

OTH

OSTBAYERISCHE  
TECHNISCHE HOCHSCHULE  
REGENSBURG

BW

BETRIEBSWIRTSCHAFT

REGENSBURG PAPERS IN MANAGEMENT AND ECONOMICS - NO. 2

## „Nowcasting des deutschen BIP“

AUTOREN:

JENS DOLL, BEATRICE ROSENTHAL,  
JONAS VOLKENAND, SANDRA HAMELLA



# Nowcasting des deutschen BIP

Jens Doll\*, Beatrice Rosenthal\*, Jonas Volkenand\*, Sandra Hamella\*\*

Januar 2017

\*) BayernInvest  
Kapitalverwaltungsgesellschaft mbH  
Karlstraße 35  
D-80333 München

\*\*) OTH Regensburg  
Seybothstraße 2  
D-93053 Regensburg

## Abstract:

Although there are numerous institutions predicting the German gross domestic product, there is currently a lack of so-called "nowcasting" models, in which the forecast quality is improved for every newly available data point. The following work develops and tests a concept to enable nowcasting forecasts for the German gross domestic product on the basis of bottom-up modeling. The combination of models used contributes a new approach to the current literature on nowcasting for the German gross domestic product. By means of the diversified prediction of the individual components and the improved forecasting quality, a detailed interpretation of the economic situation also becomes possible. Compared to benchmark models, the prediction model results in few prognosis errors, which is particularly important in times of crisis.

## Deutscher Abstract

Obgleich es zahlreiche Institutionen gibt, die das deutsche Bruttoinlandsprodukt vorhersagen, mangelt es aktuell an sogenannten „Nowcasting“-Modellen, deren Prognosegüte mit jedem neu verfügbaren, das deutsche Bruttoinlandsprodukt beeinflussenden Datenpunkt verbessert wird. In der folgenden Arbeit wird ein Konzept entwickelt und getestet, das auf Basis einer Bottom-up-Modellierung Nowcasting-Prognosen für das deutsche Bruttoinlandsprodukt ermöglicht. Hierbei bringt es mit der verwendeten Kombination von Modellen einen neuen Ansatz in die aktuelle Literatur des Nowcasting für das deutsche Bruttoinlandsprodukt ein. Durch die diversifizierte Vorhersage der einzelnen Komponenten ist neben einer verbesserten Prognosegüte ebenfalls eine dezidierte Interpretation des wirtschaftlichen Geschehens möglich. Das vorgestellte Prognosemodell zeigt in einem Pseudo Out of Sample Test eine gute Prognoseleistung im Vergleich zu Benchmark-

Modellen und kann insbesondere in Krisenzeiten mit geringen Prognosefehlern überzeugen.

**Keywords:** Nowcasting, Bruttoinlandsprodukt, kurzfristige Konjunkturprognose, Wachstum, Bottom-up, Brückengleichungen, Deutschland

**JEL:** E 32, E 37, C 51, C 52, C 53

## Inhaltsverzeichnis

Abbildungsverzeichnis.....	iv
Tabellenverzeichnis .....	iv
Abkürzungsverzeichnis.....	iv
1. Einleitung .....	1
2. Stand der Forschung .....	2
3. Herausforderungen .....	3
4. Modellbeschreibung.....	5
4.1 Datensatz .....	6
4.2 Bottom-up-Ansatz .....	7
4.3 Auswahl monatlicher Indikatoren.....	8
4.4 Brückengleichungen.....	9
4.4.1 Fortschreibung der monatlichen Indikatoren.....	10
4.4.2 Aggregation auf Quartalsebene .....	11
4.4.3 Regression der Subkomponenten.....	12
4.4.4 Aggregation des Bruttoinlandsprodukts .....	14
5. Empirische Analyse.....	16
5.1 Pseudo Out of Sample .....	16
5.2 Ergebnisse.....	17
6. Problematik und Ausblick.....	21
7. Fazit.....	23
8. Literaturverzeichnis .....	25
9. Anhang.....	26

## **Abbildungsverzeichnis**

Abbildung 1 Zerlegung des BIP in Komponenten und Subkomponenten.....	8
Abbildung 2 Nowcasting-Prognosen Deutschland (1 Monat) .....	18

## **Tabellenverzeichnis**

Tabelle 1 Prognosezeitpunkte.....	10
Tabelle 2 Pseudo out of Sample-Ergebnisse .....	19
Tabelle 3 Trefferquote Tendenz .....	20

## **Abkürzungsverzeichnis**

AIC: Akaike Informationskriterium

AR: Autoregressiv

ARDL: Autoregressive Distributed Lag

BIC: Bayessche Informationskriterium

BIP: Bruttoinlandsprodukt

MIDAS: Mixed-Data Sampling

OLS: Ordinary Least Squares

RMSE: Root Mean Squared Error

VAR: Vektorautoregressiv

## 1. Einleitung

Für Akteure am Kapitalmarkt spielen die Veröffentlichungen wirtschaftlicher Daten eine außerordentlich wichtige Rolle. Weichen diese deutlich von der Konsenserwartung ab, so kann es unter Umständen zu erheblichen Bewegungen am Kapitalmarkt kommen. Diese Schwankungen bestmöglich vorausszusehen und sich im Vorfeld entsprechend zu positionieren, ist ein für die meisten Fondsmanager erstrebenswertes Ziel, das helfen kann, den entscheidenden Vorsprung im Vergleich zu den übrigen Akteuren am Kapitalmarkt zu erzielen.

Hierbei spielt die Verlässlichkeit von Prognosen eine wichtige Rolle. Je treffsicherer die bezüglich des zur Veröffentlichung anstehenden Datenpunktes anstehende Prognose ist, desto leichter lässt sich eine Vermutung im Hinblick auf das Ausmaß der zu erwartenden Marktbewegung anstellen. Eine besondere Bedeutung kommt dabei der Idee des „Nowcastings“ zu. Hierbei handelt es sich um die Vorabschätzung eines bereits realisierten und zur Veröffentlichung anstehenden Datenpunktes unter der Zuhilfenahme von bis zum Veröffentlichungszeitpunkt bereits verfügbaren Daten, die maßgeblich Einfluss auf den Datenpunkt von Interesse haben.

Nicht zuletzt das deutsche Bruttoinlandsprodukt (BIP) ist einer der Datenpunkte, die möglicherweise marktbewegend sein können. Obgleich es eine Vielzahl an Institutionen gibt, die das deutsche Bruttoinlandsprodukt vorhersagen, mangelt es aktuell an „Nowcasting“-Modellen, deren Prognosegüte mit jedem neu verfügbaren, das deutsche Bruttoinlandsprodukt beeinflussenden Datenpunkt verbessert wird. Ziel der vorliegenden Arbeit ist es, ein solches Modell zu entwickeln.

Das in diesem Papier vorgestellte Konzept des Nowcastings für das deutsche Bruttoinlandsprodukt folgt dabei einer Bottom-up-Modellierung. Dies bietet einige zentrale Vorteile. Zum einen können Vorhersagebeziehungen zwischen einzelnen Indikatoren und Subkomponenten des Bruttoinlandsprodukts ausgenutzt werden, obwohl diese möglicherweise kaum eine Prognosekraft für das gesamte Bruttoinlandsprodukt besitzen. Ein weiterer Vorteil ist die Möglichkeit der Aufnahme von Vergangenheitsdaten einzelner Wirtschaftsbereiche in die Prognose des

Bruttoinlandsprodukts. Ein nachhaltig sinkender privater Konsum kann beispielsweise auch dann bei der Prognose über autoregressive Prozesse berücksichtigt werden, wenn dessen Entwicklung auf Aggregationsebene durch steigende Staatsausgaben oder Exporte ausgeglichen wird. Schlussendlich ist wohl der für viele Ökonomen wichtigste Vorteil von Bottom-up-Modellen, dass nicht nur Prognosen des Bruttoinlandsprodukts als Ganzes angestellt werden, sondern auch Vorhersagen für die einzelnen Subkomponenten. Dies ermöglicht eine tiefergehende Analyse der aktuellen wirtschaftlichen Entwicklung und ihrer Treiber.

