

Die ökonometrische Prognose von makroökonomischen Zeitreihen steht häufig vor dem Problem, dass die verwendeten Indikatoren und die Zielzeitreihe in verschiedenen Frequenzen vorliegen. So ist das Bruttoinlandsprodukt nur auf Quartalsbasis verfügbar, während die meisten Indikatoren, wie z.B. das ifo Geschäftsklima, monatlich erhoben werden. Der vorliegende Artikel¹ stellt zwei Modellklassen aus der neueren Literatur vor, die – anders als die klassischen Brückengleichungen – Schätzungen mit gemischten Frequenzen ohne aggregationsbedingten Informationsverlust erlauben: MIDAS-Modelle und VAR-Zustandsraummodelle. Diese Verfahren haben den zusätzlichen Vorteil, dass hochfrequente Informationen, die innerhalb einer Periode hinzukommen, problemlos in die Prognose einbezogen werden können. Anhand einer Fallstudie für das deutsche Bruttoinlandsprodukt wird gezeigt, dass die neuen Modellklassen genauere Prognosen als die üblichen Zeitreihenmodelle liefern. Die neuen Verfahren werden am ifo Institut zur Kurzfristprognose eingesetzt.

Die zukünftige Entwicklung von makroökonomischen Zeitreihen ist von zentraler Bedeutung für viele wirtschaftliche und politische Akteure. Besondere Aufmerksamkeit nimmt dabei das Bruttoinlandsprodukt (BIP) ein, das die umfassendste Aggregation gesamtwirtschaftlicher Aktivität darstellt. Das Bruttoinlandsprodukt und seine Wachstumsrate werden oft als Maßstäbe für den Zustand und die Entwicklung einer Volkswirtschaft interpretiert.² Sie beeinflussen u.a. die Zinsentscheidungen von Zentralbanken, die Budgetplanungen des Staates, die Investitionsentscheidungen von Unternehmen und den privaten Konsum. Da solche Entscheidungen typischerweise zukunftsgerichtet sind, ist eine möglichst zuverlässige Prognose von großer Bedeutung.

Die makroökonomische Prognose wirtschaftlicher Kennzahlen basiert oft auf Modellen, in denen die Zielgröße zu Indikatoren in Beziehung gesetzt wird, die einen Informationsgehalt bezüglich der weiteren wirtschaftlichen Entwicklung besitzen. In der Praxis ist man jedoch mit dem zentralen Problem konfrontiert, dass die Indikatoren und die Zielgröße oft zu verschiedenen Frequenzen erhoben werden. Standardmodelle in der Zeitreihenökono-

metrie gehen jedoch davon aus, dass alle verwendeten Zeitreihen dieselbe Frequenz besitzen. Ein klassisches Beispiel ist die Prognose des Bruttoinlandsprodukts. Nahezu alle wichtigen Frühindikatoren werden monatlich erhoben, während das Bruttoinlandsprodukt nur auf Quartalsebene vorliegt. Einige Indikatoren sind sogar auf Wochen- oder Tagesbasis verfügbar.³ Hier stellt sich die Frage, inwieweit diese hochfrequenten Informationen insbesondere für die Kurzfristprognose genutzt werden können.

Die Standardlösung ist eine zweistufige Prozedur. Zunächst werden alle Daten auf die niedrigste Frequenz aggregiert und darauf aufbauend wird ein Zeitreihenmodell geschätzt. Dieses Vorgehen hat zwei schwerwiegende Nachteile. Zum einen werden durch die Aggregation hochfrequente Informationen zerstört, welche für die Prognose nützlich sein könnten. Zum anderen sind die auf der niedrigeren Frequenz operierenden Standardzeitreihenmodelle nicht in der Lage, Informationen zu verarbeiten, die innerhalb des zu prognostizierenden Zeitintervalls veröffentlicht werden. Soll z.B. Ende Februar eines Jahres die Wachstumsrate des Bruttoinlandsprodukts im ersten Quartal prognostiziert werden, kann z.B. das ifo Geschäftsklima im Januar und Februar für die Berechnung nicht verwendet werden.

¹ Dieser Artikel basiert auf Forschungsergebnissen des DFG-Projektes am ifo Institut »Modellierung von Zeitreihen verschiedener Frequenzen, Konjunkturanalyse und die Analyse der Interaktion zwischen dem Real- und Finanzsektor«.

² Wenn in der öffentlichen Diskussion über »Wachstum« gesprochen wird, dann bezieht sich dies meist auf die Wachstumsrate des BIP.

³ Als Beispiele seien Wechsel- und Aktienkurse oder Rohstoffpreise genannt. Im Prinzip können auch Minutendaten als Basis für Prognosen dienen.

In der aktuellen Forschung sind zwei neuere Zeitreihenmodelle entwickelt worden, die sich mit diesem Aspekt der gemischten Frequenzen beschäftigen: die MIDAS-Modelle und die vektorautoregressiven Zustandsraummodelle. Der vorliegende Aufsatz stellt diese zwei Ansätze zur Modellierung von gemischten Frequenzen vor. Darüber hinaus werden diese mit dem älteren Ansatz der Brückengleichungen verglichen. Diese Modellklasse der gemischten Frequenzen erlaubt die Beantwortung vieler aktueller Fragen. Zum einen besteht die Möglichkeit zu untersuchen, inwieweit (Tages- oder Wochen-)Informationen innerhalb des aktuellen Quartals zur Verbesserung der Prognose makroökonomischer Kenngrößen beitragen können. Zum anderen erlauben die Modelle zeitreihenökonomisch zu analysieren, inwieweit Interaktionen zwischen Finanz- und Realwirtschaft bestehen. Dies ist vor allem vor dem Hintergrund der aktuellen Wirtschafts- und Finanzkrise von Relevanz. Selbst die Zusammenführung und Analyse von hochfrequenten Zeitreihen der Finanzmärkte (z.B. Minuten- und Tagesdaten) und von niedrigfrequenten Zeitreihen aus der Realwirtschaft (z.B. Quartals- und Jahresdaten) ist auf der Basis der neuen Modelle möglich geworden.

