

Klaus S. Friesenbichler, Christian Glocker, Werner Hölzl (WIFO), Philipp Wegmüller (SECO)

Ein neues Modell für die kurzfristige Prognose der Herstellung von Waren und der Ausrüstungsinvestitionen

Ein neues Modell für die kurzfristige Prognose der Herstellung von Waren und der Ausrüstungsinvestitionen

Seit Juni 2018 unterstützt ein dynamisches Faktormodell die WIFO-Prognose der Wertschöpfung der Sachgüterproduktion (Herstellung von Waren) und der Ausrüstungsinvestitionen. Wie eine Überprüfung seiner Prognoseeigenschaften zeigt, hat es einen hohen Vorlauf und kann daher einen wichtigen Input zur Expertenprognose leisten.

A New Model for Short-term Forecasting of Manufacturing and Equipment Investments

In June 2018, a dynamic factor model was introduced to support the WIFO forecast of value added in the manufacturing sector and of investments in machinery and equipment. As a review of its forecasting characteristics shows, it has a high time lead and can therefore provide important input for expert forecasting.

Kontakt:

Mag. Dr. Klaus S. Friesenbichler: WIFO, 1030 Wien, Arsenal, Objekt 20, klaus.friesenbichler@wifo.ac.at

Mag. Dr. Christian Glocker, MSc: WIFO, 1030 Wien, Arsenal, Objekt 20, christian.glocker@wifo.ac.at

Dr. Werner Hölzl: WIFO, 1030 Wien, Arsenal, Objekt 20, werner.hoelzl@wifo.ac.at

Dr. Philipp Wegmüller: Staatssekretariat für Wirtschaft (SECO), 3003 Bern, Holzikofenweg 36, philipp.wegmueller@seco.admin.ch

JEL-Codes: C32, C53, E37 • **Keywords:** Dynamisches Faktormodell, Prognose und Nowcasting, Echtzeitdaten

Begutachtung: Michael Peneder, Philipp Schmidt-Dengler • **Wissenschaftliche Assistenz:** Astrid Czaloun (astrid.czaloun@wifo.ac.at)

Die frühzeitige Einschätzung der Wirtschaftsentwicklung ist Kernaufgabe der Prognosefähigkeit. Vor allem Kurzfristprognosen sind für die Entscheidungsfindung der Wirtschaftsakteure und der Wirtschaftspolitik von Bedeutung. Der Werkzeugkasten des WIFO für die Erstellung von Prognosen umfasst Methoden und Modelle für unterschiedliche Sektoren, Aggregationsebenen und Zeithorizonte und verändert sich über die Zeit. Seit kurzem unterstützt ein neues dynamisches Faktormodell die kurzfristige Expertenprognose der Wertschöpfung der Herstellung von Waren und der Ausrüstungsinvestition.

Die Herstellung von Waren reagiert unter den Sektoren auf der Entstehungsseite des BIP neben der Bauwirtschaft am stärksten auf Konjunkturschwankungen (Hölzl – Kaniowski – Reinstaller, 2015). Sie ist zudem eng mit internationalen Wertschöpfungsketten verflochten. Der Sektor beschäftigte 2017 rund 642.000 Erwerbstätige laut VGR (14,6% aller Erwerbstätigen, Personenkonzept) und erzielte eine nominelle Wertschöpfung von 61,1 Mrd. € (16,5% des BIP).

Die Investitionen sind ein wichtiger Teil der Verwendungsseite des BIP (Bruttoanlageinvestitionen 23,5% des BIP, Ausrüstungen und Waffensysteme 7,9% des BIP) und jener Bereich, der die höchste Konjunkturabhängigkeit aufweist. Ein großer Teil der Ausrüstungsinvestitionen entfällt auf die Herstellung von Waren (23% der gesamten Ausrüstungsinvestitionen 2016). Dies motiviert die Verwendung beider Variablen (Bruttowertschöpfung der Herstellung von Waren und Ausrüstungsinvestitionen der Gesamtwirtschaft) im selben Faktormodell¹⁾.

¹⁾ Investitionen sind eine der am schwierigsten zu prognostizierenden Größen: Ihr erheblicher Vorlauf im Konjunkturzyklus erfordert im Vorfeld eine sorgfältige Auswahl geeigneter Vorlaufindikatoren. Die Veränderungsrate der Investitionen weisen zudem eine sehr hohe Volatilität auf.

Im Zusammenhang mit der Erstellung von Kurzfristprognosen ist der Einsatz statistischer Methoden von großer Bedeutung, um statistische Eigenheiten ökonomischer Zeitreihen konsistent berücksichtigen zu können. Häufige statistische Probleme in der Erstellung von Kurzfristprognosen sind der Mangel an zeitnahen Informationen aufgrund der verzögerten Berechnung oder Veröffentlichung makroökonomischer Aggregate – aus diesem Grund werden auch Nowcasts durchgeführt –, Revisionen von Zeitreihen und der Umstand, dass Reihen in unterschiedlicher Frequenz (monatlich oder quartalsweise) vorliegen können. Diese Probleme erschweren nicht nur die Experteneinschätzung der Wirtschaftsentwicklung, sondern auch die Verwendung quantitativer Methoden. In der Praxis kann sich daraus eine Revisionsaversion ergeben. Auch aus diesem Grund setzt das WIFO künftig für die kurzfristige Prognose der Wertschöpfung der Herstellung von Waren und der Ausrüstungsinvestitionen ein dynamisches Faktormodell ein. Dynamische Faktormodelle wurden in den 1990er-Jahren entwickelt und gehören mittlerweile zu den Standardinstrumenten für ökonomische Kurzfristprognosen (Barhoumi – Darné – Ferrara, 2014). Das vom WIFO eingesetzte Modell orientiert sich an jenem von Camacho – Perez-Quiros (2010) und Glocker – Wegmüller (2017).