Im Folgenden gibt diese Arbeit zunächst einen kurzen Überblick über den aktuellen Forschungsstand im Bereich der kurzfristigen Konjunkturprognose sowie eine Analyse der besonderen Herausforderungen. Nach einer ausführlichen Beschreibung des entwickelten Prognosemodells sowie Vorstellung und Analyse der empirischen Ergebnisse, schließt eine kritische Diskussion die Arbeit ab.

## **2. Stand der Forschung**

Im Bereich der kurzfristigen Konjunkturprognose existiert ein kaum mehr überschaubares Angebot an Modellen und Methoden, die auf die unterschiedlichsten Weisen in den verschiedenen nationalen Prognosen angewendet werden. In jüngster Vergangenheit erfreuen sich besonders Modelle, die auf Basis monatlicher Indikatoren Prognosen für das Bruttoinlandsprodukt als Ganzes sowie dessen einzelne Komponenten gleichermaßen anstellen, zunehmender Beliebtheit.

Die grundlegende Vorgehensweise der kurzfristigen Konjunkturprognose im Allgemeinen und somit auch des Nowcastings im Speziellen stellt die Regression des Bruttoinlandsprodukts oder dessen Wachstums direkt auf verschiedene Indikatoren und Vergangenheitswerte dar. Aufgrund ihrer Einfachheit und schnellen Anwendung wird diese (auch als Top-down Methodik bezeichnete) Vorgehensweise nach wie vor in vielen Prognose-Modellen verwendet. Ingenito und Trehan (1996) regressieren für ihre Prognose des realen Bruttoinlandsprodukts in den USA dieses in einem solchen



Ansatz per OLS-Regression direkt auf den privaten Konsum und die Beschäftigung als Indikatoren sowie auf mehrere Vergangenheitswerte (Lags) des Bruttoinlandsprodukts selbst.<sup>1</sup> Auch Rünstler et al. (2009) prognostizieren für ihren Vergleich diverser Top-Down Modelle das Wachstum des Bruttoinlandsprodukts mittels Vektorautoregressiver (VAR) Modelle, Brückengleichungen und verschiedener Faktormodelle direkt auf Basis einer Vielzahl an monatlichen Indikatoren.<sup>2</sup>

In jüngster Vergangenheit setzen sich jedoch zunehmend sogenannte Bottom-up-Modellierungen durch. Hierbei wird das Bruttoinlandsprodukt zunächst mehr oder weniger kleinteilig in seine Bestandteile zerlegt und diese Subkomponenten einzeln vorhergesagt. Anschließend wird aus den Prognosen der einzelnen Komponenten eine Vorhersage für das gesamte Bruttoinlandsprodukt aggregiert. Eine ausführliche Analyse und einen Vergleich der Prognosegüte von Top-down und Bottom-up-Modellen kann in Drechsel und Scheufele (2012) eingesehen werden.

### **3. Herausforderungen**

Das immer stärker wachsende Angebot an potenziell relevanten Daten und Indikatoren stellt die aktuelle Forschung vor neue Herausforderungen. Das Ziel, möglichst viele potenziell relevante Informationen zu verarbeiten, muss gegen Probleme herkömmlicher Modelle bei der Verarbeitung zu großer Datenmengen abgewogen werden. Bei der Aufnahme vieler erklärender Variablen steigt die Anzahl der zu schätzenden Parameter bei herkömmlichen Modellen stark an, was zu Overfitting, verzerrten Signifikanztests und instabilen Schätzungen führt. Um dem Anspruch, möglichst viele Informationen zu verarbeiten, trotzdem gerecht zu werden, wird in der aktuellen Literatur auf unterschiedliche Vorgehensweisen zurückgegriffen.

Zum einen können eine Vielzahl sparsam spezifizierter Modelle mit jeweils wenigen erklärenden Variablen einzeln und stabil geschätzt werden. Beispielsweise könnte für

---

<sup>1</sup> Vgl. Ingenito und Trehan, 1996.

<sup>2</sup> Vgl. Rünstler, Barhoumi, Benk, Cristadoro, Den Reijer, Jakaitiene, Jelonek, Rua, Ruth und Van Nieuwenhuyze, 2009.

jeden Indikator und dessen Lags jeweils eine eigene Regression angestellt werden. Anschließend werden diese Einzelprognosen zu einer gemeinsamen Vorhersage verdichtet. Alternativ zu diesem als *Pooling of Forecasts* bezeichneten Ansatz kann mittels sogenanntem *Pooling of Information* auf Modelle zurückgegriffen werden, die in der Lage sind, mit einer großen Datenbasis zu arbeiten. Zu letztgenannten Modellen gehören beispielsweise Faktormodelle oder Bayesianische VAR Modelle. Ein praxisnaher Ansatz stellt alternativ oftmals eine Modellspezifikation dar, die durch eine restriktive Variablenauswahl die Zahl der genutzten Indikatoren bereits im Vorfeld einschränkt und somit in die endgültige Regression nur einige wenige Variablen aufnimmt. Diese Variablenselektion erfolgt je nach Modell nach unterschiedlichen Selektionskriterien. Neben einer rein subjektiven Auswahl der Indikatoren wird meist auf objektive, statistische Kennzahlen und Modellwahlkriterien wie die Kreuzkorrelation oder das Akaike Informationskriterium (AIC) beziehungsweise das Bayessche Informationskriterium (BIC) zurückgegriffen. Weiterführende, mehrstufige Regressionsdurchläufe wie das Boosting-Verfahren bieten zusätzlich interessante Möglichkeiten der Variablenselektion.<sup>3</sup>

Eine weitere Herausforderung an die kurzfristige Konjunkturprognose stellen unterschiedliche Publikationsfrequenzen der verschiedenen Variablen dar. Während das Bruttoinlandsprodukt ausschließlich in Quartalswerten zur Verfügung steht, werden die meisten potenziellen Indikatoren auf Monatsbasis publiziert. Der Vorteil ist hier der frühere Informationsgewinn im Vergleich zu Quartalswerten. Indikatoren können grundsätzlich nur zur kurzfristigen Konjunkturprognose verwendet werden, wenn sie einen bestimmten Vorlauf aufweisen oder früher zur Verfügung stehen als die interessierenden BIP-Werte selbst. Dementsprechend werden vorwiegend monatliche Indikatoren zur Prognose verwendet, da diese innerhalb des Quartals zumindest für einen bestimmten Zeitraum zur Verfügung stehen und somit zusätzliche Informationen bezüglich der aktuellen Entwicklung bereitstellen können. Eine Modellklasse, die sowohl diese Frequenzproblematik löst, als auch ökonomisch interpretierbare Zusammenhänge zwischen den einzelnen Bruttoinlandsprodukts-Komponenten und Indikatoren durch lineare Regressionen modelliert, sind

---

<sup>3</sup> Für eine Beschreibung des Boosting-Verfahrens siehe Carstensen, Henzel, Mayr und Wohlrabe, 2009.

sogenannte Brückengleichungen. Diese überbrücken Frequenzunterschiede in den genutzten Variablen durch eine Aggregation der hochfrequenten Variablen auf die niedrigere Frequenz und anschließender Regression auf Basis dieser niedrigen Frequenz.

Eine ausführliche Implementierung derartiger Modelle in den USA stellt das GDPNow der Federal Reserve Bank of Atlanta dar, in dem das Bruttoinlandsprodukt auf Verwendungsseite zerlegt und anschließend die Subkomponenten unter anderem per Brückengleichungen auf Basis monatlicher Indikatoren vorhergesagt werden.<sup>4</sup> Eine entsprechende Anwendung von Brückengleichungen für Europa stellt das von Barhoumi et al. (2011) für die französische Wirtschaft erstellte Modell dar.<sup>5</sup> Für Deutschland wendet das ifo Institut in seinem IFOCAST eine entsprechende Modellierung im Pooling of Forecasts Ansatz an.<sup>6</sup>

#### **4. Modellbeschreibung**

Ziel der Arbeit ist es, die Entwicklung des deutschen BIP im aktuellen Quartal durch ein Nowcasting-Modell abschätzen zu können. Das Bruttoinlandsprodukt soll also bereits innerhalb des zu prognostizierenden Quartals (oder kurz nach Ablauf des Quartals), in jedem Fall vor der offiziellen Veröffentlichung, vorhergesagt werden. Besonders in derartigen Nowcasting-Ansätzen spielen die schnelle Verfügbarkeit von Daten und der damit einhergehende Informationsvorteil im Vergleich zu Modellen niedrigerer Frequenzen eine besonders wichtige Rolle. Aus diesem Grund greift das in dieser Arbeit verwendete Modell auf monatliche Indikatordaten zur Prognose der niederfrequenten Quartalswerte des BIP zurück.

