</sup> Auch der Sachver-

---

<sup>78</sup> Jung/Patnam/Ter-Martirosyan (2018), S. 4.

<sup>79</sup> Varian (2014), S. 6.

<sup>80</sup> Jung/Patnam/Ter-Martirosyan (2018), S. 7.

<sup>81</sup> Woloszko (2017), S. 7.

<sup>82</sup> Sachverständigenrat (2019), S. 54.

<sup>83</sup> Für eine genauere Erklärung der Kreuzvalidierung siehe Varian (2014).

<sup>84</sup> Varian (2014), S. 6–7.

<sup>85</sup> Jung/Patnam/Ter-Martirosyan (2018), S. 4.

ständigenrat zur Begutachtung der gesamtwirtschaftlichen Entwicklung weist in seinem Jahresgutachten 2019/20 darauf hin, dass Methoden des ML eine potenzielle Alternative zu herkömmlichen (BIP-)Prognoseverfahren darstellen. Dabei sieht er insbesondere in neuronalen Netzen eine gute Alternative zu den herkömmlichen Brückengleichungen. *Random Forests* wird hingegen eine niedrigere Prognosegüte zugeschrieben.<sup>86</sup>

## Möglichkeiten und Grenzen von Nowcasts mit Big Data und maschinellem Lernen

Die Verwendung der oben genannten Methoden des maschinellen Lernens für Nowcasts mit Big Data eröffnet eine Vielzahl von Möglichkeiten für (Echtzeit-)Prognosen. Diese sind in der gegenwärtigen Literatur bisher nur wenig erforscht. Allerdings zeichnet sich das enorme Potenzial dieser Anwendung künstlicher Intelligenz immer mehr ab. Erste Ergebnisse bei der kurz- und langfristigen Prognose mit Methoden des maschinellen Lernens in verschiedenen Anwendungsbereichen finden sich in Campos Vázquez/López-Araiza B.<sup>87</sup>, Jung/Patnam/Ter-Martirosyan<sup>88</sup> sowie bei der Organisation für wirtschaftliche Zusammenarbeit und Entwicklung (OECD)<sup>89</sup>.

Campos Vázquez/López-Araiza B.<sup>90</sup> erstellen sehr moderne Nowcasts eines anderen volkswirtschaftlichen Indikators mit Big Data und ML. Basierend auf Google-Trends-Daten prognostizieren sie mit Nowcasts die Arbeitslosigkeit in Mexiko. Dabei vergleichen sie den Vorhersagefehler verschiedener Modelle des ML. Den niedrigsten RMSE weist das LASSO-Verfahren auf (0,28). Es wurde mit kubischen Wechselwirkungen trainiert und kann sich deutlich besser an Situationen anpassen, in denen sich die Beziehung zwischen den Variablen ungewöhnlich verhält.<sup>91</sup> Das LASSO-Verfahren erzielt eine etwas höhere Prognosegüte als das herkömmliche autoregressive Modell. Des Weiteren verbessert die

---

<sup>86</sup> Sachverständigenrat (2019), S. 54–55.

<sup>87</sup> Campos Vázquez/López-Araiza B. (2020).

<sup>88</sup> Jung/Patnam/Ter-Martirosyan (2018).

<sup>89</sup> Woloszko (2017).

<sup>90</sup> Campos Vázquez/López-Araiza B. (2020).

<sup>91</sup> Campos Vázquez/López-Araiza B. (2020), S. 145–146.

Verwendung der Google-Trends<sup>92</sup>-Daten die Prognosen.<sup>93</sup> Der RMSE des AR-Modells mit Google Trends liegt bei 0,29 im Vergleich mit 0,31 ohne.<sup>94</sup>

Jung/Patnam/Ter-Martirosyan<sup>95</sup> testen die Prognosegüte von BIP-Forecasts für sechs verschiedene Länder für drei Methoden des ML: elastisches Netz, Super Lerner und rekurrentes neuronales Netzwerk. Dabei erstellen sie BIP-Prognosen für ein Quartal beziehungsweise ein Jahr im Voraus. Bei der Quartalsprognose ohne Weltwirtschaftskrisenzeitraum, von 2010 bis 2016, schneiden die ML-Verfahren elastisches Netz und Super Lerner besser ab als die Prognosen des Weltwirtschaftsausblicks (*world economic outlook* [WEO]) des Internationalen Währungsfonds (IWF). Für die Quartalsprognose mit Krisenzeitraum (2007 bis 2016), wird das jeweils beste ML-Modell je Land dem WEO-Modell, dem AR-Modell sowie dem VAR-Modell gegenübergestellt. Der RMSE ist für alle Länder bei Prognose mit ML am niedrigsten und liegt zwischen 0,20 und 0,81. Im Fall des VAR-Modells liegt der RMSE zwischen 1,09 und 2,20, im Fall des AR-Modells zwischen 0,80 und 1,52 und bezogen auf das WEO-Modell zwischen 1,11 und 2,20 – je nach Land. Die Prognose für ein Jahr im Voraus erzielt deutlich schlechtere Ergebnisse und ist nur teilweise besser als die IWF-Standardprognose.<sup>96</sup> Allgemein sind Jung/Patnam/Ter-Martirosyan der Überzeugung, dass mit ML erstellte Prognosen Expertenprognosen nicht ersetzen, sondern viel mehr als zusätzliche Hilfestellung für die finale Prognose dienen sollten.<sup>97</sup>