Nach Vorstellung der Zeitreihenmodelle wird im Rahmen einer kleinen Fallstudie die Prognosegüte der neuen und der klassischen Verfahren insbesondere für die kurze Frist verglichen. Die Zielzeitreihe ist das Bruttoinlandsprodukt Deutschlands. Um die Lesbarkeit zu vereinfachen, werden in dem Artikel die Modelle vor allem am Beispiel der Mischung von Monats- und Quartalsdaten vorgestellt. Grundsätzlich sind alle drei Modellklassen in der Lage, jegliche Frequenzmischungen zu verarbeiten. Für eine Verallgemeinerung siehe Wohlrabe (2009a).

Die klassische Lösung des Problems der gemischten Frequenzen

Üblicherweise wird das Problem unterschiedlicher Frequenzen durch Transformation der Zeitreihen umgangen. Dabei bestehen zwei grundlegende Optionen. Entweder werden die hochfrequenten Variablen auf die niedrigste Frequenz aggregiert oder die niedrigfrequenten Variablen werden auf die höchste Frequenz interpoliert. So werden z.B. bei der Verwendung von Monats- und Quartalsdaten im ersten Fall die Monatsdaten zu Quartalsdaten aggregiert und im zweiten Fall werden die Quartalsdaten zu Monatsdaten interpoliert.

Die häufigste Form der Aggregation ist die Durchschnittsbildung über eine Periode der niederen Frequenz (z.B. Dreimonatsdurchschnitt für ein Quartal). Alternativ wird bei Bestandsvariablen der letzte Monatswert im Quartal verwendet, und im Falle von Flussvariablen werden die drei Monatswerte addiert.

Die Interpolation von Quartals- auf Monatsdaten kann auf Basis rein statistischer Verfahren, wie z.B. die lineare oder kubische Interpolation, auf Basis der Regression auf andere Zeitreihen⁴, oder durch Nutzung von Zustandsraummodellen erfolgen. Letztere modellieren ein multivariates System von Zeitreihen auf der höchsten Frequenz und behandeln die fehlenden Beobachtungen letztlich als zu schätzende Werte.⁵

Im Prinzip handelt es sich bei diesen klassischen Lösungen um zweistufige Verfahren. Im ersten Schritt werden alle Zeitreihen in eine gleiche Frequenz transformiert. Im zweiten Schritt werden das zeitreihenökonomische Modell auf der einheitlichen Frequenz geschätzt und darauf aufbauend die Prognosen berechnet. Die Standardverfahren, ihre Spezifikation und die darauf aufbauende Berechnung der Prognosen werden in Robinsonov und Wohlrabe (2010) ausführlich erläutert.

Die Transformationslösung ist jedoch unbefriedigend. Durch die Aggregation gehen Informationen verloren, insbesondere die Dynamik der hochfrequenten Variablen. Bei der Interpolation besteht erhebliche Schätzunsicherheit bezüglich des Interpolationsverfahrens, da es kein »wahres« Verfahren gibt. Methoden, die eine Transformation der Daten umgehen, sollten deshalb bessere Prognosen erwartet lassen.

In der Tat zeigen Ghysels und Valkanov (2006) und Hyung und Granger (2008) auf Basis theoretischer Modelle, dass die Prognosegüte bei der Nutzung von gemischten Frequenzen höher ist als bei Modellen, bei denen die Daten aggregiert werden müssen. Die empirische Literatur bestätigt dieses Ergebnis.⁶

Brückengleichungen

Brückengleichungen (»bridge equations«) werden häufig für die Kurzfristprognose insbesondere des Bruttoinlandsprodukts verwendet.⁷ Der Name ist darauf zurückzuführen, dass eine Brücke zwischen der hoch- und der niedrigfrequenten Variablen »gebaut« wird. Im strengen Sinne operieren Brückengleichungen nur auf einer Frequenz, nämlich der niedrigeren. Verwendet man einen hochfrequenten Indikator x , so wird dieser zunächst auf die niedrige Frequenz

⁴ Die klassische Referenz ist Chow und Lin (1971). Siehe Seiler (2009) für weiterführende Details.

⁵ Siehe Angelini, Henry und Marcellino (2006) für weitere Details und einen Vergleich unterschiedlicher Interpolationsverfahren.

⁶ Weitere Informationen finden sich in dem Abschnitt über empirische Evidenz. Einen ausführlichen Überblick liefert Wohlrabe (2009a).

⁷ Brückengleichungen werden insbesondere häufig an Zentralbanken verwendet. Dies dokumentiert sich darin, dass die Mehrheit der Veröffentlichungen in diesem Bereich von Autoren an Zentralbanken stammt. Siehe Wohlrabe (2009a) für einen Überblick.

aggregiert. Dann wird er in das typischerweise verwendete ADL-Modell («autoregressive distributed lag»)

$$(1) \quad y_t = \alpha + \sum_{i=1}^p \beta_i y_{t-i} + \sum_{j=0}^q \gamma_j x_{t-j} + \varepsilon_t$$

integriert. Die zu prognostizierende niedrigfrequente Variable y_t , hängt zum einen von den p eigenen Verzögerungen ab. Zum anderen besitzt der auf die niedrige Frequenz transformierte Indikator x sowohl einen vorlaufenden (bis zu q Verzögerungen) als auch einen kontemporären Einfluss auf die Zielvariable y .⁸ Das ADL-Modell kann um weitere Variablen erweitert werden, die zu unterschiedlichen Frequenzen erhoben worden sind.