1. Herausforderungen in der Erstellung von modellbasierten Kurzfristprognosen

Die Wahl des geeigneten ökonometrischen Modells und des verwendeten Schätzansatzes – ein entscheidender Faktor für die Prognosegüte – wird vor allem von datenbezogenen Herausforderungen bestimmt:

- Das Problem, *Zeitreihen unterschiedlicher Frequenzen* (z. B. monatliche Indikatoren aus Konjunkturumfragen und vierteljährliche VGR-Daten) ohne Informationsverlust gemeinsam zu verwenden, wird üblicherweise gelöst, indem monatliche Reihen zu vierteljährlichen Reihen aggregiert werden. Dies ermöglicht die Verwendung traditioneller Techniken, geht aber mit Informationsverlusten einher. So bleibt die ursprünglich abgebildete Dynamik innerhalb eines Quartals unberücksichtigt. Monatsdaten am aktuellen Rand fließen zudem nur dann ein, wenn Werte für ein vollständiges Quartal vorhanden sind. Informationen, die nur bis zum ersten oder zweiten Monat des aktuellen Quartals verfügbar sind, können nicht genutzt werden. Die Qualität von Kurzfristprognosen wird jedoch vor allem durch die aktuellen Informationen bestimmt.
- *Das Fehlen von Beobachtungen* in verwendeten Zeitreihen stellt auch ausgefeilte ökonometrische Techniken vor Probleme, vor allem wenn die Schätzmethode hohe Anforderungen an die Zahl der Beobachtungen stellt. Eine Schätzung auf Basis zu kurzer Reihen ist unmöglich oder liefert unzuverlässige Ergebnisse. Daten können auch aufgrund unterschiedlicher Publikationstermine am aktuellen Rand fehlen oder nach Veränderung der statistischen Definitionen für die Datenerfassung. Dies betrifft viele makroökonomische Zeitreihen, insbesondere Daten der Volkswirtschaftlichen Gesamtrechnung, Arbeitsmarktdaten sowie Finanzdaten und Kreditbestandsdaten. Eine für Prognosezwecke geeignete statistische Methode sollte somit in der Lage sein, die Möglichkeit des Fehlens von Beobachtungen zu berücksichtigen.
- Weiters sollte die Methode auf die regelmäßigen *Datenrevisionen* durch die Statistischen Ämter reagieren können. Bleiben Datenänderungen und neue Informationen aufgrund von Datenrevisionen unberücksichtigt, so kann dies eine signifikante Änderung im statistischen Profil von Prognosen zur Folge haben. Der Revisionsprozess soll aber nicht die treibende Kraft hinter den Prognoseergebnissen sein, wie dies vor allem für Prognosen mit Hilfe von ARIMA-Modellen (linearen, zeitdiskreten Modellen mit autoregressiven und Moving-Average-Termen) gilt. Ein adäquates Modell soll daher Prognoseergebnisse liefern, die weitgehend invariant zu reinen bzw. prognostizierbaren Datenrevisionen sind. Dies legt nahe, Datenrevisionen explizit im Modell zu modellieren.

Neben der Wahl des statistischen Modells stellt die Prognose selbst eigene Herausforderungen. Mehrperiodenprognosen können rekursiv auf Basis von sequentiellen Einzschritt-Prognosen – wie im vorliegenden Fall – oder als explizites Mehrperiodenmodell mit auf den Prognosehorizont abgestimmten Verlustfunktionen durchgeführt werden.

Rekursive Methoden liefern in der Regel effizientere Parameterschätzungen als explizite Mehrperiodenmodelle (Marcellino – Stock – Watson, 2006). Allerdings sind rekursive Methoden in der Regel anfälliger für Verzerrungen, wenn das Modell fehlerhaft spezifiziert ist und eigene Prognosemodelle für die erklärenden Variablen benötigt werden. Ein häufig verwendeter und überzeugender Ansatz in diesem Zusammenhang ist das vektorautoregressive (VAR) Modell auf Basis unterschiedlicher Frequenzen. Allerdings leidet die Qualität der Prognosen mit diesen Modellen bei Verwendung vieler Indikatoren mit hoher Datenfrequenz unter der Mehrdimensionalität. Um diesem Problem Rechnung zu tragen, kann man Bayes'sche Schätzmethode verwenden oder die Dimensionalität verringern.

In der Statistik werden üblicherweise Faktormodelle verwendet, um die Dimensionalität zu verringern. Dabei wird für Variable, die eng miteinander korreliert sind, angenommen, dass sie durch gemeinsame latente Faktoren (nicht beobachtbare Hintergrundvariable) erklärt werden können. Für makroökonomische Daten trifft dies in der Regel zu: Aufgrund ihrer hohen Kollinearität wird daher in makroökonomischen Anwendungen oft angenommen, dass die zeitliche Variation auf einen einzigen gemeinsamen Faktor zurückgeführt werden kann, der die (makroökonomische) Variabilität des gesamten Datensatzes abbildet.

Das von Stock – Watson (1992) vorgeschlagene und von Camacho – Perez-Quiros (2010) erweiterte dynamische Faktormodell ist ein insbesondere für Kurzfristprognosen interessanter und mittlerweile vielverwendeter ökonometrischer Ansatz. In diesem Modell wird die Information eines beobachtbaren Vektors von Zeitreihen durch einen Vektor unbeobachteter Faktoren mit geringerer Dimensionalität erklärt. Diese gemeinsamen Faktoren sollen die wichtigsten gemeinsamen Bewegungen der beobachteten Zeitreihen abbilden, da theoretisch makroökonomische Schocks Auswirkungen auf viele (wenn nicht alle) makroökonomischen Variablen haben sollten. Besondere Aufmerksamkeit erhalten dynamische Faktormodelle in der Konjunkturanalyse (z. B. Forni – Reichlin, 1998, Eickmeier, 2007, Ritschl – Sarferaz – Uebele, 2016), in der Konjunkturprognose (z. B. Stock – Watson, 2002A, 2002B) und dem Nowcasting (z. B. Banbura et al., 2013).