Die OECD erstellt Vorhersagen des BIP-Wachstums der G6-Länder<sup>98</sup> in Pseudo-Echtzeit mit adaptiven Bäumen. Die Prognosen anhand dieses Verfahrens liefern bessere Ergebnisse als Standardmodelle wie das OECD-Indikatormodell oder die Konsensprognose.<sup>99</sup> Werte des RMSE liegen für diese Methode leider nicht vor, sondern nur die Angabe, um wie viel Prozent der RMSE im Vergleich mit den Standardmodellen verbessert werden konnte. Die ermittelte

---

<sup>92</sup> Google Trends ist ein täglicher beziehungsweise monatlicher Echtzeitindex, der das Abfragevolumen von Google-Nutzern erfasst.

<sup>93</sup> Campos Vázquez/López-Araiza B. (2020), S. 147–148.

<sup>94</sup> Campos Vázquez/López-Araiza B. (2020), 146.

<sup>95</sup> Jung/Patnam/Ter-Martirosyan (2018).

<sup>96</sup> Jung/Patnam/Ter-Martirosyan (2018), S. 22–24.

<sup>97</sup> Jung/Patnam/Ter-Martirosyan (2018), S. 27.

<sup>98</sup> Großbritannien, USA, Frankreich, Japan, Deutschland und Italien Woloszko (2017), S. 25.

<sup>99</sup> Woloszko (2017), S. 27.

Verbesserung der Prognosegüte liegt bei 12 bis 23 % in Bezug auf das Indikatormodell und durchschnittlich bei 32 % für die Konsensprognose.<sup>100</sup>

Die beschriebenen Arbeiten deuten an, welche weitreichende Möglichkeiten sich für Nowcasts mit Big Data und ML bieten. Dennoch ergibt die Analyse der in diesem Beitrag beleuchteten Studien relativ große Schwankungen in der Prognosegüte der einzelnen Modelle. Dabei bleibt festzuhalten, dass es sich hierbei um keinen vollumfänglichen Vergleich der verschiedenen Verfahren handelt, da dieser Bereich noch nicht in ausreichendem Umfang untersucht wurde und die Studien aufgrund unterschiedlicher Datengrundlagen nur eingeschränkt vergleichbar sind. Stattdessen werden unterschiedliche Ansätze anhand von exemplarischen Studien einander gegenübergestellt, um einen ersten Eindruck von der Güte der Prognosen zu erhalten. Den höchsten Wert der mittleren Fehlerquadratsumme weisen in dieser Übersicht das VAR-Modell, ein AR-Modell sowie das Brückengleichungsmodell des GDPNow auf. Der RMSE dieser Verfahren kann oberhalb des Wertes zwei liegen. Deutlich niedrigere Werte ergeben das ML-Modell von Jung/Patnam/Ter-Martirosyan<sup>101</sup> sowie das Brückengleichungsmodell und das dynamische Faktormodell von Bańbura/Giannone/Modugno/Reichlin<sup>102</sup> mit Werten unter eins. Den niedrigsten RMSE erzielen Campos Vázquez/López-Araiza B.<sup>103</sup> mit der LASSO-Methode und mit der Random-Forest-Schätzung sowie Bańbura/Giannone/Reichlin<sup>104</sup> mit einem dynamischen Faktormodell. Alle drei RMSE sind niedriger als 0,3.

Die teilweise großen Unterschiede zwischen den jeweiligen RMSE innerhalb einer Studie lassen sich bei Vergleichen verschiedener Länder vermutlich auf die länderspezifischen Unterschiede hinsichtlich der Volatilität der Daten und der Zahl der Beobachtungen zurückführen. Bei mehreren Prognosen für das gleiche Land ergeben sich Unterschiede im RMSE durch das Hinzukommen von Informationen für die jeweilige prognostizierte Periode, beispielsweise das Quartal oder Jahr, im Zeitablauf, was die Prognose verbessert.

---

<sup>100</sup> Woloszko (2017), S. 23 und 25.

<sup>101</sup> Jung/Patnam/Ter-Martirosyan (2018).

<sup>102</sup> Bańbura et al. (2013).

<sup>103</sup> Campos Vázquez/López-Araiza B. (2020).

<sup>104</sup> Bańbura/Giannone/Reichlin (2011).