---

<sup>4</sup> Vgl. Higgins, 2014.

<sup>5</sup> Vgl. Barhoumi, Darne, Ferrara und Pluyaud, 2011.

<sup>6</sup> Vgl. Carstensen et al., 2009.

## 4.1 Datensatz

Die untersuchten Daten erstrecken sich über den Zeitraum von Januar 1995 bis Dezember 2015. Als Quelle für die Daten des Bruttoinlandsprodukts, der Komponenten und der Subkomponenten dient das Statistische Bundesamt. Für die Daten der Indikatoren wurden mehrere Quellen verwendet (z.B. Eurostat, Deutsche Bundesbank).<sup>7</sup> Der Datensatz wird jeweils in Daten auf Quartals- und Monatsbasis untergliedert. Dies ergibt 84 Beobachtungen der Produktionsdaten und Indikatoren auf Quartalsebene und 252 Beobachtungen auf Monatsebene für die Indikatoren sowie Importe und Exporte. Um Stationaritätsprobleme von vornherein zu minimieren, werden lediglich die Quartalswachstumsraten der Variablen untersucht. Die Daten sind grundsätzlich saisonbereinigt und deflationiert. Nach Möglichkeit werden Variablen mit schlechter Stationaritätseigenschaft grundsätzlich nicht in das Modell aufgenommen oder entsprechend zunächst stationarisiert (z.B. trendbereinigt).<sup>8</sup>

Bei den Indikatoren wird sowohl auf quantitative (z.B. Einzelhandelsumsätze), als auch qualitative Daten (z.B. Verbraucherpreisindex) zurückgegriffen. Es sei außerdem darauf hingewiesen, dass für das gesamte Modell ausschließlich Daten zum Stand 2016 verwendet werden. Hierbei handelt es sich meist um mehrfach revidierte Daten und eben nicht um die jeweiligen Erstveröffentlichungen. Inwiefern dies ein Problem darstellen kann, wird in Kapitel 6 diskutiert. Eine Aktualisierung der Daten erfolgt automatisch, sobald neue Daten zur Verfügung stehen.

Aus Gründen der Übersichtlichkeit soll zukünftig die Quartalswachstumsrate eines Indikators  $z$  im Quartal  $t$  vereinfachend als  $x_t$  bezeichnet werden. Es gilt somit:

$$x_t^Q = \frac{z_t^Q - z_{t-1}^Q}{z_{t-1}^Q}. \text{ Entsprechend gilt } x_{t,m}^M = \frac{z_{t,m}^M - z_{t-1,m}^M}{z_{t-1,m}^M} \text{ für die Wachstumsrate des Indikators } z$$

im Monat  $m$  des Quartals  $t$  im Vergleich zum Wert im Vorquartal.

---

<sup>7</sup> Siehe Tabelle im Anhang.

<sup>8</sup> Die Variablen wurden per Augmented Dickey-Fuller-Test zum 10%-Signifikanzniveau auf einen stochastischen Trend hin überprüft und bei Vorliegen eines solchen nicht in das Modell aufgenommen oder bereinigt. Variablen mit deterministischem Trend wurden ebenfalls nicht aufgenommen oder trendbereinigt.

## 4.2 Bottom-up-Ansatz

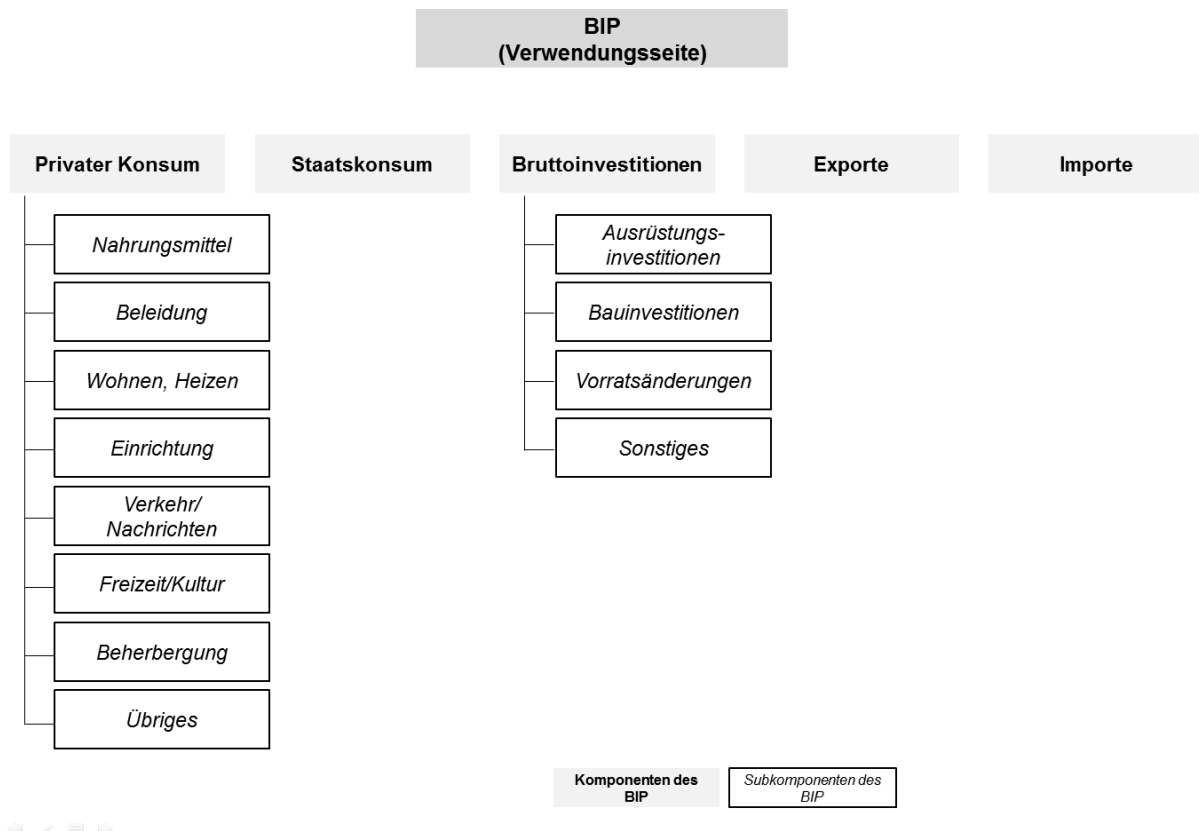
Für die Prognose werden die von Carstensen et al. (2009) oder Barhoumi et al. (2011) vorgeschlagenen Brückengleichungen mit einer Bottom-up-Modellierung für das deutsche Bruttoinlandsprodukt kombiniert.

Hierbei wird das deutsche BIP, nicht wie in vielen gängigen Modellen auf Entstehungsseite, sondern auf Verwendungsseite zerlegt. Als Ergebnis sollen Jahreswachstumsraten des deutschen BIP prognostiziert werden, zur Schätzung wird das Modell jedoch auf Quartalswachstumsraten aufgebaut. Dies hat vorrangig den Vorteil, dass somit beinahe sämtliche Variablen in stationärer Form vorliegen. Entsprechend wird zum Ende der Prognose die geschätzte Quartalswachstumsrate in eine Jahreswachstumsrate umgerechnet.<sup>9</sup>

Gemäß dem verwendeten Bottom-up-Ansatz wird das Bruttoinlandsprodukt zunächst in seine Komponenten zerlegt und diese Bestandteile prognostiziert, bevor daraus eine Vorhersage für das gesamte BIP angestellt wird. Abbildung 1 zeigt die entsprechende Zerlegung des Bruttoinlandsprodukts in dessen Komponenten und Subkomponenten. Die Aufteilung der Komponente „Konsum“ in die einzelnen Subkomponenten ist aufgrund des hohen Konsumanteils am deutschen Bruttoinlandsprodukt und zur Erleichterung der Suche nach geeigneten Indikatoren sinnvoll. Zudem wird die Komponente „Bruttoinvestitionen“ in die Subkomponenten „Ausrüstungsinvestitionen“, „Bauinvestitionen“ sowie „sonstige Investitionen“ und „Vorratsveränderungen“ aufgeteilt. Der Staatskonsum sowie Importe und Exporte werden nicht weiter unterteilt, sondern direkt prognostiziert. Insgesamt ergeben sich somit 15 in einem ersten Schritt zu prognostizierende Komponenten und Subkomponenten.