Die Grundidee besteht darin, eine möglichst große Zahl beobachtbarer Variablen in zwei unabhängige, nicht beobachtbare, aber schätzbare Faktoren zu trennen: einen gemeinsamen Faktor, der den Hauptteil der gemeinsamen Bewegung der beobachtbaren Variablen erfasst, und eine residuale Komponente, welche die verbleibenden Bewegungen beschreibt. Dies verringert die Dimension des Modells. Statistisch werden die Modelle oft in einer Zustandsraumdarstellung formuliert und mit Hilfe des Kalman-Filters geschätzt. Die Schätzung erfolgt rekursiv, daher können fehlende Beobachtungen relativ einfach berücksichtigt werden; dazu werden Unterschritte der Iterationen des Kalman-Filters übersprungen, sodass die ursprüngliche Version des Kalman-Filters gültig bleibt und die Parameter des Modells mit Maximum Likelihood geschätzt werden können. Dieses Merkmal ist für die Berechnung von Prognosen von praktischer Relevanz, da die künftigen Werte der Zeitreihen als (noch) fehlende Beobachtungen interpretiert werden können. Somit bietet der Kalman-Filter eine geeignete Methode zur Prognoseberechnung, die sehr ähnlich funktioniert wie die Schätzung fehlender Werte.

Die Modellschätzung erfolgt mit Hilfe des Kalman-Filters zweistufig: Prognoseberechnung und Aktualisierung (Updating Step); diese zwei Schritte erfolgen wiederholt im Rahmen der Maximierung der Likelihood-Funktion. Aus diesen beiden Schritten ergibt sich die Parameterschätzung. Die eigentliche Prognose ist dabei lediglich ein Nebenprodukt, da sie sich im Rahmen der Iterationen des Kalman-Filters zur Parameterschätzung automatisch ergibt.

Das dynamische Faktormodell

Der Datenvektor $y_t = ((x_{1,t}^h)^s, (x_{1,t}^s)^s, y_t^{1st}, y_t^{fjn})^2$ bezeichnet einen Vektor von N unterschiedlichen Zeitreihen, die zum Zeitpunkt t vorliegen. Die für die Konstruktion des Faktors gewählten Variablen x werden in zwei Gruppen geteilt: Die Gruppe x_t^s umfasst die weichen (soft) Vorlaufindikatoren (z. B. aus dem WIFO-Konjunkturtest) und x_t^h die Gruppe der harten (hard) Indikatoren: Harte und weiche Indikatoren weisen oft ein unterschiedliches zeitliches Korrelationsmuster mit den zu prognostizierenden Variablen in y_t^{fjn} auf. Die Ergebnisvariablen y liegen mit ihrem zuletzt verfügbaren Wert vor (y_t^{fjn}) sowie mit dem Wert ihrer Erstveröffentlichung (y_t^{1st}).

Somit bezeichnet $I_t = \{y_1, \dots, y_t\}$ die Menge aller Informationen bis einschließlich Zeitpunkt t . Das Faktormodell ermöglicht es nun, alle beobachtbaren Variablen in y_t als Summe zweier unabhängiger Komponenten darzustellen: des gemeinsamen Faktors f_t und der verbleibenden idiosynkratischen Komponente e_t (Bai – Ng, 2008). Die idiosynkratische Komponente entsteht durch Messfehler und durch datenspezifische Besonderheiten. Der gemeinsame Faktor f_t folgt einem Zeitreihenprozess, z. B. einem autoregressiven Prozess, d. h. er wird als dynamischer Faktor spezifiziert. In Gleichungsform kann das dynamische Faktormodell wie folgt angeschrieben werden:

- (1) $\begin{pmatrix} x_t^h \\ x_t^s \end{pmatrix} = \begin{pmatrix} \gamma_h \cdot f_{t-\zeta(L)} \\ \gamma_s \cdot \sum_{j=0}^{\zeta(L)} f_{t-j-\zeta(L)} \end{pmatrix} + \begin{pmatrix} u_t^h \\ u_t^s \end{pmatrix},$
- (2) $\begin{pmatrix} y_t^{1st} \\ y_t^{fjn} \end{pmatrix} = \begin{pmatrix} \omega \\ \omega \end{pmatrix} \cdot [y_q f_{t-\zeta(L)} + u_{t,q}] + \begin{pmatrix} 0 \\ \epsilon_t \end{pmatrix},$
- (3) $(1 - \phi_\epsilon(L)) \epsilon_t = \mu_\epsilon + e_t, \quad \text{mit } e_t \sim NID(0, \sigma_e^2),$
- (4) $\phi_q(L) \cdot u_{t,q} = v_t^q, \quad \text{mit } v_t^q \sim NID(0, \Sigma_q^2),$
- (5) $\phi_f(L) \cdot f_t = v_t^f,$
- (6) $\phi_u(L) \begin{pmatrix} u_t^h \\ u_t^s \end{pmatrix} = v_t,$
- (7) $\begin{pmatrix} v_t^f \\ v_t \end{pmatrix} \sim NID\left(0, \begin{bmatrix} \sigma_f^2 & 0 \\ 0 & \Sigma_v \end{bmatrix}\right),$

wobei $\omega = \frac{1}{3} + \frac{2}{3} \cdot L + L^2 + \frac{2}{3} \cdot L^3 + \frac{1}{3} \cdot L^4$ für jene Variablen in $[(y_t^{1st})', (y_t^{fjn})']$, die als vierteljährliche Veränderungsrate spezifiziert sind, und $\omega = 1$ für jene, die im Modell als Vorjahresveränderungsrate verwendet werden. L beschreibt den Verzögerungsoperator (Lag).

Der Term ϵ_t modelliert explizit Revisionen mit Gleichung (3). Die für die Konstruktion des Faktors gewählten Variablen liegen in zwei Gruppen vor: x_t^s umfasst die weichen Vorlaufindikatoren und x_t^h die Gruppe der harten Indikatoren. Diese Unterscheidung erfordert eine explizite Berücksichtigung der unterschiedlichen Korrelationsmuster (Gegenüberstellung der harten Indikatoren auf Basis von vierteljährlichen oder jährlichen Veränderungsrate und der weichen Indikatoren), und zwar mit Hilfe des Ausdruckes $\sum_{j=0}^{\zeta(L)} f_{t-j-\zeta(L)}$. Die harten Indikatoren werden in der Regel mit der gleichen Transformation ins Modell aufgenommen wie die zu erklärenden Variablen (y_t^{1st}, y_t^{fjn}).