Tab. 1: RMSE verschiedener Prognosemodell

MODELL	RMSE	QUELLE
Autoregressives Modell	0,85 – 2,34	Cepni et al. (2020)
Autoregressives Modell	0,80 – 1,52*	Jung et al. (2018)
Autoregressives Modell	0,29 – 0,31	Campos Vázquez/López-Araiza B. (2020)
Vektorautoregressives Modell	1,09 – 2,20*	Jung et al. (2018)
Brückengleichungsmodell	0,58 – 0,66	Bañbura et al. (2013)
Brückengleichungsmodell (GDPNow)	1,15 – 2,2	Higgins (2014)
Dynamisches Faktormodell	0,18 – 0,28	Bañbura et al. (2011)
Dynamisches Faktormodell	0,43 – 0,57	Bañbura et al. (2013)
Dynamisches Faktormodell (ifoCAST)	0,32	Lehmann et al. (2020)
Bestes ML-Modell	0,20 – 0,81*	Jung et al. (2018)
LASSO	0,28	Campos Vázquez/López-Araiza B. (2020)
Random Forest	0,29	Campos Vázquez/López-Araiza B. (2020)

RMSE = root mean square error (Wurzel der mittleren Fehlerquadratsumme)

\* Werte beziehen sich auf Quartalsprognose mit Krisenzeitraum (2007 bis 2016)

Quelle: Eigene Darstellung.

Weitere potenzielle Frühindikatoren, die sich aus bisher kaum genutzten Datensätzen diverser Aktivitäten ableiten lassen, werden vom Statistischen Bundesamt untersucht. Beispielsweise kann mit Mobilfunkdaten die Mobilität der Bevölkerung dargestellt werden. Im Zuge der COVID-19-Pandemie wurden so allgemeine Unterschiede im Pendlerverhalten erkannt. Ein solcher Näherungswert kann als tagesaktueller Index der konjunkturellen Aktivität in bestimmten Gebieten verwendet werden. Als frühzeitige Umsatzprognose eignet sich die Auswertung von Umsatzsteuervoranmeldungen. Des Weiteren kann mit Daten zu Onlinetransaktionen sowie neuen Hypotheken- und Kreditverträgen die Aktivität im Onlinehandel, bei Hauskäufen oder beim privaten Konsum abgebildet werden.<sup>105</sup>

Zur frühzeitigen Prognose von Verbraucherpreisen können Scannerdaten aus dem Einzelhandel herangezogen werden. Sie enthalten Informationen über Art, Absatz und Umsatz verkaufter Artikel und werden an der Kasse erfasst. Dabei kann auch die Nachfrage nach bestimmten Produktgruppen analysiert werden. Außerdem kann man daraus die gegenwärtige wirtschaftliche Lage des Einzelhandels ableiten. Des Weiteren können Satellitendaten zur Bestimmung der wirtschaftlichen Aktivität herangezogen werden, zum Beispiel zum Aufkommen an Schiffen auf dem Meer oder von Autos vor einem Geschäft.<sup>106</sup> Als Frühindikator

<sup>105</sup> Hauf/Stehrenberg/Zwick (2020), S. 55–60.

<sup>106</sup> Hauf/Stehrenberg/Zwick (2020), S. 55–60.

für die Industrieproduktion in Deutschland kann ein an Arbeitstagen aktualisierter Lkw-Maut-Fahrleistungsindex verwendet werden. Die Fahrleistung großer Lkw kann damit mit fünf bis neuntägigem Abstand ziemlich genau erfasst werden.<sup>107</sup>

Eine weitere potenzielle Quelle von Big Data für ökonomische Analysen sind Textdaten. Ähnlich wie in den Beiträgen von Silke Sturm sowie von Deniz Dilan Karaman Örsal in diesem Band beschrieben, können Textdaten aus den Sozialen Medien automatisiert ausgewertet werden und als weiterer, sehr kurzfristiger Faktor in Nowcasts einfließen. Erste Erfahrungen im Bereich der Politikanalyse sowie bei der Prognose von Kaufverhalten deuten auf eine hohe Genauigkeit dieses Verfahrens hin. Manche Forscher:innen gehen sogar so weit zu sagen, dass Wörter die neuen Zahlen sind.<sup>108</sup> Mehr Informationen zur Verwendung von Textdaten aus Zeitungen für die Konjunkturanalyse mit Nowcasts finden sich auch in Thorsrud<sup>109</sup>.

Mit der Nutzung von Big Data, den Methoden des ML sowie dem Nowcast selbst gehen einige Probleme einher. Beispielsweise verlangt die große Geschwindigkeit von Big Data eine Vielzahl notwendiger Reaktionen. Diese schnellen Reaktionen erfordern im Gegenzug enorme Ressourcen für die zeitnahe Sammlung, Speicherung und Verarbeitung der Daten. Außerdem können sowohl die Ungenauigkeit als auch die Verschiedenartigkeit der Daten und die damit einhergehende Komplexität teilweise nicht ohne Weiteres bewältigt werden.<sup>110</sup> So liegen viele Probleme mit Big Data in den hohen Anforderungen begründet, die diese Datenart an Systemarchitekturen, Datenverarbeitungsrahmen sowie Verarbeitungsmodi stellt.<sup>111</sup>

Außerdem kann es bei der Vielzahl von Datenpunkten leicht passieren, dass ein Ergebnis nur aufgrund der Menge der Daten statistisch signifikant ist und nicht aufgrund eines tatsächlichen Zusammenhangs. Darüber hinaus werden mit Big Data überwiegend Korrelationen und keine Kausalitäten aufgezeigt (Scheinkorrelationen). Auch das Auswerten von Daten ohne zugrunde liegende Theorie, die die Ergebnisse erklären könnte, kann zu Problemen führen.<sup>112</sup> Des-

---

<sup>107</sup> Cox et al. (2020).