---

<sup>9</sup> Siehe hierzu Schritt 4.4.4.



**Abbildung 1 Zerlegung des BIP in Komponenten und Subkomponenten**

### 4.3 Auswahl monatlicher Indikatoren

In einem nächsten Schritt werden geeignete Indikatoren zur Prognose der in Kapitel 4.2 gezeigten Subkomponenten gesucht. Um das Problem der Überanpassung (Overfitting) und der Multikollinearität zu umgehen, werden mehrere Selektionsschritte zu einer restriktiven Variablenwahl kombiniert.

1. Schritt: Subjektive Auswahl passender Indikatoren je Subkomponente
2. Schritt: Objektive Analyse per Kreuzkorrelation
3. Schritt: Objektive Selektion per AIC

Im ersten Schritt wird eine große Auswahl von monatlichen Indikatoren, denen eine gewisse Erklärungskraft in Bezug auf die Entwicklung der zu prognostizierenden Subkomponente zugesprochen werden kann, für jede Subkomponente einzeln

selektiert. Anschließend werden die ausgewählten Subkomponente-Indikator-Kombinationen auf ihre jeweilige Kreuzkorrelation hin überprüft.

Hier wird der Vorteil eines Bottom-up-Ansatzes deutlich. So korreliert beispielsweise der Indikator „Produktionsindex Baugewerbe“ sehr stark mit der Subkomponente „Bauinvestitionen“. Allerdings ist die Korrelation zum Bruttoinlandsprodukt als Ganzes schwach. Bei einem Top-Down Ansatz würde der Indikator vernachlässigt werden, obwohl er signifikant zur Erklärungskraft des Modells beiträgt. Aufgrund des Bottom-up-Ansatzes kann der Indikator berücksichtigt werden und zur Prognosegüte des Modells beitragen.

Im dritten Selektionsschritt werden für jede Subkomponente per Stepwise-Selection die Kombinationsmöglichkeiten aus Indikatoren und Vergangenheitswerten der Indikatoren und Subkomponenten hinsichtlich des Akaike Informationskriteriums (AIC) geprüft. Das AIC lässt sich folgendermaßen berechnen:

$$( 1 ) \quad AIC = 2k - 2\ln(L)$$

wobei  $k$  für die Anzahl der Parameter und  $L$  für den Wert der Likelihood Funktion an der Stelle der geschätzten Parameter steht. Das AIC dient als Gütemaß und wird häufig bei der Wahl der Modellspezifikation verwendet. Umso kleiner der Wert des AIC, desto besser ist die Anpassungsgüte des Modells. Damit das Modell nicht übermäßig komplex gestaltet wird, wird jeder zusätzliche Parameter strafend berücksichtigt. Entsprechend wird je Subkomponente nur die Kombination mit dem niedrigsten AIC in die endgültige Regression aufgenommen.

Als Ergebnis dieses Schrittes ergibt sich die abgeschlossene Modellwahl aus Indikatoren und Lags für die Regression der Subkomponenten im nächsten Schritt.

#### **4.4 Brückengleichungen**

Grundelement des Modells zur Prognose des aktuellen deutschen Bruttoinlandsprodukts sind die verwendeten Brückengleichungen, die eine Brücke

zwischen den quartalsweise publizierten Daten (beispielsweise BIP-Subkomponenten) und monatlichen Indikatoren schlagen. Brückengleichungen werden in der aktuellen Literatur oftmals für kurzfristige Konjunkturprognosen eingesetzt und basieren im Allgemeinen auf drei Schritten:

Schritt 1: Fortschreibung monatlicher Indikatoren

Schritt 2: Aggregation der Monatsindikatoren auf Quartalsebene

Schritt 3: Schätzung der interessierenden Variablen auf Basis der Indikatoren

Auch im Nowcasting stehen je nach Prognosezeitpunkt innerhalb des zu prognostizierenden Quartals, aber auch in den ersten Monaten des Folgequartals, noch nicht alle benötigten Beobachtungen der Monatsindikatoren zur Verfügung. Dementsprechend müssen diese zunächst für die benötigten Zeiträume fortgeschrieben werden. Vereinfachend kann von dem Prognosebedarf in Tabelle 1 ausgegangen werden.

<b>Bezeichnung</b>	<b>Monat des zu prognostizierenden Quartals</b>	<b>Fortzuschreibende Monate</b>
P1	2.-3. Monat des Quartals	2
P2	3. Monat des Quartals bis 1. Monat des darauffolgenden Quartals	1

**Tabelle 1 Prognosezeitpunkte**

#### **4.4.1 Fortschreibung der monatlichen Indikatoren**

In einem ersten Schritt werden zunächst die monatlichen Indikatoren für den benötigten Zeitraum fortgeschrieben. Dies kann mittels unterschiedlicher Methoden durchgeführt werden. Eine denkbar einfache Methodik ist die „naive“ Fortschreibung des letztbekannten Wertes.<sup>10</sup> Aufgrund einer überlegenen Prognoseleistung<sup>11</sup> wird

<sup>10</sup> Vgl. Carstensen et al., 2009

<sup>11</sup> Siehe beispielsweise Barhoumi et al., 2011.



jedoch auf die Modellierung der Zeitreihe als einen univariaten, autoregressiven Prozess zurückgegriffen. Bei einem Autoregressiven (AR) Modell handelt es sich um ein Prognosemodell, welches die interessierende Zeitreihe auf Basis ihrer Vergangenheitswerte fortschreibt. Grundlage ist die Annahme, dass sich eine stationäre Variable als AR-Prozess k-ter Ordnung darstellen lässt. Gleichung (2) beschreibt ein entsprechendes AR(k)-Modell.

$$(2) \quad x_t = \alpha + \sum_{i=1}^k \delta_i x_{t-i} + \varepsilon_t$$

Wobei  $k$  für die Anzahl der vorhergehenden Werte des Indikators und  $\varepsilon$  für den Störterm steht. Gleichung (2) kann mittels OLS geschätzt werden. Da AR-Modelle die Variable zum Zeitpunkt  $t$  mit ihren Ausprägungen bis  $t-1$  erklären, können grundsätzlich ausschließlich 1-Perioden-Vorhersagen angestellt werden. Für Prognosehorizonte über eine Periode hinaus kann dieser Schritt entsprechend iterativ wiederholt werden.

Aufgrund der robusten Ergebnisse wurden mittels eines AR(4) Prozesses fehlende Monatswerte der ausgewählten Indikatoren fortgeschrieben. Es ergeben sich also für alle relevanten Zeitpunkte die monatlichen Werte der Wachstumsraten der verwendeten Indikatoren.

#### **4.4.2 Aggregation auf Quartalsebene**

Da sämtliche Indikatoren bisher auf Monatsebene zur Verfügung stehen, jedoch in Quartalswerten in die anschließende Schätzung eingehen sollen, müssen die monatlichen nun zu Quartals-Werten aggregiert werden. Sämtliche Indikatoren gehen direkt per Wachstumsrate in das Modell ein, somit ist eine Summierung der prognostizierten Monatsdaten zu einem entsprechenden Quartalswert wie bei Absolutwerten nicht möglich. Für Quartale, in denen alle Monatsausprägungen zur Verfügung stehen, wird die Quartalswachstumsrate auf Basis der vorhandenen Werte berechnet. Für Quartale, in denen Monatsausprägungen geschätzt werden müssen,

erfolgt die Berechnung durch Bildung des Mittelwertes der teilweise geschätzten Wachstumsraten der Monatswerte unter Zuhilfenahme der Schätzungen.<sup>12</sup>

Als Ergebnis dieses Schrittes sind Quartalswachstumsraten der Indikatoren auf Quartalsebene und somit gleichfrequentierte Daten bezüglich der quartalsmäßigen Produktionswerte verfügbar.