Die Variablen (x_t^s, x_t^h) weisen zudem einen unterschiedlich starken Vorlauf gegenüber den zu prognostizierenden Größen (y_t^{1st}, y_t^{fjn}) auf. Anhand des Ausdruckes $\zeta(L)$ kann im Modell in Form einer zeitlichen Verschiebung des gemeinsamen Faktors f_t ein geeignetes zeitliches Profil spezifiziert werden, d. h. dieser Faktor bestimmt, mit welcher Verzögerung die Variablen ins dynamische Faktormodell aufgenommen werden, sodass der Faktor f_t gegenüber den Variablen in (y_t^{1st}, y_t^{fjn}) möglichst weit vorausseilend ist.

Da nur ein latenter Faktor in Betracht gezogen wird, kann sich eine Autokorrelation in den Residuen u_t^h, u_t^s und $u_{t,q}$ ergeben. Für die Residuen werden daher autoregressive Prozesse in Form von Gleichung (4) und (6) vorgegeben¹⁾. Zur Identifikation des Modells werden $\phi_\epsilon(L), \phi_q(L), \phi_u(L)$ jeweils als diagonale Matrizenpolynome der zweiten Ordnung und $\Sigma_e^2, \Sigma_q^2, \Sigma_v$ als diagonale Matrizen festgelegt sowie $\sigma_f^2 = 1$ normalisiert. Gleichung (5) geht davon aus, dass der latente Faktor f_t einem autoregressiven Prozess der zweiten Ordnung (AR(2)) folgt. Diese Spezifikation ist wesentlich für die Bestimmung der Dynamik des Modells; sie kann in diesem Zusammenhang als sparsame Spezifikation betrachtet werden, da sie die Schätzung von nur zwei Parametern erfordert, andererseits aber noch eine reichhaltige Dynamik erlaubt.

Die beschriebene Modelldynamik wird innerhalb der Struktur eines Zustandsraummodells betrachtet, wobei die Messgleichung und die Übergangsgleichung wie folgt spezifiziert sind:

$$y_t = Hs_t + w_t, \quad w_t \sim NID(0, R),$$

$$s_t = Fs_{t-1} + v_t, \quad v_t \sim NID(0, Q).$$

Da das Modell mit Hilfe des Kalman-Filters geschätzt wird, erfordert dies zunächst eine Verpackung des Gleichungssystems (1) bis (7) in die Form eines Zustandsraummodells²⁾.

¹⁾ Alternativ könnte man die Zahl der latenten Faktoren erhöhen. Dadurch würde jedoch das Dimensionalitätsproblem wieder verstärkt. – ²⁾ Details zum Kalman-Filter bieten Hamilton (1994), Mariano – Murasawa (2003) oder Camacho – Perez-Quiros (2010); Details zum Zustandsraummodell – einschließlich einer Beschreibung der Matrizen und Vektoren – finden sich in Glocker – Wegmüller (2017).

2. Modellspezifikation

Der Kasten "Das dynamische Faktormodell" gibt einen technischen Überblick über die Schätzmethode des Modells. Das Modell ist ein in der Literatur vielfach verwendetes dynamisches Faktormodell (Barhoumi – Darné – Ferrara, 2014) mit nur einem gemeinsamen (latenten) Faktor, welcher in der Folge verwendet wird, um Prognosen für die Bruttowertschöpfung der Herstellung von Waren sowie für die Ausrüstungsinvestitionen zu erstellen. Für diese Variablen werden quartalsweise Vorjahresveränderungsraten prognostiziert. Da diese ein beträchtliches Maß an Autokorrelation aufweisen, wird innerhalb des Modells der Faktor als autoregressiver Prozess spezifiziert.

Ein zentrales Element der Modellspezifikation ist die Auswahl der Variablen. In einem ersten Schritt wurde daher eine große Zahl an Indikatoren gesammelt. Ein Kriterium war dafür die frühzeitige Veröffentlichung.

Diese Variablen wurden um die Quartalsreihen Wertschöpfung der Herstellung von Waren und Ausrüstungsinvestitionen ergänzt. Sie sind im Modell durch jeweils zwei Zeitreihen eingebunden: Die erste Reihe enthält die Werte der jeweils ersten Datenveröffentlichung (Erststand), die zweite Reihe die zum aktuellen Zeitpunkt vorliegenden Daten (Letztstand). Dies erlaubt es, systematische Datenrevisionen modelltechnisch explizit zu berücksichtigen.

Übersicht 1: Schätzergebnisse für die Faktorladungen

	Faktorladung	Standardfehler	t-Wert	p-Wert
Österreich, Bruttowertschöpfung Herstellung von Waren, real, saison- und arbeitstagsbereinigt	0,047	0,007	6,69	0,000
Österreich, Ausrüstungsinvestitionen, real, saison- und arbeitstagsbereinigt	0,031	0,009	3,44	0,001
Österreich, Offene Stellen in der Berufsabteilung Industrie–Gewerbe	0,031	0,007	4,36	0,000
Österreich, Unselbständig Beschäftigte, insgesamt	0,031	0,005	5,61	0,000
Österreich, Produktionsentwicklung in den vergangenen Monaten in der Herstellung von Waren, saisonbereinigt	0,050	0,008	6,33	0,000
Österreich, Bank Austria Einkaufsmanagerindex	0,042	0,007	5,97	0,000
Österreich, Index der unternehmerischen Erwartungen in der Sachgütererzeugung	0,049	0,007	7,23	0,000
Deutschland, Auftragsgänge im verarbeitenden Gewerbe, Volumenindex, saison- und arbeitstagsbereinigt	0,056	0,007	7,56	0,000
Deutschland, Produktionstätigkeit im verarbeitenden Gewerbe, Veränderung gegenüber dem Vormonat, saisonbereinigt	0,049	0,006	7,59	0,000
Deutschland, Industrieproduktion, real, saison- und arbeitstagsbereinigt	0,051	0,006	7,95	0,000
USA, Industrieproduktion, saisonbereinigt	0,036	0,006	5,86	0,000
Welthandel, Import, real, saisonbereinigt	0,045	0,008	5,61	0,000

Q: WIFO, Destatis, Arbeitsmarktservice Österreich, Europäische Kommission, ifo (Institut für Wirtschaftsforschung), Bank Austria, CBP, Macrobond.