Um eine Kurzfristprognose für das aktuelle Quartal durchführen zu können, muss ein aktueller Quartalsdurchschnitt des hochfrequenten Indikators x vorliegen. Sind aber noch nicht alle Monatswerte bekannt, so müssen die fehlenden Werte bis zum Ende des Quartals fortgeschrieben werden, um zu einer Quartalszahl aggregiert werden zu können. Dafür gibt es mehrere Möglichkeiten, die sowohl von den Daten als auch von dem Zeitpunkt der Prognose abhängen. In der Literatur werden dazu häufig zwei Ansätze verwendet. Am einfachsten ist die naive Prognose der fehlenden Monatswerte, worunter die Fortschreibung des letzten beobachteten Wertes verstanden wird. Alternativ wird ein separates Zeitreihenmodell, z.B. ein autoregressives Modell, in Monatsfrequenz benutzt.

Das MIDAS-Modell

Grundsätzlich besteht die Möglichkeit, die niederfrequente Zielvariable direkt auf einen hochfrequenten Indikator zu regressieren, ohne dass dieser vorher aggregiert wird. Der Nachteil einer unrestringierten Schätzung kann darin bestehen, dass zu viele Koeffizienten geschätzt werden müssen (Parameterproliferation) und so die Schätzunsicherheit zunimmt. Wird z.B. vermutet, dass eine quartalsweise vorliegende Zielvariable y von den zurückliegenden Ausprägungen eines ganzen Jahres des monatlich erhobenen Indikators x abhängt, so müssen dafür zwölf Koeffizienten geschätzt werden (ein Koeffizient pro zurückliegendem Monat), während im Rahmen einer Brückengleichung auf Quartalsebene nur vier Koeffizienten bestimmt werden müssen (ein Koeffizient pro Quartal). Der unrestringierte Ansatz wurde in einem Aufsatz von Koenig, Dolmas und Piger (2003) verwendet, ansonsten aber kaum in der Literatur genutzt.

⁸ Diese kontemporären Einflüsse sind wichtig für die Kurzfristprognose, da sie eine aktuelle Schätzung z.B. des Bruttoinlandsprodukts für das laufende Quartal erlauben. Ein solcher Nowcast bildet häufig die Basis für alle weiteren Prognosen. Das Statistische Bundesamt veröffentlicht eine erste Schätzung des Bruttoinlandsprodukts erst sechs Wochen nach Ablauf eines Quartals.

Ein Ansatz, der das Problem der Parameterproliferation vermeidet, ist das MIDAS-Modell (vgl. Box 1 für eine formale Erläuterung). Die Abkürzung MIDAS steht für Mixed Data Sampling. Diese Modellklasse ist eng verwandt mit den verzögerten Lagstrukturmodellen und wurde von Ghysels, Santa-Clara und Valkanov (2004) zur Schätzung bei gemischten Frequenzen vorgeschlagen. Im Kern geht es darum, bei der Regression der niederfrequenten Zielvariable auf den hochfrequenten Indikator eine Gewichtungsfunktion der Verzögerungen vorzugeben, mit deren Hilfe die Anzahl der zu schätzenden Parameter gegenüber dem unrestringierten Ansatz erheblich verringert wird. Anstatt also jeder Verzögerung einen freien Parameter zuzuweisen, wird in MIDAS-Modellen nur ein Parameter für die addierten gewichteten Verzögerungen spezifiziert. Die Gewichtungsfunktion selbst hängt nur von wenigen Parametern ab.

In Abbildung 1 sind vier verschiedene Beispiele einer exponentiellen Almon-Gewichtungsfunktion dargestellt. Es zeigt sich, dass durch die Wahl der zwei Parameter θ_1 und θ_2 unterschiedlichste Gewichtungsverläufe dargestellt werden können. So gehen im Quadranten links oben die Gewichte mit zunehmender Verzögerung zurück, was die Vermutung widerspiegelt, dass weiter zurückliegende Ereignisse weniger Einfluss auf die Prognose haben. In der Praxis sind aber auch die anderen Gewichtungsverläufe prinzipiell relevant. Für den Anwender besteht die Möglichkeit, die Gewichtungsfunktion aus den Daten schätzen zu lassen, zu restringieren (z.B. fallende Gewichte), oder *a priori* vorzugeben, wenn dies sich z.B. aus theoretischen Erwägungen ergibt. Insgesamt wird deutlich, dass das MIDAS-Modell eine sehr sparsame aber trotzdem flexible Parametrisierung der Verzögerungen erlaubt.

Für die Prognose ist zu beachten, dass MIDAS-Modelle als direkte Prognosemodelle spezifiziert werden. Das bedeutet, dass für eine h -Schritt-Prognose ein Modell gewählt wird, in dem die Zielvariable von der h -ten und höheren Verzögerungen abhängt. Folglich muss für jeden Prognosehorizont ein separates Modell aufgestellt und geschätzt werden. So hängt die Zielvariable im Modell für eine Einschnitt-Prognose von der ersten und höheren Verzögerungen ab, im Modell für eine Vierschnitt-Prognose von der vierten und höheren Verzögerungen.