#### 4.4.3 Regression der Subkomponenten

Bei der Prognose der Subkomponenten und Komponenten des Bruttoinlandprodukts werden neben den ausgewählten Indikatoren außerdem die Vergangenheitswerte der erklärten Variable selbst mit in die Regression aufgenommen, um deren zusätzliche Erklärungskraft auszunutzen. Dies stellt einen großen Vorteil der disaggregierten Vorgehensweise von Bottom-up-Modellen dar. Die hierbei verwendete Regressionsgleichung (3) wird entsprechend als Autoregressive Distributed Lag (ARDL) Modell bezeichnet.

$$(3) \quad y_t^Q = \beta_0 + \sum_{m=1}^p \beta_m y_{t-m}^Q + \sum_{j=1}^k \sum_{i=0}^q \gamma_{j,i} x_{j,t-i}^Q$$

Wobei  $y_t^Q$  der Quartalswachstumsrate der interessierenden Subkomponente entspricht. Die Wachstumsrate der Subkomponente wird auf ihre  $p$  Vergangenheitswerte sowie jeweils  $q$  Lags der verwendeten  $k$  Indikatoren regressiert. In die endgültige Regression gehen ausschließlich die per AIC als optimal ausgewählten Kombinationen aus Indikatoren und Lags ein. Um die zu schätzenden Parameter annehmbar gering zu halten, wird die maximale Anzahl an pro Gleichung verwendeten Indikatoren auf 4 und die maximale Anzahl Lags pro Variable auf 5 beschränkt ( $k \in [1,4], p \in [1,5] \& q \in [0,5]$ ).<sup>13</sup> Mittels der geschätzten Koeffizienten und der unter Schritt 4.4.1 für den entsprechenden Zeitraum fortgeschriebenen

<sup>12</sup> Für vorhandene Monate ergibt sich die Berechnungsformel:  $x_t^Q = \ln\left(\frac{x_{t,1}^M + x_{t,2}^M + x_{t,3}^M}{x_{t-1,1}^M + x_{t-1,2}^M + x_{t-1,3}^M}\right)$  mit  $x_{t,1}^M$  als dem Absolutwert von Indikator  $x$  in Monat 1 des Quartals  $t$ . Für zu prognostizierende Zeiträume ergibt sich:  $\hat{x}_t^Q = \frac{\Delta \ln(x_{t,1}^M) + \Delta \ln(x_{t,2}^M) + \Delta \ln(x_{t,3}^M)}{3}$

<sup>13</sup> Die Modellselektion erfolgt mittels Stepwise-Selection (Backwards und Forwards) auf Basis des AIC als Modellwahlkriterium.

Indikatorwerte können anschließend Prognosen für die Subkomponenten angestellt werden. Mit dieser Methodik werden Prognosen für die Subkomponenten der Komponenten „Privater Konsum“ und „Bruttoinvestitionen“ angestellt. Da eine indikatorgestützte Vorhersage keine entscheidende Verbesserung der Prognosegüte erzielen konnte, werden die Komponenten „Exporte“ und „Importe“ direkt per AR(4) Modell auf Monatsbasis fortgeschrieben und anschließend auf Quartalsebene aggregiert. Der Staatskonsum wird auf Quartalsebene per AR(4) Modell fortgeschrieben.

Als Prognose für das Quartalswachstum des Privaten Konsum für Nahrungsmittel ergibt sich beispielsweise:<sup>14</sup>

$$\begin{aligned}
 (4) \quad \widehat{KonsNahrung}_t^Q &= -0,00213 - 0,50900 \widehat{KonsNahrung}_{t-1}^Q + \\
 &0,75131 \widehat{Einzelh. UmsatzNahrung}_t^Q - \\
 &0,51447 \widehat{Einzelh. UmsatzSonstige}_t^Q + \\
 &0,13551 \widehat{Einzelh. UmsatzSonstige}_{t-1}^Q
 \end{aligned}$$

Die Subkomponenten „Konsum für Sonstiges“ sowie „Vorratsveränderungen“ (Teil der Investitionen) werden aufgrund fehlender Indikatoren nicht entsprechend Kapitel 4.4.3 regressiert und prognostiziert. Eine alternative Fortschreibung dieser Subkomponenten per AR-Modell und anschließende Aufnahme in die Regression der Komponenten führt überdies zu keiner Steigerung der Prognosegüte, weshalb auf eine Aufnahme der Komponenten an dieser Stelle verzichtet wird. Die Subkomponente „Konsum für Freizeit und Kultur“ wird aufgrund schlechter Stationaritätseigenschaften<sup>15</sup> nicht in die Regression aufgenommen und entsprechend auch nicht im vorangegangenen Schritt modelliert. Da diese Variable bei einer Regression des „Privaten Konsums“ auf seine Bestandteile ohnehin eine nur insignifikante Erklärungskraft aufweist, beeinträchtigt dies die Resultate nicht ausschlaggebend.

---

<sup>14</sup> Regression zum Zeitpunkt 2016Q1 mit Daten von Januar 1995 bis Dezember 2015.

<sup>15</sup> Siehe Kapitel 4.1 bezüglich des Umgangs mit nicht stationären Variablen.

#### 4.4.4 Aggregation des Bruttoinlandsprodukts

Stehen die Schätzungen der Subkomponenten bereit, müssen diese in einem letzten Schritt zu einer Prognose für das gesamte Bruttoinlandsprodukt aggregiert werden.

Da sämtliche Variablen in dem Modell in Form von Wachstumsraten aufgenommen wurden, ist eine schlichte Summierung der Subkomponenten hier nicht möglich. Außerdem werden die Subkomponenten „Vorratsveränderungen“, „Konsum für Kultur“ und „Sonstiger Konsum“ nicht einzeln spezifiziert und geschätzt. Dies hätte zur Folge, dass sich die einzelnen Subkomponenten nicht zur gesamten Komponente summieren. Dementsprechend wird für die Aggregation der Komponenten anstelle einer schlichten Summierung eine einfache OLS-Regression der Gleichung (5) genutzt, in der die Quartalswachstumsraten der Komponenten auf die Wachstumsraten ihrer M Subkomponenten regressiert werden.

$$(5) \text{Komp}_t^b = \beta_0 + \sum_{m=1}^M \beta_m^b \text{Sub}_t^{m,b} + \epsilon_t^{16}$$

$\text{Komp}_t^b$  entspricht der Komponente b zum Zeitpunkt t (z.B. Wachstumsrate privater Konsum),  $\text{Sub}_t^{m,b}$  ist die m-te Subkomponente der Komponente b zum Zeitpunkt t (z.B. Wachstumsrate „Privater Konsum für Nahrungsmittel“ als Teil des „Privaten Konsums“) und  $\epsilon_t$  ein Störterm. Mithilfe der geschätzten Koeffizienten und vorhergesagten Subkomponenten können nun Prognosen für die Komponenten des Bruttoinlandsprodukts angestellt werden. Gleichung 6 zeigt die Regression der Wachstumsrate des „Privaten Konsums“ für das letzte analysierte Quartal 2015Q4 mit Daten des gesamten Betrachtungszeitraums.

$$(6) \quad \widehat{\text{PrivKonsum}}_t^Q = 0,00170 + 0,02690 \widehat{\text{KonsNahrung}}_t^Q + \\ 0,07017 \widehat{\text{KonsKleidung}}_t^Q + 0,16630 \widehat{\text{KonsWohnen}}_t^Q + \\ 0,01758 \widehat{\text{KonsEinrichtung}}_t^Q + 0,15792 \widehat{\text{KonsTransport}}_t^Q + \\ 0,01618 \widehat{\text{KonsHotel}}_t^Q$$

---

<sup>16</sup> An dieser Stelle wird aus Gründen der Übersichtlichkeit auf die Kennzeichnung der Variablen als Quartalswerte verzichtet. Sämtliche Variablen stellen jedoch Quartalswerte da.