Aufbauend auf einer Reihe von Kernvariablen (z. B. Industrieproduktion, unselbständig Beschäftigte; Stock – Watson, 1992) wurde die von Camacho – Perez-Quiros (2011) vorgeschlagene Regel zur Auswahl weiterer Variablen angewandt: Auf Basis eines Bestimmtheitsmaßes (hier des korrigierten R^2) wird entschieden, ob eine der rund 30 Variablen hinzugefügt wird und, wenn ja, mit welcher Verzögerung ($\zeta(L)$). Damit wird ein Variablenset ausgewählt, dessen gemeinsamer Faktor f_t einen größtmöglichen Teil der Varianz der Veränderungsraten der Variablen erklärt. Damit werden nur Indikatoren in den Datensatz aufgenommen, die zum gemeinsamen Faktor beitragen²⁾.

Die für das Kurzfristprognosemodell des WIFO ausgewählten Variablen weisen wie erwartet eine positive Faktorladung – ein Maß ihrer Bedeutung zur Beschreibung des Faktors – auf (Übersicht 1). Gemessen daran sind die Auftragsgänge im verarbeitenden Gewerbe in Deutschland die wichtigste Variable im Modell.

²⁾ Neben den beiden Auswahlkriterien (Korrelation mit den Bestimmungsgrößen und Vorlauf) wurden die zeitliche Stabilität der Parameterschätzungen und der Faktorladungen im Besonderen überprüft. Die zeitliche Stabilität ist eine wichtige Eigenschaft, da das Modell im Rahmen einer Prognoseerstellung wiederholt angewandt werden soll. Damit wird u. a. sichergestellt, dass mit Daten bis einschließlich des Vorkrisenjahres 2007 ähnliche Variable ausgewählt werden wie auf Basis des gesamten Datenbestandes, d. h. bis einschließlich 2018.

3. Vorlaufeigenschaften

In einem ersten Schritt wird mit Hilfe der dynamischen Korrelation das Ausmaß des Vorlaufs des Faktors beurteilt, um den Prognosehorizont, für den aussagekräftige Informationen vorliegen, modellgestützt einschätzen zu können. Die Modellprognose beruht im Wesentlichen auf dem latenten Faktor f_t , wodurch dessen Vorlaufeigenschaft die Prognosegüte des Modells bestimmt. Übersicht 2 fasst die Werte der Korrelation des Faktors f_t mit der Wertschöpfung der Herstellung von Waren und den Ausrüstungsinvestitionen zusammen; um eine allgemeinere Einschätzung zu geben, wurde auch das Bruttoinlandsprodukt in die Bewertung aufgenommen. Mit zunehmender Verzögerung der drei Variablen nimmt die Korrelation zu. Die jeweils größte Korrelation ergibt sich bei einer Verzögerung um 5 Monate im Falle der Bruttowertschöpfung der Herstellung von Waren, um 9 Monate im Falle der Ausrüstungsinvestitionen und um 5 Monate im Falle des Bruttoinlandsproduktes. Der latente Faktor (f_t) hat somit eine Vorlaufeigenschaft von knapp einem halben Jahr.

Übersicht 2: Vorlauf des latenten Faktors f_t

Dynamische Korrelation mit den wichtigsten Variablen

	Bruttowertschöpfung Herstellung von Waren	Ausrüstungsinvestitionen	BIP
Verzögerung in Monaten			
0	0,72	0,21	0,62
1	0,81	0,29	0,70
2	0,87	0,37	0,77
3	0,92	0,44	0,82
4	0,94	0,51	0,85
5	0,95*	0,57	0,87*
6	0,93	0,62	0,86
7	0,88	0,66	0,83
8	0,82	0,68	0,79
9	0,74	0,69*	0,73
10	0,65	0,69	0,66
11	0,56	0,68	0,58
12	0,45	0,65	0,50

Q: WIFO. * . . . jeweils höchste Korrelation.

Der Vorlauf ist hier im Vergleich mit anderen Studien (meist höchstens 2 Monate) beträchtlich, aber überwiegend auf die Verwendung quartalsweiser Veränderungsdaten gegenüber dem Vorjahresquartal anstelle von Veränderungsdaten gegenüber dem Vorquartal zurückzuführen. Die Erstellung von Veränderungsdaten durch Differenzbildung impliziert eine Phasenverschiebung im Spektrum einer Zeitreihe und beeinflusst damit die Kohärenz, also die dynamische Korrelation mit anderen Variablen im Frequenzbereich. Die Phasenverschiebung ist umso größer, je weiter eine Differenzbildung zurückreicht. Im Falle von quartalsweisen Vorjahresveränderungsdaten reicht sie weiter zurück als im Falle von Veränderungsdaten gegenüber dem Vorquartal. Eine Modellschätzung auf Basis von Vorquartalsveränderungsdaten ergibt einen Vorlauf des latenten Faktors f_t von 2 Monaten und entspricht damit dem üblichen Befund in der Literatur (Camacho – Perez-Quiros, 2010, Glocker – Wegmüller, 2017).

4. Ein erster Test auf Prognosegüte: die Finanzmarkt- und Wirtschaftskrise


Ausgangspunkt der Beurteilung der Prognosegüte des dynamischen Faktormodells ist die Schätzung auf Basis eines Echtzeit-Datensatzes. So werden zu jedem betrachteten Zeitpunkt nur jene Informationen verwendet, die zu diesem Zeitpunkt für die Prognose verfügbar waren. Der Echtzeit-Datensatz wird auf Quartalsbasis erstellt. Die Indikatoren werden in Pseudo-Echtzeit aufgenommen, d. h. anhand des aktuell verfügbaren Datenstandes bis zum jeweils betrachteten Quartal. Dies erlaubt es, das Verfahren nachzuzeichnen, das in den letzten Jahren zur Schätzung der Modellprognosen durchgeführt worden wäre.