Vektorautoregressive Zustandsraummodelle

Zustandsraummodelle sind eine sehr flexible Modellklasse, in deren Rahmen eine Vielzahl von klassischen und neuen Zeitreihenmodellen geschätzt werden kann. Ein Zustandsraummodell besteht immer aus einer Zustandsgleichung, die eine unbeobachtbare Variable modelliert, und aus einer Beobachtungsgleichung, welche diese latente Variable in Beziehung zu den beobachtbaren Variablen setzt.

Box 1
MIDAS-Modelle

Das einfachste MIDAS-Modell ist gegeben durch:

$$y_t = \beta_0 + \beta_1 B(L^{1/m}, \theta) x_{t-1}^{(m)} + \varepsilon_t^{(m)},$$

wobei $B(L^{1/m}, \theta) = \sum_{k=0}^K B(k; \theta) L^{k/m}$ eine Gewichtungsfunktion ist und $L^{k/m} = X_{t-1-k/m}^{(m)}$ einen fraktionalen Lag-Operator darstellt. Der Index t repräsentiert die niedrigere Frequenz und m entspricht dem Mischungsverhältnis der Frequenzen. Wenn z.B. Monats- und Quartalsdaten verwendet werden, dann entspricht m gleich drei, da drei Monate einem Quartal entsprechen.

Um ein Beispiel zu geben, nehmen wir an, dass $m = 3$ und $K = 6$ (6 Monate als Verzögerungen (Lags)), dann gilt

$$y_t = \beta_0 + \beta_1 B(L^{1/3}, \theta) x_{t-1}^{(3)} + \varepsilon_t^{(3)}$$

mit $B(L^{1/3}, \theta) = \sum_{k=0}^6 B(k; \theta) L^{k/3}$. Je nach Prognosehorizont ergibt sich das konkrete Modell. Gilt ein Prognosehorizont

von einem Quartal ($h=1$), dann gilt $L^{k/3} = X_{t-1-k/3}^{(3)}$. Somit ergibt sich

$$y_t = \beta_0 + \beta_1 \left(B(0, \theta) x_{t-1}^{(3)} + B(1, \theta) x_{t-1-1/3}^{(3)} + \dots + B(6, \theta) x_{t-3}^{(3)} \right) + \varepsilon_t^{(3)}.$$

Soll das erste Quartal (y_t) eines Jahres prognostiziert werden, dann entspricht X_{t-1} dem Wert des Indikators im Dezember, $X_{t-1-1/3}$ dem im November und schließlich X_{t-3} dem im Juli.

Befindet man sich innerhalb des Quartals, z.B. $h=1/3$, (vgl. Abbildung 2), dann gilt $L^{k/3} = X_{t-(1+k)/3}^{(3)}$, somit ergibt sich

$$y_t = \beta_0 + \beta_1 \left(B(0, \theta) x_{t-1/3}^{(3)} + B(1, \theta) x_{t-1-1/3}^{(3)} + \dots + B(6, \theta) x_{t-2}^{(3)} \right) + \varepsilon_t^{(3)}$$

In diesem Falle entspricht $X_{t-1/3}$ dem Februar, $X_{t-2/3}$ dem Januar und schließlich X_{t-2} dem September.

Die Gewichtungsfunktion B kann auf verschiedene Arten modelliert werden. In der Literatur wird vor allem die exponentielle Almon-Lag-Funktion verwendet, welche in ihrer einfachsten Form gegeben ist durch:

$$B(k; \theta) = \frac{\exp(\theta_1 k + \theta_2 k^2)}{\sum_{k=1}^K \exp(\theta_1 k + \theta_2 k^2)}$$

Diese Formulierung der Gewichtungsfunktion stellt sicher, dass sich die Gewichte positiv sind und sich zu 1 addieren. Aufgrund dieser Eigenschaften kann das Modell ökonometrisch eindeutig identifiziert werden. Eine alternative Gewichtungsfunktion ist die Beta-Funktion, siehe Ghysels, Sinko und Valkanov (2007) für Details.


MIDAS-Modelle werden mit nichtlinearen Kleinst-Quadrate-Schätzer geschätzt, da das Modell nichtlinear in den Parametern ist. In der MIDAS-Modellklasse ist die Anzahl der zu schätzenden Parametern unabhängig von der Anzahl der Lags K . Es verkürzt sich lediglich das Schätzsample. Clements und Galvao (2008) zeigen, wie sich MIDAS-Modelle um einen autoregressiven Parameter erweitern lassen.

Mit Hilfe des so genannten Kalman-Filters lässt sich die un beobachtbare Variable in optimaler Weise extrahieren.⁹ Im

Fall gemischter Frequenzen können so die fehlenden Beobachtungen der niedrigfrequenten Variablen bestimmt und die Interaktionen mit der hochfrequenten Variablen untersucht werden. Dadurch ist im Prinzip ein Informationsvorteil gegenüber konkurrierenden Verfahren zu erreichen.

⁹ Die klassische Referenz für Zustandsraummodelle und deren Anwendungen in der Zeitreihenanalyse ist Harvey (1989), siehe auch Durbin und Koopman (2001) für eine neuere Darstellung.

Abb. 1
Beispiele für exponentielle Almon-Lag-Gewichtsfunktionen



Quelle: Berechnungen des ifo Instituts.

Die Idee, Zustandsraummodelle zur Schätzung von vektorautoregressiven Zeitreihenmodellen mit gemischten Frequenzen zu verwenden, geht auf Zadrozny (1988; 1990) zurück. Das Verfahren blieb lange Zeit unberücksichtigt und wird erst in jüngster Zeit wieder verwendet, z.B. von Mitnik und Zadrozny (2005), Hyung und Granger (2008), Kuzin, Marcellino und Schumacher (2009b) oder Wohlrabe (2009a; b).