Anschließend werden die Komponenten wiederum mittels OLS-Regression (7) zum gesamten Bruttoinlandsprodukt aggregiert. Hierbei wird das Wachstum des Bruttoinlandsprodukts auf seine fünf Komponenten regressiert.

$$(7) \quad BIP_t^Q = \beta_1 PrivKonsum_t^Q + \beta_2 Staatskonsum_t^Q + \beta_3 Bruttoinvest_t^Q + \beta_4 Exporte_t^Q + \beta_5 Importe_t^Q + \epsilon_t$$

Gleichung (8) zeigt die mittels der hierbei geschätzten Koeffizienten angestellte Prognosegleichung für das Wachstum des Bruttoinlandsprodukts in 2015Q4.

$$(8) \quad \widehat{BIP}_t^Q = 0,20519 PrivKonsum_t^Q + 0,09138 Staatskonsum_t^Q + 0,20145 Bruttoinvest_t^Q + 0,21623 Exporte_t^Q - 0,07324 Importe_t^Q$$

Die geschätzten Koeffizienten entsprechen hierbei rein der per OLS Regression geschätzten Faktoren für die beste Modellanpassung und können keinesfalls als Spending Shares der einzelnen Komponenten interpretiert werden.

Da in dem gesamten bisherigen Modell mit Quartalswachstumsraten der Variablen gearbeitet wurde, abschließend jedoch Jahreswachstumsraten vorhergesagt und analysiert werden sollen, müssen die in Schritt 7 angestellten Prognosen der Quartalswachstumsraten noch auf Jahreswachstumsraten umgerechnet werden. Gleichung (9) zeigt die verwendete Formel für die Überführung der Quartals- auf Jahreswachstumsraten mithilfe des absoluten BIP (BIP in € statt Wachstumsraten).  $BIP_t^y$  entspricht den daraus berechneten Jahreswachstumsraten.

$$(9) \quad \widehat{BIP}_t^y = \ln\left(\frac{\text{absolutBIP}_{t-1}^Q * (1 + \widehat{BIP}_t^Q)}{\text{absolutBIP}_{t-4}^Q}\right)$$

Aus diesem Schritt ergibt sich nun schlussendlich die interessierende Prognose der Jahreswachstumsrate des deutschen BIP im aktuellen Quartal.

## **5. Empirische Analyse**

### **5.1 Pseudo Out of Sample**

Im folgenden Kapitel soll ein Blick auf die Möglichkeiten und die Prognosegenauigkeit des Modells geworfen werden. Für diese Analyse der Vorhersageleistung wird eine Pseudo out of Sample-Modellierung konstruiert.

Diese Vorgehensweise hat im Vergleich zu einer reinen in Sample-Analyse den Vorteil, auch Aussagen über die Vorhersageleistung außerhalb des regressierten Datensatzes treffen zu können. Zusätzlich ergibt sich ganz offensichtlich ein zeitlicher Vorteil gegenüber einer entsprechend zu ähnlichen Ergebnissen führenden „wahren“ out of Sample-Analyse.

Für die Pseudo out of Sample-Regression wird der Zeitraum ab dem ersten Quartal 2008 bis zum vierten Quartal 2015 und somit auch die für kurzfristige Konjunkturprognosen besonders interessante weil schwer vorherzusagende Zeitperiode der Finanzkrise betrachtet. Für die Analyse werden die Pseudo out of Sample-Ergebnisse nach Prognosezeitpunkt betrachtet. Es ergibt sich somit eine pseudo out of Sample-Analyse für den Prognosezeitpunkt P1 mit 2 fortzuschreibenden Monaten und P2 mit einem zu prognostizierende Monatswert der Indikatoren. Es ergeben sich außerdem jeweils 32 Prognosen. Die grundsätzlichen Modellspezifikationen wie Variablenselektion bleiben über den gesamten Betrachtungszeitraum unverändert, während sämtliche Regressionen für jeden Pseudo out of Sample-Zeitpunkt durchgeführt werden.

Der Root Mean Squared Error (RMSE) der Schätzung dient als Gütemaß des Prognosemodells und wird folgendermaßen definiert:


$$( 10 ) \text{ RMSE} = 100 * \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}}$$

Wobei  $n$  die Anzahl der untersuchten Quartale,  $y$  den tatsächlich realisierten Wert des BIP-Jahreswachstums und  $\hat{y}$  den geschätzten Wert zum Quartal  $t$  darstellt.

Für die Einschätzung der Prognosegüte hat sich in der Literatur der Vergleich des RMSE eines Modells im Vergleich zu dem Wert eines einheitlichen Benchmark-Modells durchgesetzt. Bei der folgenden Analyse wird hierzu auf ein AR(4) Modell als Benchmark zurückgegriffen.

## 5.2 Ergebnisse

Abbildung 2 zeigt die Ergebnisse der Pseudo Out of Sample-Prognosen des Modells für die Vorhersagezeitpunkte 2008Q1 bis 2015Q4 sowie die wahre Realisation der Jahreswachstumsrate des deutschen Bruttoinlandsprodukts. Hierbei handelt es sich um Prognosen zum Zeitpunkt P2, also eine Prognose mit Fortschreibung eines Monats und entsprechend kurzem Vorlauf vor der offiziellen Bekanntgabe durch das Statistische Bundesamt. Wie gut zu erkennen ist, gibt die Prognose sowohl auf die absolute Wachstumsrate, als auch ihre tendenzielle Entwicklung im Vergleich zur vorangegangenen Ausprägung gute Hinweise. Außerdem gelingt es, selbst die besonders schwer vorherzusagenden starken Einbrüche der Wirtschaft in Folge der Finanzkrise ab 2008 bereits im Vorfeld recht präzise anzukündigen.



**Abbildung 2 Nowcasting-Prognosen Deutschland (1 Monat)**

Neben dieser graphischen Analyse der Prognoseleistung des Modells zeigt Tabelle 2 die RMSE sowie die relativen RSME im Vergleich zu einer AR(4) Benchmark nach den zwei analysierten Prognosezeitpunkten P1 bis P2. Hierbei wird deutlich, dass das analysierte Modell im Vergleich zu einem einfachen AR-Modell den Vorhersagefehler erheblich reduzieren und deutlich präzisere Vorhersagen der Jahreswachstumsraten anstellen kann. Mit einem relativen RMSE von 0,517 in P2 können die letztangestellten Prognosen den Vorhersagefehler im Vergleich zur Benchmark um beinahe 50% reduzieren.

Kaum überraschend, verbessert sich die Prognoseleistung des Modells mit voranschreitendem Zeitpunkt und damit zusätzlich verfügbaren Daten von 0,695 in P1 auf 0,602 in P2. Auch der relative RMSE sinkt entsprechend im Vergleich zu der vom Zeitpunkt innerhalb des Quartals unabhängigen AR-Benchmark von 0,597 auf 0,517.



<b>Vorhersagefehler nach Prognosezeitpunkten</b>		
	<b>RMSE</b>	<b>RelativerRMSE*</b>
AR(4)	1,163	1
<b>Prognosezeitpunkt</b>		
P1	0,695	0,597
P2	0,602	0.517
* Im Vergleich zur AR(4)-Benchmark ebenfalls indirekt über Quartalswerte auf Ebene von Jahreswachstumsraten. Zeitraum 2008Q1-2015Q4.		

**Tabelle 2 Pseudo out of Sample-Ergebnisse**

Neben möglichst präzisen Prognosen über die Wachstumsrate des BIP sollte bei der Analyse der Prognosegüte eines kurzfristigen Konjunkturmodells die Frage beantwortet werden, ob das Modell grundsätzlich in der Lage ist, die Richtung und Dynamik der Wirtschaftsentwicklung korrekt abzuschätzen. Tabelle 3 zeigt die Ergebnisse einer solchen Betrachtung im Vergleich der Realisationen und Prognosen. Ob im aktuellen Quartal mit einer Zu- oder einer Abnahme der Wirtschaftsleistung zu rechnen ist, konnte, begünstigt durch im betrachteten Zeitraum selten wechselnden Vorzeichen, in 97% der betrachteten Fälle korrekt prognostiziert werden. Wird gefragt, ob sich die bisherige Entwicklung im aktuellen Quartal beschleunigt oder verlangsamt, sinkt die Prognosegüte zwar, jedoch wird mit einer Trefferquote von knapp 91% in den meisten Fällen im Vorfeld korrekt auf eine sich beschleunigende oder abflauende Konjunktorentwicklung hingewiesen (Pfeil nach oben entspricht positivem Wachstum bzw. beschleunigtem Wachstum, Pfeil nach unten entspricht Abschwung bzw. verlangsamtem Wachstum – rote Pfeile zeigen eine falsche Prognoseleistung an). Auffällig ist außerdem, dass auch während der Rezession in Folge der Finanzkrise in beinahe allen Fällen richtig abgeschätzt werden konnte, ob die Wirtschaftsleistung fällt oder steigt und ob sich diese Entwicklung beschleunigt oder verlangsamt.