Mit Hilfe dieses Datensatzes werden Echtzeitprognosen für die Jahresveränderungsrate im Jahr 2009 zu unterschiedlichen Zeitpunkten berechnet. So kann exemplarisch nachvollzogen werden, wann das Modell im Vorfeld der Finanzmarkt- und Wirtschaftskrise den Beginn des Abschwunges erkannt hätte. Die Vorhersage dieses Wendepunktes war eine große Herausforderung: Die Turbulenzen auf den Finanzmärkten verstärkten die Prognoseunsicherheit; dies zeigte sich deutlich an quantitativen Unsicherheitsmaßen wie dem VIX oder dem VSTOXX³⁾. Finanzmarktvariable und verschiedene Vorlaufindikatoren wiesen demnach bereits früh auf eine bevorstehende Rezession hin. Diese Hinweise standen jedoch zunächst in erheblichem Gegensatz zur realwirtschaftlichen Entwicklung. Zudem war 2009 das erste Jahr mit einem Rückgang des BIP seit 1981, der zudem der schärfste seit 1947 war.

Die Abbildungen 1 und 2 zeigen den Prognoseverlauf für die Bruttowertschöpfung der Herstellung von Waren und für die Ausrüstungsinvestitionen, und zwar neben der Modellprognose auch die Expertenprognose (WIFO-Prognose)⁴⁾ für die Jahresveränderungsrate 2009. Sowohl die Herstellung von Waren als auch die Ausrüstungsinvestitionen brachen 2009 ein. Das Faktormodell weist erstmals im September 2008 auf eine negative Vorjahresveränderungsrate der Bruttowertschöpfung der Herstellung von Waren hin, für die Ausrüstungsinvestitionen bereits im Juni 2008. Im weiteren Verlauf bewirkt die Information aus Vorlaufindikatoren eine stetige Anpassung der Prognose. Die im Dezember 2008 prognostizierten Werte zur Bruttowertschöpfung und zu den Ausrüstungsinvestitionen lagen bereits nahe an der ersten Realisierung, die im März 2010 verfügbar war. Somit gab das Faktormodell bereits mehr als eineinhalb Jahre vor der ersten offiziellen Veröffentlichung eine relativ zuverlässige Einschätzung der Entwicklung wieder.

Abbildung 1: Bruttowertschöpfung in der Herstellung von Waren

Verlauf der Prognose für das Jahr 2009 zu unterschiedlichen Zeitpunkten



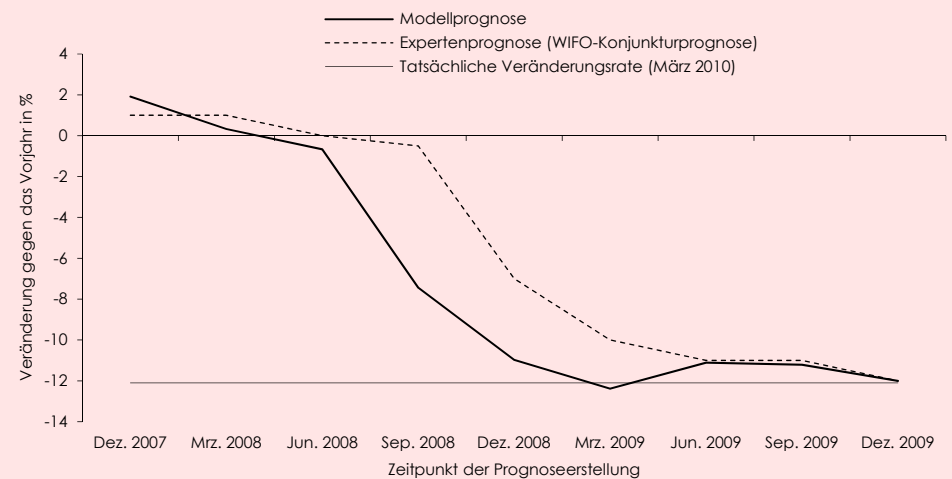
Q: WIFO.

³⁾ VIX und VSTOXX sind in der Literatur häufig verwendete Volatilitätsindizes. Sie geben die vom Markt erwartete kurzfristige Schwankungsintensität (implizite Volatilität) anhand von Optionspreisen auf Aktienindizes (VIX: S&P 500, VSTOXX: Eurostoxx50) über 30 Tage in Prozentpunkten an. Ein hoher Wert weist auf einen unruhigen Markt hin, niedrige Werte lassen eine Entwicklung ohne große Kursschwankungen erwarten. Zwischen den Volatilitätsindizes (VIX und VSTOXX) und den zugrunde liegenden Aktienindizes (S&P 500 und Eurostoxx50) besteht eine gegenläufige Korrelation. Steigt die Volatilität, dann sinkt in der Regel der Aktienindex und umgekehrt.

⁴⁾ Die Modellsimulation in "Echtzeit" hat aufgrund der Variablenauswahl Eigenschaften einer Ex-post-Prognose, während die Expertenprognosen ex ante erstellt wurden. Allerdings weisen Tests der Parameterschätzungen auf eine hohe (zeitliche) Parameterstabilität hin; somit hat die Finanzmarkt- und Wirtschaftskrise von 2008/09 für die Variablenauswahl keine Bedeutung.

Abbildung 2: Ausrüstungsinvestitionen

Verlauf der Prognose für das Jahr 2009 zu unterschiedlichen Zeitpunkten



Q: WIFO.

5. Allgemeine Einschätzung der Prognosegüte

Als Maßzahl für eine allgemeine Einschätzung der Prognosegüte des dynamischen Faktormodells wird der mittlere quadratische Fehler (MQF) herangezogen (Übersicht 3). Die Prognosen der zwei alternativen Modelle (einfache statistische Modelle: Random-Walk, autoregressives Modell AR(2)) wurden auf Quartalsbasis erstellt. Für die kurze Frist (Prognosehorizont bis 13 Monate) weist demnach das Faktormodell den kleinsten MQF auf, wenngleich aufgrund der geringen Zahl der Beobachtungen kein formaler Test zur Bewertung herangezogen werden kann. Der Unterschied zur Expertenprognose ist bei einem längeren Prognosehorizont vernachlässigbar klein, bei einem kürzeren Horizont weist das Faktormodell einen geringeren MQF auf.