Die komplette Darstellung der Modellierung von gemischten Frequenzen mit Zustandsraummodellen würde den Rahmen des Artikels sprengen. Box 2 präsentiert die Grundidee des Modells in Anlehnung an Hyung und Granger (2008), welches sich im Aufbau leicht vom Modell von Zadrozny (1990) unterscheidet. Für Details sei auf Wohlrabe (2009a) verwiesen. Grundsätzlich werden alle Variablen als endogen aufgefasst und als vektorautoregressiver Prozess (VAR-Prozess) modelliert, der als Zustandsraummodell dargestellt wird.

Die Spezifikation erfolgt dabei auf der höchsten Frequenz, d.h. werden z.B. Wochen-, Monats- und Quartalsdaten verwendet, so werden das System und die Dynamik der Variablen auf Wochenbasis abgebildet. Auf diese Weise wird

sichergestellt, dass die aktuell zur Verfügung stehende Information effizient verarbeitet wird. Insbesondere können auch sehr kurzfristige Entwicklungen für die Prognose genutzt werden.

Im Gegensatz zum MIDAS-Modell werden VAR-Zustandsraummodelle in der gegenwärtigen Literatur nicht als direkte, sondern als indirekte Modelle spezifiziert.¹⁰ Dies hat den Vorteil, dass nur ein Modell für jeden Prognosehorizont geschätzt werden muss. Ist das Modell einmal in einem Zustandsraum spezifiziert, so erfolgt die Schätzung mit Hilfe des Kalman-Filters. Der »Trick«, zur Behandlung der gemischten Frequenzen besteht darin, dass die Matrizen innerhalb des Filters den tatsächlichen beobachteten Werten angepasst werden. Sind z.B. zum Zeitpunkt t sowohl die Monats- als auch die Quartalsinformationen verfügbar, so werden diese beide verarbeitet. Liegen zum folgenden Zeitpunkt $t + 1$ keine Quartalsbeobachtungen vor, wird nur die Monatsinformation im Filter verwendet.

¹⁰ Grundsätzlich ist es jedoch möglich, die indirekten als direkte Gleichungen zu spezifizieren. Dies ist in der Literatur jedoch bisher nicht angewandt worden.

Box 2
VAR-Zustandsraummodelle nach Hyung und Granger (2008)

Das Modell soll am Beispiel eines VAR(1) mit zwei Zeitreihen illustriert werden. Das System ist durch folgende Gleichung gegeben.

$$(1) \quad \begin{bmatrix} y_{1\tau} \\ y_{2\tau} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} y_{1\tau-1} \\ y_{2\tau-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1\tau} \\ \varepsilon_{2\tau} \end{bmatrix},$$

wobei $y_{1\tau}$ und $y_{2\tau}$ die entsprechenden Zeitreihen sind. Die Parameter a_{ij} stellen die zu schätzenden Koeffizienten dar. Die übliche Zeitindexierung t wurde schon im MIDAS-Modell verwendet, ist dort aber für die niedrigste Frequenz definiert. Deshalb wird aus Gründen der Eindeutigkeit der Zeitindex τ für die höchste Frequenz verwendet.

Gleichung (1) lässt sich in Matrixform kompakter schreiben:

$$(2) \quad y_{\tau} = Fy_{\tau-1} + \varepsilon_{\tau}$$

Die entsprechende Zustandsgleichung für das bivariate Zeitreihensystem (1) ist gegeben durch

$$(3) \quad x_{\tau} = Fx_{\tau-1} + \varepsilon_{\tau},$$

wobei der Vektor x zwei unbeobachtbaren Zeitreihen (Zustände) und die Matrix F die zu schätzenden Koeffizienten aus Gleichung (1) enthält.

Die korrespondierende Beobachtungsgleichung ist gegeben durch

$$(4) \quad y_{\tau} = H_{\tau}x_{\tau}.$$

In dieser Gleichung werden die unbeobachtbaren Zustände mit den tatsächlich beobachteten Werten in Zusammenhang gebracht. Gleichung (3) und (4) definieren das Zustandsraummodell.

Wie bereits erwähnt, werden Zustandsraummodelle mit dem Kalman-Filter geschätzt. Dies ist ein rekursives Verfahren, in dem die Informationen sequentiell verarbeitet werden. Der „Trick“ zur Verarbeitung der gemischten Frequenzen besteht darin, dass die Matrix H_{τ} in der Gleichung (4) entsprechend der tatsächlichen Beobachtungen zum Zeitpunkt τ angepasst wird.

In dem gegebenen Beispiel werden beide Zeitreihen zu einem Zeitpunkt τ beobachtet, so dass gilt: $H_{\tau} = I_2$, was einer 2×2 -Einheitsmatrix entspricht. Wird jedoch nur die höhere Frequenz beobachtet, gilt: $H_{\tau} = \begin{bmatrix} 1 & 0 \end{bmatrix}$, d.h. nur die Information der höheren Frequenz wird im rekursiven Kalman-Filter verarbeitet. Die Rekursionsfolge des Kalman-Filters ist in Wohlrabe (2009a) ausführlich dargestellt.

Solche Zustandsraummodelle erlauben es auch, *ex post* die fehlenden Werte der niedrigfrequenten Variablen zu interpolieren und somit z.B. ein Bruttoinlandsprodukt auf Monatsbasis zu erhalten.