<sup>108</sup> Thorsrud (2020), S. 393.

<sup>109</sup> Thorsrud (2020).

<sup>110</sup> Jin et al. (2015), S. 59 und 62.

<sup>111</sup> Jin et al. (2015), S. 63.

<sup>112</sup> Taylor/Schroeder/Meyer (2014), S. 6–7.

wegen bezweifeln Ökonom:innen häufig die Zuverlässigkeit und die Repräsentativität von Big Data.<sup>113</sup>

Aus unternehmerischer Sicht gibt es zwei weitere Herausforderungen. Einerseits existiert eine Kluft zwischen Unternehmen, die über viele Daten verfügen, zum Beispiel Social-Media-Plattformen, und solchen, die kaum Zugriff auf Daten haben. Andererseits müssen Unternehmen über entsprechende Technologien und Fertigkeiten im Umgang mit Big Data verfügen, um wettbewerbsfähig zu sein.<sup>114</sup>

Bezüglich des ML ist es problematisch, dass diese Verfahren oft nicht ohne Weiteres erklären können, welche Faktoren zu der Prognose geführt haben, weil der Analyse kein spezielles Modell zugrunde liegt. Deswegen sind die mit Methoden des ML erlangten Ergebnisse nur schwer nachvollziehbar und interpretierbar und bleiben häufig sozusagen in einer Black Box.<sup>115</sup>

Um langfristig als zuverlässige Konjunkturprognose anerkannt zu werden, müssen Nowcasts, die auf Big Data und ML-Methoden basieren, bestimmte Kriterien erfüllen. Laut Deutscher Bundesbank ist die Prognosegüte dabei der wichtigste Faktor, also die Frage, wie genau das jeweilige Modell eine relevante Zielvariable voraussagen kann. Außerdem sollte das Modell möglichst geringen Schwankungen unterliegen, um die Interpretation und Kommunikation aktueller Ergebnisse zu erleichtern. Darüber hinaus ist jedoch auch relevant, dass das Ergebnis mit Hilfe des Modells nachvollzogen werden kann.<sup>116</sup> Dies gestaltet sich, wie oben beschrieben, bei Verfahren des ML häufig schwierig. Abgesehen davon ist die frühzeitige Prognose von Trendwenden immens wichtig. Da dies nicht so leicht zu erreichen ist, sollte das Augenmerk auch auf die Vorhersage solcher Wendungen gelegt werden. Weitere Probleme beim ökonomischen Nowcasting, wie mögliche Messfehler, werden in Castle et al.<sup>117</sup> beleuchtet.

Überdies gilt es, auch ethische und datenschutzrechtliche Erwägungen zu berücksichtigen. Ungeachtet der Vorteile der Big-Data-Analyse kann es aus ethischer Sicht ungünstig sein, dass sowohl in der Gegenwart als auch in der Zukunft der freie Wille nicht geschützt ist, da mit großen Datenmengen gegen-

---

<sup>113</sup> Taylor/Schroeder/Meyer (2014), S. 1.

<sup>114</sup> Mauro/Greco/Grimaldi (2015), S. 100–101.

<sup>115</sup> Sachverständigenrat (2019), S. 54; Jung/Patnam/Ter-Martirosyan (2018), S. 4–5.

<sup>116</sup> Deutsche Bundesbank (2018), S. 17.

<sup>117</sup> Castle/Fawcett/Hendry (2009).

wärtiges Verhalten untersucht und zukünftiges Verhalten prognostiziert und damit auch für manipulative Zwecke instrumentalisierbar wird.<sup>118</sup>

Außerdem ist aus datenschutzrechtlichen Gründen der Zugriff auf interessante Datensätze nur eingeschränkt möglich. Häufig werden Daten nur dort ausgewertet, wo sie gesammelt werden. Beispielsweise wird der Lkw-Maut-Fahrleistungsindex vom Bundesamt für Güterverkehr erstellt. Kooperationen mit anderen Einrichtungen wie dem Statistischen Bundesamt werden ebenfalls durchgeführt. Allerdings ist es nur schwer vorstellbar, dass solche Daten in Deutschland kurzfristig einer Vielzahl von Forscher:innen zur Verfügung gestellt werden. Auch Verwaltungsdaten sind hochinteressant für die Wirtschaftsforschung. Allerdings ist der Zugriff auf diese Daten je nach Land sehr umständlich.<sup>119</sup> Daten aus dem privaten Sektor können beispielsweise durch Kollaborationen mit privaten Firmen analysiert werden.<sup>120</sup> Abgesehen davon sind Verfügbarkeit und Zugriff auf Daten europaweit sehr unterschiedlich geregelt,<sup>121</sup> sodass Big-Data-Prognosen unter Berücksichtigung der jeweiligen länderspezifischen gesetzlichen Regelungen erfolgen müssen. Dennoch sind die mit solchen Datensammlungen machbaren Prognosen voller Potenzial und von großer Bedeutung für zukünftige Konjunkturvorhersagen.