Das Faktormodell kann somit einen wertvollen Beitrag insbesondere zur kurzfristigen Expertenprognose leisten. Dies ergibt sich in erster Linie aus der Verwendung der Information von Vorlaufindikatoren⁵).

Übersicht 3: Mittlerer quadratischer Fehler des Faktormodells relativ zu dem anderer Prognosemethoden nach Prognosehorizont

	Expertenprognose (WIFO-Konjunktur- prognose)	Random-Walk-Modell	Autoregressives Modell AR(2)
Bruttowertschöpfung Herstellung von Waren			
Alle Zeithorizonte	0,85	0,48	0,70
Bis 13 Monate	0,61	0,32	0,48
14 bis 25 Monate	0,89	0,55	0,88
Ausrüstungsinvestitionen			
Alle Zeithorizonte	0,74	0,39	0,72
Bis 13 Monate	0,51	0,30	0,48
14 bis 25 Monate	0,80	0,44	0,84
BIP			
Alle Zeithorizonte	0,91	0,42	0,84
Bis 13 Monate	0,66	0,36	0,60
14 bis 25 Monate	0,94	0,46	0,90

Q: WIFO. Werte < 1 . . . mittlerer quadratischer Fehler des Faktormodells kleiner als der der anderen Prognosemethode, Werte > 1 . . . mittlerer quadratischer Fehler des Faktormodells größer als der der anderen Prognosemethode.

⁵) Wie Hölzl – Schwarz (2014) zeigen, sind die aggregierten Reihen des WIFO-Konjunkturtests für die Kurzfristprognose wertvoll, weil sie früher verfügbar sind als die statistischen Daten, aber auch eigenständige Informationen bereitstellen, die nicht allein auf ihrer vorzeitigen Verfügbarkeit beruhen.

Das Random-Walk-Modell weist in allen Fällen einen deutlich größeren MQF auf als das dynamische Faktormodell. Der Vergleich mit dem AR(2)-Modell verdeutlicht die Wirkungsweise der Vorlaufindikatoren im Faktormodell: Das Faktormodell basiert ebenfalls auf einer autoregressiven Struktur mit zwei Verzögerungstermen. Der große Vorsprung hinsichtlich der Prognosegüte gegenüber dem AR(2)-Modell resultiert somit aus der Berücksichtigung der aktuellen monatlichen Indikatoren, die vor allem in der kurzen Frist die Präzision der Prognose des Faktormodells deutlich erhöhen.

6. Illustrative Anwendung auf das Wachstum der Gesamtwirtschaft

Das hier diskutierte dynamische Faktormodell eignet sich im Prinzip auch für Nowcasts bzw. Kurzfristprognosen der BIP-Entwicklung, wenn auch das BIP nicht Teil des Variablensets zur Bestimmung des latenten Faktors (f_t) ist. Ökonomisch ergibt sich dies wie erwähnt, da einerseits die Herstellung von Waren wegen ihres hohen Anteils am BIP (2017: 16,5% des BIP) einen großen Teil der Konjunkturdynamik auf der Angebotsseite bestimmt und andererseits die Ausrüstungsinvestitionen als sehr konjunktursensible Größe trotz ihres geringen Anteils am BIP (2017: 7,9% des BIP) die Konjunkturdynamik auf der Nachfrageseite prägen. Der Faktor f_t beschreibt die Dynamik dieser beiden Variablen gut und sollte sich deshalb auch für Nowcasts bzw. Kurzfristprognosen der BIP-Entwicklung eignen.

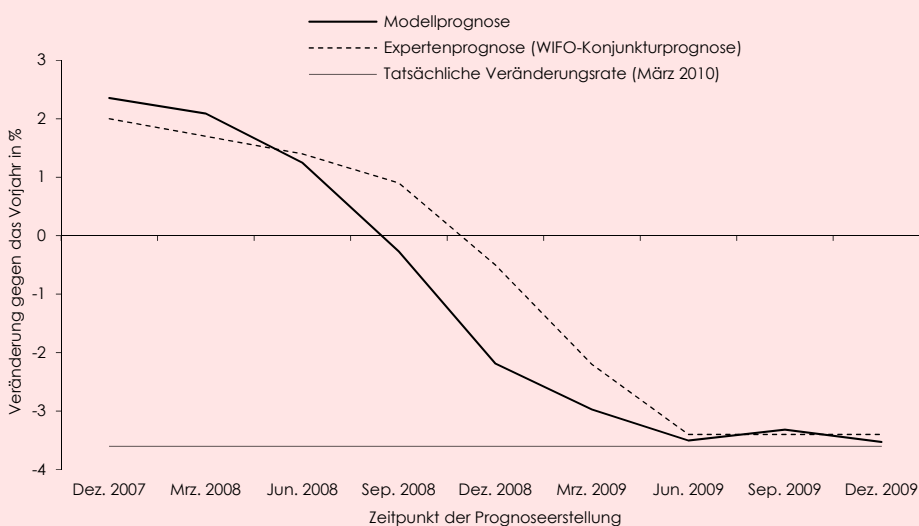
Der latente Faktor f_t wird hier im Rahmen des folgenden univariaten Modells verwendet:

$$g_t^{(q)} - \mu = \beta \cdot f_{t-k}^{(m)} + \sum_{i=0}^q \vartheta_i \tilde{u}_{t-i}^{(m)}$$

$g_t^{(q)}$... Vorjahresveränderung des BIP (Quartalsdaten), $\sum_{i=0}^q \vartheta_i \tilde{u}_{t-i}^{(m)}$... Moving-Average-Term, μ ... Konstante, β ... Koeffizient. Für den Faktor f_t wurde ein Verzögerungsintervall k von 5 Monaten gewählt, weil die Korrelation dieser beiden Variablen bei dieser Verzögerung am größten ist. Anhand der Indizes q und m für Quartals- und Monatsdaten berücksichtigen Schätzung und Prognose des Modells gemischte Frequenzen.

Abbildung 3: BIP

Verlauf der Prognose für das Jahr 2009 zu unterschiedlichen Zeitpunkten



Q: WIFO.