Vergleich von MIDAS und VAR-Zustandsraummodellen

Der Ansatz zur Modellierung von gemischten Frequenzen unterscheidet sich fundamental bei den beiden Modellklassen. Während beim MIDAS die niedrigere Frequenz auf die höhere regressiert wird, wird im Rahmen der vektorauto-

regressiven Zustandsraummodelle das komplette System auf der höchsten Frequenz modelliert. Daraus folgt, dass die VAR-Modelle Feedbacks zwischen den Variablen modellieren können, da alle Variablen als endogen betrachtet werden.¹¹

Ein potentiell großer Vorteil von MIDAS gegenüber den VAR-Zustandsraummodellen ist ihre Sparsamkeit. Im einfachsten Modell müssen nur vier Parameter (zwei Ge-

¹¹ Weiterentwicklungen von MIDAS-Modellen erlauben auch eine Vektorspezifikation mit Feedback, siehe Ghysels, Sinko und Valkanov (2007). In der empirischen Literatur haben sie bisher jedoch keine Anwendung gefunden.

wichtungskoeffizienten, eine Konstante und den Einflussparameter der verzögerten Werte) unabhängig von der Anzahl der Verzögerungen geschätzt werden. Trotzdem wurde in Abbildung 1 gezeigt, dass die Gewichtungsfunktion eine hohe Flexibilität aufweist und in der Lage ist, eine Vielzahl dynamischer Strukturen zu modellieren. Im Gegensatz dazu steigt die Anzahl der geschätzten Parameter bei den VAR-Zustandsmodellen mit der Anzahl der Verzögerungen an. Diese Parameterproliferation führt einerseits zu einer verstärkten Schätzunsicherheit, zum anderen erhöht sie die Berechnungszeit zur Schätzung des Modells.

Der Modellierungsunterschied kommt vor allem bei der Mischung von sehr hochfrequenten mit niedrigfrequenten Variablen zum Tragen. Werden z.B. Tages- mit Jahresdaten gemischt ($m = 360$) und ein Jahr soll verzögert modelliert werden, dann müssen im einfachsten MIDAS-Modell weiterhin nur vier Parameter geschätzt werden, während dies im Hyang-Granger-Modell 1 440 Parameter wären. Dies ist praktisch jedoch kaum mehr durchführbar.

Eine zentrale Annahme von MIDAS ist, dass die Beobachtungen zeitäquidistant gesampelt sind, d.h., der Zusammenhang (dargestellt durch Parameter m) zwischen den Frequenzen muss über die Zeit konstant sein. Diese Annahme ist vor allem problematisch, wenn Tages- mit Monatsdaten gemischt werden. So ist die Anzahl der (Handels-)Tage im Monatsverlauf über das Jahr nicht konstant. Diese Tatsache muss bei der Modellierung von MIDAS-Modellen berücksichtigt werden. Darüber hinaus ist es schwieriger, Aspekte wie Messfehler, Revisionen und Publikationsverzögerungen abzubilden. Die VAR-Zustandsraummodelle sind dagegen flexibler. Sie können jegliche Datenstruktur verarbeiten, da bei der Schätzung des Modells jeweils nur der Kalman-Filter für die tatsächlich beobachtbaren Variablen angepasst werden muss.

Ein weiterer Unterschied zwischen den Modellklassen besteht in der Berechnung der Prognosen. In der MIDAS-Modellklasse werden die Prognosen immer direkt berechnet. Daraus folgt, dass für jeden Prognosehorizont ein neues Modell spezifiziert und geschätzt werden muss. Die VAR-Zustandsraummodelle berechnen die Prognosen iterativ, so dass eine Neuspezifizierung für die Prognosehorizonte nicht notwendig ist. Vom theoretischen Standpunkt aus ist es nicht eindeutig, ob das direkte oder das iterative Verfahren genauere Prognosen liefert. Diese Beurteilung kann immer nur aufgrund der konkreten Datensituation erfolgen.¹²

¹² Für eine systematische Untersuchung zwischen direkten und indirekten Prognosen für Standardzeitreihenmodelle siehe Marcellino, Stock und Watson (2006).

Weitere Modellierungsansätze

Neben den drei vorgestellten Modellklassen gibt es noch weitere Verfahren, die den Aspekt der gemischten Frequenzen berücksichtigen. In diesem Abschnitt sollen diese kurz vorgestellt werden, für Details sei wieder auf Wohlrabe (2009a) verwiesen.

Ein sehr früher Ansatz geht auf die Idee zurück, Prognosen sowohl für die niedrigere als auch die höhere Frequenz zu berechnen und diese dann zu kombinieren. Dass die Kombination von Prognosen oft zu besseren Resultaten führt als die aus einem einzelnen Modell, ist in der Literatur bekannt.¹³ Die Idee, Prognosen auf Basis verschiedener Frequenzen zu kombinieren, geht auf Greene, Howrey und Hymanns (1986) zurück. Dieser Ansatz wurde jedoch in der Literatur nicht weiter verfolgt. Die letzte Anwendung dieser Methode ist in Shen (1996) zu finden.

Neben den VAR-Zustandsraummodellen gibt es noch weitere Anwendungen, die auf Zustandsraummodelle zugreifen. In einem bedeutenden Aufsatz zeigten Stock und Watson (1989), wie mit Hilfe dieser Modellklasse ein unbeobachtbaren Zustand einer Volkswirtschaft auf Basis mehrerer Zeitreihen extrahiert werden kann. Mariano und Mursawa (2003) erweiterten die Idee unter Nutzung von Variablen unterschiedlicher Frequenz. Diese Idee ist dann u.a. von Nunes (2005) und Evans (2005) angewendet und ausgebaut worden. Arouoba, Diebold und Scotti (2009) demonstrieren, inwieweit es möglich ist, den (unbeobachtbaren) Zustand einer Volkswirtschaft auf Tagesbasis nachzuvollziehen. Aufbauend auf Zustandsraummodellen zeigen die Autoren jedoch, dass die Mischung von Tages-, Wochen-, Monats- und Quartalszeitreihen sehr rechenintensiv ist. Die Extraktion eines unbeobachtbaren Zustandes einer Volkswirtschaft dient vor allem der Erkennung und Prognose von Wendepunkten in Echtzeit.