## Schlussfolgerungen

Konventionelle Methoden zur Vorhersage der Konjunkturentwicklung reichen nicht mehr aus, da sie Veränderungen und Wandel nicht genau genug abbilden und Trendwenden nicht frühzeitig genug erkennen. Wissenschaft und auch Gesellschaft verlangen nach neuen, besseren Prognoseverfahren. Dieser Beitrag hat gezeigt, dass es neue Möglichkeiten der Konjunkturprognose gibt, gerade auch durch, mit und dank der Datenökonomie.

Eine in der gegenwärtigen Literatur vieldiskutierte Alternative zu traditionellen Forecasts sind hochaktuelle Nowcasts, die, wenn sie auf hochfrequenten Daten beruhen, quasi in Echtzeit Informationen lesen und zu Prognosen der Gegenwart verarbeiten können. Verschiedene Verfahren verweisen auf die schier unendlichen Möglichkeiten der Kombination von Big Data und ML mit

---

<sup>118</sup> Mauro/Greco/Grimaldi (2015), S. 100.

<sup>119</sup> Einav/Levin (2014b), S. 2–3.

<sup>120</sup> Einav/Levin (2014b), S. 3.

<sup>121</sup> Hauf/Stehrenberg/Zwick (2020), S. 61.

Nowcasts. Im Allgemeinen zeichnet sich bei diesem Ansatz eine Tendenz zu erhöhter Prognosegüte gegenüber herkömmlichen Verfahren ab.

Momentan steht die Wissenschaft noch am Anfang dieser neuartigen Entwicklungen. Trotz der genannten Limitationen wird weiter an der Entwicklung von Nowcasts entscheidender makroökonomischer Variablen wie des BIP gearbeitet werden, da die Kenntnis der gegenwärtigen Konjunktur von großer Bedeutung ist, das Potenzial von Big Data enorm und ML für die effiziente Auswertung dieser Daten bestens geeignet ist. Der Drang nach Etablierung und Weiterentwicklung von Nowcasts zeigt sich beispielsweise an den enormen Fortschritten, die im vergangenen Jahr auf diesem Gebiet in Instituten und Zentralbanken gemacht wurden. Schon jetzt ermöglichen die verschiedenen Nowcasts einen ersten Schritt in Richtung Neuvermessung der Weltwirtschaft, indem Informationen zu konjunkturellen Aktivitäten (zum Beispiel das BIP) früher veröffentlicht werden, ohne große Einbußen an Genauigkeit hinnehmen zu müssen. Auf längere Sicht ist es denkbar, dass die Verfügbarkeit eines genauen, aktuellen Konjunkturindikators zu einem Wettbewerbsvorteil für Unternehmen, Institutionen und Länder werden kann. Wer früher als alle anderen über die gegenwärtigen Entwicklungen informiert ist, kann am besten auf die Wirtschaft einwirken und somit Tendenzen verstärken oder frühzeitig abfangen.

Die immense Bedeutung der riesigen Datenmengen (das heißt von Big Data), mit denen das Verhalten Einzelner, aber auch die Entwicklungen einer ganzen Volkswirtschaft relativ genau beschrieben werden können, wird immer deutlicher werden, auch für Nowcasts. Es zeigt sich bereits, dass die Erweiterung traditioneller Prognosen um diese Datenart die Genauigkeit von Vorhersagen erhöht. Um Big Data möglichst effizient auszuwerten, sollten insbesondere Methoden des ML zum Einsatz kommen und mit den Ergebnissen herkömmlicher Verfahren verglichen werden. Vieles deutet darauf hin, dass künstliche Intelligenz die Zukunft mitgestalten wird. Deswegen müsste auch die Wissenschaft von dieser Art, Informationen zu verarbeiten, Gebrauch machen. Dabei sollte ML nicht vorwiegend als Konkurrenz zu etablierten Methoden betrachtet werden, sondern als Möglichkeit, bestehende Ansätze zu erweitern beziehungsweise zu vertiefen.

Damit es nicht zu ethischen Problemen kommt, muss die Auswertung von Big Data sehr vorsichtig und nach international festgelegten Regeln und Gesetzen erfolgen. Dann bieten sich der Echtzeitprognose wichtiger Kennzahlen unzählige Möglichkeiten und die neue Datenökonomie kann selbst dazu beitragen, die mit ihr einhergehenden Herausforderungen zu bewältigen.