	Realisierte Vorzeichen	Prognosevorzeichen	Realisierte Dynamik	Dynamik Prognose
2008 Q1	↑	↑	↑	↑
2008 Q2	↑	↑	↓	↓
2008 Q3	↑	↓	↓	↓
2008 Q4	↓	↓	↓	↓
2009 Q1	↓	↓	↓	↓
2009 Q2	↓	↓	↑	↑
2009 Q3	↓	↓	↑	↑
2009 Q4	↓	↓	↑	↑
2010 Q1	↑	↑	↑	↑
2010 Q2	↑	↑	↑	↑
2010 Q3	↑	↑	↑	↑
2010 Q4	↑	↑	↓	↑
2011 Q1	↑	↑	↑	↑
2011 Q2	↑	↑	↓	↓
2011 Q3	↑	↑	↓	↓
2011 Q4	↑	↑	↓	↓
2012 Q1	↑	↑	↓	↓
2012 Q2	↑	↑	↓	↓
2012 Q3	↑	↑	↓	↑
2012 Q4	↑	↑	↓	↓
2013 Q1	↓	↓	↓	↓
2013 Q2	↑	↑	↑	↑
2013 Q3	↑	↑	↑	↓
2013 Q4	↑	↑	↑	↑
2014 Q1	↑	↑	↑	↑
2014 Q2	↑	↑	↓	↓
2014 Q3	↑	↑	↓	↓
2014 Q4	↑	↑	↑	↑
2015 Q1	↑	↑	↓	↓
2015 Q2	↑	↑	↑	↑
2015 Q3	↑	↑	↓	↓
2015 Q4	↑	↑	↓	↓
<b>Anteil korrekter Prognosen</b>	<b>97%</b>		<b>91%</b>	

Tabelle 3 Trefferquote Tendenz

## 6. Problematik und Ausblick

Grundsätzlich sind kurzfristige Konjunkturprognosen und Nowcasting-Modelle mit unterschiedlichen Problemen konfrontiert. Zum einen sei auf die Fehlervarianz der Prognosemodelle verwiesen. So weist das vorgestellte Modell einen RMSE zwischen 0,6 und 0,7 auf. Die Jahreswachstumsraten des BIP betragen für den betrachteten Zeitraum -7,2% bis +5,4% und im Mittel 1,3% (der betragsmäßiger Durchschnitt der Wachstumsraten entspricht 2%). Das vorgestellte Modell weist außerdem einen Mean Absolut Error von 0,4 Prozentpunkten auf.<sup>17</sup> Das bedeutet, dass bei einer realisierten Wachstumsrate von beispielsweise 2% die Prognose durchschnittlich 0,4 Prozentpunkte danebengelegt und Werte von 1,6% oder 2,4% vorausgesagt hätte. Selbst wenn dies einer verhältnismäßig guten Prognoseleistung entspricht, können derartige Prognosen nicht als präzise Vorhersagen, sondern vornehmlich als möglichst genaue Hinweise auf die Tendenz der aktuellen Entwicklung angesehen werden.

Sollen derartige Modelle für das Ausnutzen von Reaktionen auf den Kapitalmärkten genutzt werden, stellt eine solche Abweichung ein großes Erschwernis dar, da aufgrund der Ungenauigkeit des Modells kaum vorzeitige Positionierungen eingegangen werden können. Daher ist es für den Kapitalmarkt von ausschlaggebender Bedeutung, diese Prognosemodelle zu präzisieren.

Ein weiterer, nicht unerheblicher Nachteil des hier beschriebenen Modells liegt in der Verwendung bereits revidierter Daten. Obgleich sich mit zunehmender Revision die realisierten Wachstumsraten möglicherweise den Schätzwerten annähern, ist ein auf revidierten Daten beruhendes Schätzmodell für Akteure am Kapitalmarkt weitestgehend irrelevant. Dies liegt in der Tatsache begründet, dass der Kapitalmarkt zunächst auf die revisionsanfällige Erstveröffentlichung reagiert, die durch das Modell, in das teilweise mehrfach revidierte Daten eingehen, schwer abgeschätzt werden kann.

---

<sup>17</sup> Der Mean Absolut Error ermöglicht die Interpretation des Wertes als mittlere Abweichung von der Realisation in Prozentpunkten und kann folgendermaßen berechnet werden:  $mae = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n}$ .

Die Verwendung von Realtime Daten wäre eine Möglichkeit, dem Ziel der Prognose von Erstveröffentlichungswerten nahe zu kommen. Allerdings gibt es in Deutschland noch wenige Indikatoren, für die eine ausreichende Datenbasis an Erstveröffentlichungen zur Verfügung stehen. Auch Baffigi, Golinelli und Parigi (2002) berichten über die schlechte Verfügbarkeit von Erstveröffentlichungen in Europa. Alternative Methoden diese Problematik zu umgehen, wäre ein interessanter Forschungsbereich für die Zukunft.

Zusätzliches Optimierungspotenzial ergibt sich bei der Handhabung von Variablen mit gemischten Frequenzen. Die in diesem Papier verwendeten Brückengleichungen stellen hier eine praktische und einfach zu implementierende Lösung dar. Allerdings weist dieses Vorgehen einen entscheidenden Nachteil auf. Durch die Aggregation der Monatswerte auf Quartalsebene gehen zusätzliche Informationen aus der höherfrequenten Entwicklung verloren. Veränderungen innerhalb eines Quartales können also nicht berücksichtigt werden, auch wenn diese unter Umständen wichtige Hinweise auf die aktuelle Entwicklung und eventuelle Trendwenden bereitstellen könnten.<sup>18</sup> Außerdem handelt es sich bei der Fortschreibung der monatlichen Indikatoren um einen Schätzprozess, der wiederum Schätzfehlern unterliegt. Aus diesem Grund sollte der Fokus auf Modelle gelegt werden, die gemischte Frequenzen verarbeiten können. Somit könnte zum einen der Informationsverlust durch die Aggregation verhindert werden und zum anderen monatliche Variablen mit ihrer aktuellen Ausprägung aufgenommen werden, ohne diese schätzfehlerbehaftet fortschreiben zu müssen.

Für Ansätze aus diesem Bereich sei auf MIDAS-Modelle und Mixed Frequency VAR-Modelle verwiesen.<sup>19</sup>

---

<sup>18</sup> Vgl. Carstensen et al., 2009

<sup>19</sup> Vgl. Wohlrabe, 2009

## 7. Fazit

Das Nowcasting der aktuellen wirtschaftlichen Entwicklung vor offizieller Veröffentlichung durch das Statistische Bundesamt, stellt eine der wichtigsten Aufgaben kurzfristiger Konjunkturprognosen dar. In dieser Arbeit wurde die Implementierung solch eines Nowcasting-Modells nach einem Bottom-up-Ansatz und einer Zerlegung des BIP auf Verwendungsseite vorgestellt und analysiert. Ziel des Modells sollte die kurzfristige Vorhersage der Jahreswachstumsraten des deutschen BIPs sein, um unter anderem eine Grundlage für Investitionsentscheidungen am Kapitalmarkt zu erhalten. Grundlage des Prognosemodells stellen die in der aktuellen Literatur weit verbreiteten Brückengleichungen dar, welche Frequenzunterschiede zwischen monatlichen Indikatoren und quartalsweise publizierte Produktionsdaten überbrücken. Mithilfe des vorgestellten Modells werden Prognosen der Quartalswachstumsraten des BIP für das jeweils aktuelle beziehungsweise gerade abgelaufene Quartal erstellt und anschließend auf die interessierenden Jahreswachstumsraten umgerechnet.