Empirische Prognoseevidenz

Bisher gibt es wenig empirische Evidenz, da die Modelle noch relativ neu sind. Im Folgenden soll kurz die bisherige empirische Prognoseevidenz vorgestellt werden. Da die Literatur relativ jung ist, gibt es bisher kaum Vergleiche zwischen den Modellklassen. So sind z.B. die Brückengleichungen bisher nicht mit den MIDAS und den VAR-Zustandsraummodellen verglichen worden (außer in Wohlrabe (2009a; b)). Die beiden letzteren sind nur in Kuzin, Marcellino und Schumacher (2009b) und Wohlrabe (2009a) Bestandteil von Vergleichen gewesen. Primär wurde jeweils eine Modellklas-

¹³ Siehe z.B. Timmermann (2006) für einen Überblick und Referenzen. Henzel und Mayr (2009) zeigen, unter welchen Bedingungen Prognosekombinationen einzelnen Prognosen überlegen sind.

se mit einem Standardzeitreihenmodell verglichen. Alle Vergleiche besitzen die Gemeinsamkeit, dass sie zeigen, dass im Durchschnitt die vorgestellten Methoden genauere Prognosen liefern als die Standardmodelle.

Die empirische Literatur über Brückengleichungen verwendet vor allem amerikanische und europäische Daten. Die Mehrheit der Ansätze modelliert eine angebotsseitige Brückengleichung, d.h., das BIP wird als einzige Brückengleichung spezifiziert. Die nachfrageseitige Modellierung, in der das BIP als Summe seiner Komponenten berechnet wird, findet sich z.B. in Parigi und Schlitzer (1995), Golinelli und Parigi (2007) oder Baffigi, Golinelli und Parigi (2004).

Amerikanische BIP-Kurzfristprognosen mit Hilfe von Brückengleichungen finden sich unter anderem in Trehan (1989; 1992), Trehan und Ingenito (1996), Fitzgerald und Miller (1989), Kitchen und Monaco (2003). Für Europa sei neben den bereits genannten nachfrageseitigen Modellierungen u.a. auch auf Rünstler und Sedillot (2003)¹⁴, Diron (2006), Hülsewig, Mayr und Sorbe (2007) und Golinelli und Parigi (2008) verwiesen.

Die Anwendungen der MIDAS-Modelle konzentrierten sich zunächst nur auf Finanzmarktdaten (Prognose von Returns und Varianzen) und auf Hochfrequenzzeitreihen (z.B. Fünfminuten- oder Tagesdaten), siehe z.B. Ghysels, Sinko und Valkanov (2007) oder Forsberg und Ghysels (2007). Die erste makroökonomische Prognose mit MIDAS-Modellen geht auf Clements und Galvao (2008) zurück. Auf Basis US-amerikanischer Daten zeigen die Autoren, dass insbesondere in der kurzen Frist MIDAS die Standardmodelle in ihrer Prognosegüte übertrifft. Marcellino und Schumacher (2007) kombinieren Faktormodelle mit MIDAS (Factor-MIDAS) und wenden diese auf deutsche Daten an. Hogrefe (2008) zeigt mit Hilfe von MIDAS-Modellen, wie Revisionen des amerikanischen BIPs besser prognostiziert werden können. Weitere makroökonomische Anwendungen finden sich in Kuzin, Marcellino und Schumacher (2009a) und Clements und Galvao (2009).

Die VAR-Zustandsraummodelle wurden zuerst von Zadrozny (1990) für die US-Wirtschaft angewendet. Der Autor demonstriert, dass mit Hilfe von Arbeitslosenzahlen das BIP besser prognostiziert werden kann als mit dem Standardmodell. Mitnik und Zadrozny (2005) zeigten, wie mit Hilfe von ifo-Indikatoren die Prognose des deutschen BIP-Wachstums verbessert werden kann. Hyung und Granger (2008) nutzen die Industrieproduktion, um eine Kurzfristprognose des US-BIP im laufenden Quartal zu berechnen.

Kuzin, Marcellino und Schumacher (2009b) vergleichen MIDAS mit dem VAR-Zustandsraummodell auf Basis von Daten für das Eurogebiet. Die Autoren zeigen, dass MIDAS tendenziell in der kurzen Frist eine bessere Prognosegüte hat, während dies für die VAR-Zustandsraummodelle eher in der langen Frist gilt.

Für eine ausführliche Darstellung der empirischen Evidenz bzgl. der Prognose mit gemischten Frequenzen sei auf Wohlrabe (2009a) verwiesen.

Eine Fallstudie für Deutschland¹⁵

Abschließend soll die Prognosegüte der drei vorgestellten Verfahren in einer kleinen Fallstudie für Deutschland verglichen werden. Die Zielvariable ist die jährliche Wachstumsrate des Bruttoinlandsproduktes in Deutschland. Als monatliche Indikatoren werden das ifo Geschäftsklima und der ZEW-Indikator verwendet. Die beiden Indikatoren für die deutsche Wirtschaft unterliegen keiner Revision. Es werden Daten von 1992 bis 2007 verwendet. Alle Zeitreihen sind standardisiert, um den Schätzaufwand (insbesondere für die VAR-Zustandsraummodelle) zu verringern.