## Literatur

- Aastveit, K. A.; Gerdrup, K. R.; Jore, A. S.; Thorsrud, L. A. (2014): Now-casting GDP in Real Time: A Density Combination Approach. In: *Journal of Business & Economic Statistics* Vol. 32 (1), S. 48–68, DOI <https://doi.org/10.1080/07350015.2013.844155>.
- An der Heiden, M.; Hamouda, O. (2020): Schätzung der aktuellen Entwicklung der SARS-CoV-2-Epidemie in Deutschland – Nowcasting. In: *Epidemiologisches Bulletin* Vol. 17, S. 10–16, DOI <https://doi.org/10.25646/6692.4>.
- Armstrong, J. S. (Hrsg.) (2004): *Principles of Forecasting. A Handbook for Researchers and Practitioners*. 4. Aufl., Kluwer Academic Publishers. New York, Boston, Dordrecht, London, Moskau (30).
- Bañbura, M.; Giannone, D.; Modugno, M.; Reichlin, L. (2013): Now-casting and the Real-Time Data Flow. In: Elliott, G. und Timmermann, A. (Hrsg.): *Handbook of Economic Forecasting*, North Holland, Amsterdam, S. 195–237.
- Bañbura, M.; Giannone, D.; Reichlin, L. (2011): Nowcasting. In: Clements, M. P. und Hendry, D. F. (Hrsg.): *The Oxford Handbook of Economic Forecasting*, Oxford University Press, Oxford, New York, Auckland, S. 193–223.
- Bok, B.; Caratelli, D.; Giannone, D.; Sbordone, A. M.; Tambalotti, A. (2018): Macroeconomic Nowcasting and Forecasting with Big Data. In: *Annual Review of Economics* Vol. 10 (1), S. 615–643, DOI <https://doi.org/10.1146/annurev-economics-080217-053214>.
- Bundesministerium für Wirtschaft und Energie (2019): Nowcasting: Ein Echtzeit-Indikator für die Konjunkturanalyse. In: *Schlaglichter der Wirtschaftspolitik* (a), S. 12–15.
- Bureau of Economic Analysis (2020): National Data. National Income and Product Accounts. Online verfügbar unter <https://apps.bea.gov/iTable/iTable.cfm?reqid=19&step=2#reqid=19&step=2&isuri=1&1921=survey>, zuletzt geprüft am 05.11.2020.
- Campos Vázquez, R. M.; López-Araiza B., S. E. (2020): Grandes Datos, Google y Desempleo - Big Data, Google and Unemployment. In: *Estudios Económicos* Vol. 35 (1), S. 125–151, DOI <https://doi.org/10.2307/26863997>.
- Castle, J. L.; Fawcett, N. W.; Hendry, D. F. (2009): Nowcasting is not Just Contemporaneous Forecasting. In: *National Institute Economic Review* Vol. 210, S. 71–89, DOI <https://doi.org/10.1177/0027950109354412>.
- Cepni, O.; Guney, I. E.; Swanson, N. R. (2020): Forecasting and Nowcasting Emerging Market GDP Growth Rates. The Role of Latent Global Economic Policy Uncertainty and Macroeconomic Data Surprise Factors. In: *Journal of Forecasting* Vol. 39 (1), S. 18–36, DOI <https://doi.org/10.1002/for.2602>.

- Cox, M.; Triebel, J.; Linz, S.; Fries, C.; Flores, L. F.; Lorenz, A. et al. (2020): Täglicher Lkw-Maut-Fahrleistungsindex aus digitalen Prozessdaten der Lkw-Mauterhebung. In: WISTA - Wirtschaft und Statistik Vol. 72 (4), S. 63–76.
- Deutsche Bundesbank (2018): Modelle zur kurzfristigen Konjunkturprognose: eine Aktualisierung. In: Monatsbericht, September, S. 15–29.
- Deutsche Bundesbank (2020): Methodik. Wöchentlicher Aktivitätsindex. Online verfügbar unter <https://www.bundesbank.de/de/statistiken/konjunktur-und-preise/woechentlicher-aktivitaetsindex/methodik-833778>, zuletzt geprüft am 25.9.20.
- Deutscher Wetterdienst (DWD) (2020): Nowcasting-Verfahren. Online verfügbar unter [https://www.dwd.de/DE/forschung/wettervorhersage/met\\_fachverfahren/nowcasting/nowcasting\\_node.html](https://www.dwd.de/DE/forschung/wettervorhersage/met_fachverfahren/nowcasting/nowcasting_node.html), zuletzt geprüft am 28.7.2020.
- Dickopf, X.; Janz, C.; Mucha, T. (2019): Vom BIP-Flash zum BIP-Nowcast. Erste Ergebnisse einer Machbarkeitsstudie zur weiteren Beschleunigung der BIP-Schnellschätzung. In: WISTA - Wirtschaft und Statistik Vol. 71 (6), S. 47–58.
- Doody, R.; Kokkinen, A.; Wouters, H. (2016): Euro Area and European Union GDP Flash Estimates at 30 Days, Publications Office. Luxemburg.
- Einav, L.; Levin, J. (2014): Economics in the Age of Big Data. In: Science Vol. 346 (6210), S. 1–6, DOI <https://doi.org/10.1126/science.1243089>.
- Eurostat (2019): Vorläufige Schnellschätzung des BIP für Europa 30 Tage nach Quartalsende. Online verfügbar unter [https://ec.europa.eu/eurostat/statistics-explained/index.php/Preliminary\\_GDP\\_flash\\_estimate\\_in\\_30\\_days\\_for\\_Europe/de](https://ec.europa.eu/eurostat/statistics-explained/index.php/Preliminary_GDP_flash_estimate_in_30_days_for_Europe/de), zuletzt aktualisiert am 19.8.19, zuletzt geprüft am 25.9.20.
- Federal Reserve Bank of Atlanta (2020): GDPNow. Online verfügbar unter <https://www.frbatlanta.org/cqer/research/gdpnow?panel=2>, zuletzt geprüft am 25.9.20.
- Federal Reserve Bank of New York (2019): Nowcasting and Forecasting with Big Data. Unter Mitarbeit von Time Series Analysis Team. Federal Reserve Bank of New York.
- Federal Reserve Bank of New York (2020): Nowcasting Report. Online verfügbar unter <https://www.newyorkfed.org/research/policy/nowcast.html>, zuletzt geprüft am 19.11.2020.
- Garboden, P. M. E. (2020): Sources and Types of Big Data for Macroeconomic Forecasting. In: Fuleky, P. (Hrsg.): Macroeconomic Forecasting in the Era of Big Data. Theory and Practice. 1. Aufl., Springer International Publishing, Cham, S. 3–23.
- Giannone, D.; Reichlin, L.; Small, D. (2008): Nowcasting: The real-time informational content of macroeconomic data. In: Journal of Monetary Economics Vol. 55 (4), S. 665–676, DOI <https://doi.org/10.1016/j.jmoneco.2008.05.010>.