Hierfür wird das BIP zunächst auf Verwendungsseite in seine Komponenten und diese weiter in ihre Subkomponenten aufgeteilt, um in einem ersten Schritt diese Teilbereiche zu prognostizieren. Es werden entsprechend zunächst geeignete, monatliche Indikatoren für die einzelnen Subkomponenten des BIP ausgewählt, um für die Prognose innerhalb des Quartals einen Informationsvorteil gegenüber reinen Quartalswerten zu erhalten. Sämtliche Variablen gehen als Quartalswachstumsraten in das Modell ein. Für die fehlenden Monatsausprägungen werden die Indikatoren entsprechend per AR-Modell fortgeschrieben und anschließend auf Quartalsebene aggregiert. Nach einer restriktiven Variablenselektion mittels eines automatisierten Selektionsmechanismus per AIC werden die Subkomponenten des BIP mithilfe der Indikatoren mittels Brückengleichungen regressiert und für das aktuelle Quartal prognostiziert. Anschließend werden per OLS-Regression die vorhergesagten Werte zu einer Prognose für das gesamte BIP aggregiert und diese Vorhersage der Quartalswachstumsrate zur Jahreswachstumsrate umgerechnet.

Das verwendete Modell mit seiner Zerlegung auf Verwendungsseite und zunächst angewandten Schätzung von Quartalswachstumsraten, um diese auf Jahreswachstumsraten umzurechnen, grenzt sich damit von den allgemein in Deutschland verwendeten Modellen ab und liefert überzeugende Prognoseleistungen.

Sobald neue Daten der Indikatoren im laufenden Quartal veröffentlicht werden, kann das Modell problemlos und aufgrund der strikten Variablenwahl und technisch einfach zu berechnenden Methodik schnell aktualisiert und eine neue Prognose des Bruttoinlandsprodukts ermöglicht werden.

Eine Pseudo out of Sample-Analyse des Prognosetools für den Zeitraum 2008Q1 bis 2015Q4 mittels eines AR-Modells als Benchmark hat eine gute Prognoseleistung des Brückengleichungsmodells gezeigt, welches den Vorhersagefehler um bis zu 50% reduzieren konnte. Auch wenn während der allgemein als schwer vorherzusagend angesehenen Finanzkrise die Prognosefehler zunehmen, gelingen doch sehr genaue Hinweise auf den starken Rückgang des BIP 2008 und seine anschließende Erholung.

Des Weiteren konnte in 97% der analysierten Quartale die Richtung der konjunkturellen Entwicklung (Wachstum, Reduktion) sowie in 91% die Richtung der Wachstumsrate (Zunahme, Abnahme der Wachstumsrate) korrekt vorhergesagt werden.

Grundsätzlich gilt es bei derartigen Prognosemodellen stets die mittlere Fehlervarianz der Prognosen zu berücksichtigen und entsprechend die angestellten Vorhersagen nicht als exakte Punktlandungen, sondern vielmehr als gute Richtschnur für die tatsächliche Entwicklung zu interpretieren.

Außerdem stellen sich mit Themengebieten wie der Datenverfügbarkeit, Realtime-Analysen und Potenzialen neuer Modelle gemischter Frequenzen einige vielversprechende Aufgabenstellungen für die Forschung.

## 8. Literaturverzeichnis

- Baffigi, A., Golinelli, R., & Parigi, G. (2002). *Real-time GDP forecasting in the euro area*. Banca d'Italia, Temi di discussione del Servizio Studi 456.
- Barhoumi, K., Darné, O., Ferrara, L., & Pluyaud, B. (2012). *Monthly GDP Forecasting Using Bridge Models: Application For The French Economy*. Bulletin of Economic Research 64 (s1), Seiten 53-70.
- Carstensen, K., Henzel, S., Mayr, J., & Wohlrabe, K. (2009). IFOCAST: Methoden der ifo-Kurzfristprognose. *ifo Schnelldienst* 23-2009, Seiten 15-28.
- Drechsel, K., & Scheufele, R. (2012). *Bottom-up or Direct? Forecasting German GDP in a Data-rich Environment*. Swiss National Bank Working Papers 2012-16.
- Higgins, P. (2014). *GDPNow: A Model for GDP "Nowcasting"*. Federal Reserve Bank of Atlanta Working Paper Series, Working Paper 2014-7.
- Ingenito, R., & Trehan, B. (1996). *Using Monthly Data to Predict Quarterly Output*. FRBSF Economic Review, Seiten 3-11.
- Rünstler, G., Barhoumi, K., Benk, S., Cristadoro, R., Den Reijer, A., Jakaitiene, A., Jelonek, P., Rua, A., Ruth, K., & Van Nieuwenhuyze, C (2009). Short-term Forecasting of GDP Using Large Datasets: A Pseudo Real-Time Forecasting Evaluation Exercise. *Journal of Forecasting* 28 (7), Seiten 595-611.
- Wohlrabe, K. (2009). Makroökonomische Prognosen mit gemischten Frequenzen. *ifo Schnelldienst* 21-2009, Seiten 22-33.

## 9. Anhang

Datenerhebung via Datastream

<b>Komponente</b>	<b>Indikator</b>	<b>Datenquelle</b>
Konsum Nahrung	Einzelhandelsumsätze Nahrungsmittel	Eurostat
	Einzelhandelsumsätze sonstige Güter	Eurostat
Konsum Kleidung	Einzelhandelsumsätze Kleidung	Eurostat
	Absatz verderbliche Ware	Statistisches Bundesamt
Konsum Wohnen	Konsum Öl	Energy Information Administration <a href="http://www.eia.gov/">http://www.eia.gov/</a>
Konsum Einrichtung	Einzelhandelsumsätze Einrichtungsgegenstände	Statistisches Bundesamt
	Consumer Price Index Einrichtungsgegenstände	Statistisches Bundesamt
	ifo Geschäftserwartungen	ifo Institut
Konsum Verkehrsmittel und Kommunikation	Fahrzeuganmeldungen	European Automobile Manufacturers' Association <a href="http://www.acea.be/">http://www.acea.be/</a>
Konsum Kultur und Freizeit	EZB Spitzenrefinanzierungssatz	Deutsche Bundesbank
	Umsatz Informationstechnologie	Eurostat
	Kredite an Unternehmen	Deutsche Bundesbank
Konsum Hotel	Consumer Confidence Index	DG ECFIN – Directorate General for Economic and Financial Affairs
Ausrüstungsinvestitionen	Industrieproduktion Produktionsaufträge	Statistisches Bundesamt Deutsche Bundesbank
Bauinvestitionen	Produktionsindex gesamtes Baugewerbe	OECD
BIP und Bestandteile		Statistisches Bundesamt
* Sämtliche Indikatoren je nach Vorlauf und Verfügbarkeit monatlich oder quartalsweise, BIP und Bestandteile auf Quartalsebene.		









Die Regensburg Papers in Management and Economics dokumentieren in unregelmäßigen Abständen Erkenntnisse aus der betriebs- und volkswirtschaftlichen Forschung und Praxis der Fakultät Betriebswirtschaft der OTH Regensburg. Sie sollen Forschungsergebnisse und Erkenntnisse aus der Zusammenarbeit mit Unternehmen der Öffentlichkeit zugänglich machen und den Austausch zwischen Wissenschaft und Praxis anregen.

ISBN: 978-3-96256-001-0

### PRINTAUSGABEN

können kostenlos über die Fakultät Betriebswirtschaft bestellt werden.

Die Diskussionsbeiträge stehen auch online zur Verfügung:

[www.oth-regensburg.de/fakultaeten/betriebswirtschaft/projekte-publikationen.html](http://www.oth-regensburg.de/fakultaeten/betriebswirtschaft/projekte-publikationen.html)

### Impressum

Ostbayerische Technische Hochschule Regensburg

Fakultät Betriebswirtschaft

Seybothstraße 2 · 93053 Regensburg



OSTBAYERISCHE  
TECHNISCHE HOCHSCHULE  
REGENSBURG

BETRIEBSWIRTSCHAFT