Wie für die Bruttowertschöpfung der Herstellung von Waren und die Ausrüstungsinvestitionen errechnet das Faktormodell auch für das BIP bereits im September 2008 eine negative Jahresveränderungsrate für das Jahr 2009. Die Hinweise auf einen BIP-

Rückgang verstärken sich in den Folgemonaten und festigen sich ab Juni 2009 auf einem Niveau nahe dem ersten realisierten Wert im März 2010 (Abbildung 3). Die Prognosegüte wird auch durch den mittleren quadratischen Fehler bestätigt (Übersicht 3). Der latente Faktor des Faktormodells in Verbindung mit dem univariaten Schätzansatz weist insbesondere in der sehr kurzen Frist einen spürbar kleineren mittleren quadratischen Fehler auf. Dieser Unterschied ist besonders groß gegenüber dem Random-Walk-Modell, weniger ausgeprägt gegenüber der WIFO-Prognose bzw. dem AR(2)-Modell. Für Zeithorizonte über 13 Monate unterscheidet sich die Prognosegüte deutlich weniger.

Diese Anwendung auf das BIP-Wachstum verdeutlicht abermals die Stärke des Faktormodells (und rein statistischer Methoden, die auf Frühindikatoren aufsetzen) für die Erstellung von Nowcasts und Kurzfristprognosen, insbesondere über einen Horizont von ungefähr einem Jahr.

7. Zusammenfassung

Das WIFO verfügt seit kurzem über ein neues Instrument für kurzfristige Prognosen: Ein relativ einfaches mittelgroßes Faktormodell wird künftig zur Unterstützung der Prognose der Bruttowertschöpfung der Herstellung von Waren und der Ausrüstungsinvestitionen im Rahmen der WIFO-Konjunkturprognose verwendet. Wie die Analyse gezeigt hat, prognostiziert dieses Modell die kurzfristige Entwicklung der Herstellung von Waren und der Ausrüstungsinvestitionen in Österreich gut und kann damit einen wichtigen Input für die Expertenprognose leisten. Vor allem der hohe Vorlauf des latenten Faktors (nicht beobachtbare gemeinsame Komponente) gegenüber den statistischen Daten zur Wertschöpfung der Herstellung von Waren und zu den Ausrüstungsinvestitionen trägt entscheidend zur Prognosegüte bei. Im Rahmen einer kleinen Erweiterung erweist sich der latente Faktor aus diesem Faktormodell auch als geeignet für eine Schnellschätzung der BIP-Entwicklung. Der hier vorgestellte Ansatz kann daher im Prinzip auf andere Variable erweitert werden.

8. Literaturhinweise

- Bai, J., Ng, S., "Forecasting economic time series using targeted predictors", *Journal of Econometrics*, 2008, 146(2), S. 304-317.
- Banbura, M., Giannone, D., Modugno, M., Reichlin, L., "Now-Casting and the Real-Time Data Flow", in Elliott, G., Granger, C., Timmermann, A. (Hrsg.), *Handbook of Economic Forecasting*, 2. Auflage, Elsevier, Amsterdam, 2013, S. 195-237.
- Barhoumi, K., Darné, O., Ferrara, L., "Dynamic factor models: A review of the literature", *Journal of Business Cycle Measurement and Analysis*, 2014, 2013(2), S. 73-107.
- Camacho, M., Perez-Quiros, G., "Introducing the euro-sting: Short-term indicator of euro area growth", *Journal of Applied Econometrics*, 2010, 25(4), S. 663-694.
- Camacho, M., Perez-Quiros, G., "Spain-Sting: Spain Short-Term Indicator of Growth", *The Manchester School*, 2011, 79(s1), S. 594-616.
- Eickmeier, S., "Business cycle transmission from the US to Germany – A structural factor approach", *European Economic Review*, 2007, 51(3), S. 521-551.
- Forni, M., Reichlin, L., "Let's Get Real: A Factor Analytical Approach to Disaggregated Business Cycle Dynamics", *Review of Economic Studies*, 1998, 65(3), S. 453-473.
- Glocker, Ch., Wegmüller, P., "Business Cycle Dating and Forecasting with Real-time Swiss GDP Data", WIFO Working Papers, 2017, (542), <https://www.wifo.ac.at/www/pubid/60645>.
- Hamilton, J. D., *Time Series Analysis*, Princeton University Press, Princeton, 1994.
- Hözl, W., Kaniovski, S., Reinstaller, A., "The exposure of technology and knowledge intense sectors to the business cycle", *Bulletin of Applied Economics*, 2015, 2(1), S. 1-19.
- Hözl, W., Schwarz, G., "Der WIFO-Konjunkturtest: Methodik und Prognoseeigenschaften", *WIFO-Monatsberichte*, 2014, 87(12), S. 835-850, <http://monatsberichte.wifo.ac.at/50863>.
- Marcellino, M., Stock, J. H., Watson, M. W., "A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series", *Journal of Econometrics*, 2006, 135(1-2), S. 499-526.
- Mariano, R. S., Murasawa, Y., "A new coincident index of business cycles based on monthly and quarterly series", *Journal of Applied Econometrics*, 2003, 18(4), S. 427-443.
- Ritschl, A., Sarferaz, S., Uebele, M., "The U.S. Business Cycle, 1867-2006: A Dynamic Factor Approach", *The Review of Economics and Statistics*, 2016, 98(1), S. 159-172.

- Stock, J. W., Watson, M. W., "A probability model of the coincident economic indicators", in Lahiri, K., Moore, G. (Hrsg.), *Leading Economic Indicators: New Approaches and Forecasting Records*, Cambridge University Press, Cambridge, 1992, S. 63-90.
- Stock, J. H., Watson, M. W. (2002A), "Macroeconomic Forecasting Using Diffusion Indexes", *Journal of Business & Economic Statistics*, 2002, 20(2), S. 147-162.
- Stock, J. H., Watson, M. W. (2002B), "Forecasting Using Principal Components from a Large Number of Predictors", *Journal of the American Statistical Association*, 2002, 97(460), S. 1167-1179.