- Günther, F.; Bender, A.; Katz, K.; Küchenhoff, H.; Höhle, M. (2020): Now-casting the COVID-19 Pandemic in Bavaria. Ludwig-Maximilians-Universität München.
- Gupta, M.; Minai, M. H. (2019): An Empirical Analysis of Forecast Performance of the GDP Growth in India. In: *Global Business Review* Vol. 20 (2), S. 368–386, DOI <https://doi.org/10.1177/0972150918825207>.
- Hauf, S.; Stehrenberg, S.; Zwick, M. (2020): EXDAT - Experimentelle Daten und Methoden für eine Innovative Statistik. In: *WISTA - Wirtschaft und Statistik* Vol. 72 (4), S. 51–62.
- Higgins, P. (2014): GDPNow: A Model for GDP „Nowcasting“. In: *Federal Reserve Bank of Atlanta Working Paper Series* Vol. 7.
- Höhle, M.; An der Heiden, M. (2014): Bayesian nowcasting during the STEC O104:H4 outbreak in Germany, 2011. In: *Biometrics* Vol. 70 (4), S. 993–1002, DOI <https://doi.org/10.1111/biom.12194>.
- Jin, X.; Wah, B. W.; Cheng, X.; Wang, Y. (2015): Significance and Challenges of Big Data Research. In: *Big Data Research* Vol. 2 (2), S. 59–64, DOI <https://doi.org/10.1016/j.bdr.2015.01.006>.
- Jung, J.-K.; Patnam, M.; Ter-Martirosyan, A. (2018): An Algorithmic Crystal Ball. Forecasts-based on Machine Learning. Washington, D.C. (IMF working paper).
- Lawless, J. F. (1994): Adjustments for reporting delays and the prediction of occurred but not reported events. In: *The Canadian Journal of Statistics* Vol. 22 (1), S. 15–31.
- Lehmann, R.; Reif, M.; Wollmershäuser, T. (2020): ifoCAST: Der neue Prognosestandard des ifo Instituts. In: *ifo Schnelldienst* Vol. 73 (11), S. 31–39. Online verfügbar unter <https://www.ifo.de/publikationen/2020/aufsatz-zeitschrift/ifocast-der-neue-prognosestandard-des-ifo-instituts>, zuletzt geprüft am 1.7.2021.
- Mauro, A. de; Greco, M.; Grimaldi, M. (2015): What is big data? A consensual definition and a review of key research topics. In: *AIP Conference Proceedings* Vol. 1644 (1), S. 97–104, DOI <https://doi.org/10.1063/1.4907823>.
- Pons, J. (2000): The accuracy of IMF and OECD forecasts for G7 countries. In: *Journal of Forecasting* Vol. 19 (1), S. 53–63.
- Sachverständigenrat zur Begutachtung der gesamtwirtschaftlichen Entwicklung (2019): Den Strukturwandel meistern. Jahresgutachten 19/20.
- Statistisches Bundesamt (2020): Volkswirtschaftliche Gesamtrechnung. BIP Schnellschätzung t+30. Online verfügbar unter <https://www.destatis.de/DE/Themen/Wirtschaft/Volkswirtschaftliche-Gesamtrechnungen-Inlandsprodukt/AnkuendigungBIPFlash.html>, zuletzt aktualisiert am 30.7.2020, zuletzt geprüft am 3.12.2020.

- Stock, J. H.; Watson, M. W. (2017): Twenty Years of Time Series Econometrics in Ten Pictures. In: *Journal of Economic Perspectives* Vol. 31 (2), S. 59–86, DOI <https://doi.org/10.1257/jep.31.2.59>.
- Taylor, L.; Schroeder, R.; Meyer, E. (2014): Emerging Practices and Perspectives on Big Data Analysis in Economics: Bigger and Better or More of the Same? In: *Big Data & Society* Vol. 1 (2), S. 1-10, DOI <https://doi.org/10.1177/2053951714536877>.
- Thorsrud, L. A. (2020): Words are the New Numbers: A Newsy Coincident Index of the Business Cycle. In: *Journal of Business & Economic Statistics* Vol. 38 (2), S. 393–409, DOI <https://doi.org/10.1080/07350015.2018.1506344>.
- Varian, H. R. (2014): Big Data: New Tricks for Econometrics. In: *Journal of Economic Perspectives* Vol. 28 (2), S. 3–28, DOI <https://doi.org/10.1257/jep.28.2.3>.
- Vosen, S.; Schmidt, T. (2011): Forecasting Private Consumption: Survey-based Indicators vs. Google Trends. In: *Journal of Forecasting* Vol. 30 (6), S. 565–578, DOI <https://doi.org/10.1002/for.1213>.
- Woloszko, N. (2017): Economic Modelling and Machine Learning. A Proof of Concept. Konferenzpapier. Organisation for Economic Co-operation and Development. Paris.
- World Meteorological Organization (2017): Guidelines for Nowcasting Techniques.



## Verfasserinnen und Verfasser

ISLAM, ZAHURUL, Professor an der NORDAKADEMIE Hochschule der Wirtschaft

KARAMAN ÖRSAL, DENIZ DILAN, Dr. rer. pol. (Humboldt-Universität zu Berlin), Universität Hamburg und außerplanmäßige Professorin an der Leuphana Universität Lüneburg.

MAASS, CHRISTINA HEIKE, M. Sc. in Economics, Universität Hamburg

ROTH, FELIX, Privatdozent für Volkswirtschaftslehre an der Universität Hamburg und Leiter des Projekts GLOBALINTO im Rahmen der Horizon-2020-Forschungsförderung der Europäischen Kommission

SCHEFFER, NIKLAS, cand. rer. pol. (Universität Potsdam), Universität Hamburg, Institut für Computer Aided Psychometric Text Analysis (CAPTA)

SCHNEIDER, HENRIQUE, Professor für Volkswirtschaftslehre an der Nordakademie, Hochschule der Wirtschaft, in Elmshorn und stellvertretender Direktor des Schweizerischen Gewerbeverbands sgv in Bern, Schweiz

STRAUBHAAR, THOMAS, Professor für Volkswirtschaftslehre, insbesondere Internationale Wirtschaftsbeziehungen der Universität Hamburg

STURM, SILKE, M. Sc (Universität Bayreuth), Universität Hamburg

VÖPEL, HENNING, Hamburgisches WeltWirtschaftsinstitut (HWWI) und Professor der Hamburg School of Business Administration (HSBA)



Hamburgisches  
WeltWirtschafts  
Institut

Reihe Edition HWWI

herausgegeben von Thomas Straubhaar

In der Edition HWWI (ISSN 1865-7974) erscheinen abgeschlossene, umfangreiche Projektergebnisse sowie Dissertationen zu Forschungsthemen, die vom HWWI bearbeitet werden. Folgende Titel sind bisher erschienen:

- Band 1: Thomas Straubhaar (Hg.): Bedingungsloses Grundeinkommen und Solidarisches Bürgergeld – mehr als sozialutopische Konzepte, 2008.  
ISBN 978-3-937816-47-0, DOI <https://doi.org/10.15460/HUP.HWWI.1.69>.
- Band 2: Martin-Peter Büch et al. (Hg.): Sportfinanzierung – Spannungen zwischen Markt und Staat, 2009.  
ISBN 978-3-937816-53-1, DOI <https://doi.org/10.15460/HUP.HWWI.2.70>.
- Band 3: Martin-Peter Büch et al. (Hg.): Zur Ökonomik von Spitzenleistungen im internationalen Sport, 2012.  
ISBN 978-3-937816-87-6, DOI <https://doi.org/10.15460/HUP.HWWI.3.122>.
- Band 4: Martin-Peter Büch et al. (Hg.): Sport und Sportgroßveranstaltungen in Europa – zwischen Zentralstaat und Regionen, 2012.  
ISBN 978-3-937816-88-3, DOI <https://doi.org/10.15460/HUP.HWWI.4.123>.
- Band 5: Seçil Paçacı Elitok, Thomas Straubhaar (eds.): Turkey, Migration and the EU: Potentials, Challenges and Opportunities, 2012.  
ISBN 978-3-937816-94-4, DOI <https://doi.org/10.15460/HUP.HWWI.5.118>.
- Band 6: Thomas Straubhaar (Hg.): Neuvermessung der Datenökonomie, 2021.  
ISBN (Print) 978-3-943423-91-4, (Epub) 978-3-943423-94-5,  
DOI <https://doi.org/10.15460/HUP.HWWI.6.212>.

Die Online-Ausgaben der Reihe sind frei zugänglich als Open-Access-Publikation erschienen. Die Printversion kann über den Buchhandel oder direkt beim Verlag (<https://hup.sub.uni-hamburg.de>) bezogen werden.