Als Standard-Benchmark-Modell wird ein autoregressiver Prozess (AR) ohne exogene Variablen (wie z.B. vorlaufende Indikatoren) verwendet. Der zweite Wettbewerber ist ein VAR, basierend auf Quartalsdaten. In diesem werden die Monatsdaten per Durchschnittsbildung auf Quartalsebene aggregiert. Solche Benchmark-Modelle dienen dem Zweck, die Leistungsfähigkeit neuer Verfahren unter Beweis zu stellen.

Der Prognosevergleich erfolgt in einem so genannten pseudo-out-of-sample Wettbewerb. D.h., der Schätz- und Prognosezeitraum wird virtuell in die Vergangenheit verlegt. Dabei werden nur Informationen verwendet, die zu dem jeweiligen Zeitpunkt zur Verfügung standen. Ziel solcher Wettbewerbe ist es, die Prognosegüte auf einer möglichst großen Anzahl von Prognose beurteilen zu können.

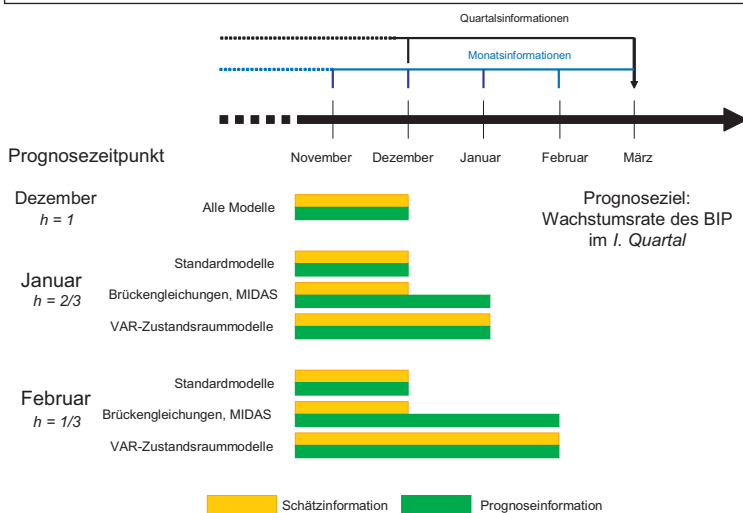
Abbildung 2 stellt die Prognosesituation mit gemischten Frequenzen beispielhaft für die Prognose des ersten Quartals dar. Da von Publikationsverzögerungen und Revisionen abstrahiert wird, wird davon ausgegangen, dass das Bruttoinlandsprodukt Ende März zur Verfügung steht.

Die Standardmodelle mit Quartalsdaten verwenden sowohl für die Schätzung als auch die Prognose Informationen, die bis zum vierten Quartal des Vorjahres vorliegen.¹⁶ Das

¹⁴ Rünstler und Seillot (2003) untersuchen auch eingehend die Prognosegüte der Indikatoren für die Brückengleichungen mit verschiedenen Verfahren, während viele andere Artikel keine Angaben über diesen Punkt machen.

¹⁵ Eine ausführliche Fallstudie für Deutschland findet sich in Wohlrabe (2009b).
¹⁶ Würden die Publikationsverzögerungen des Bruttoinlandsproduktes in den Schätzungen berücksichtigt, wäre es auch möglich Informationen aus dem ersten Quartal zu verwenden.

Abb. 2
Prognosemodell mit gemischten Frequenzen



Quelle: Darstellung des ifo Instituts.

MIDAS-Modell nutzt für die Schätzung Informationen bis zum vierten Quartal des Vorjahres, für die Prognose jedoch auch Werte aus dem Januar und Februar. Gleiches gilt für die Brückengleichungen. Das VAR-Zustandsraummodell nutzt alle zur Verfügung stehenden Informationen sowohl für die Schätzung als auch die Prognose. Das kann unter Umständen in wirtschaftlichen Wendephasen zu genaueren Prognosen im Vergleich zum MIDAS-Modell führen, da alle Informationen für die Schätzung verwendet werden.

Abbildung 2 zeigt den Vorteil der Modelle mit gemischten Frequenzen, der darin besteht, dass Informationen, die im laufenden Quartal verfügbar werden, sowohl für die ökonomische Schätzung als auch für die Prognose verwendet werden. Daraus resultiert die mögliche höhere Prognosequalität dieser Modelle.

Die erste Prognose wird für das erste Quartal 2000 berechnet. Der Schätzzeitraum wird immer weiter vergrößert, bis das vierte Quartal 2007 prognostiziert wurde. Dies wird als rekursive Schätzung bezeichnet. Bei diesem Verfahren vergrößert sich der Schätzzeitraum über die Rekursionen.¹⁷

Die Modellspezifikation für die Standardmodelle, die Brückengleichungen und das VAR-Zustandsraummodell erfolgt durch die Minimierung des Akaike-Informationskriteriums (AIC). Bei der Berechnung der Prognosen mit Brückengleichungen wird ein AR-Modell zur Berechnung der fehlenden monatlichen Monate im Quartal verwendet.

Die Modellspezifikation für die MIDAS-Modellklasse wird bisher in der Literatur vernachlässigt. Da durch die Aufnahme zusätzlicher Verzögerungen in die Schätzgleichung keine »Kosten«, entstehen (z.B. durch zusätzliche zu schätzende Parameter), lässt sich die Frage nach der konkreten Anzahl von Lags nicht beantworten. In unserem Beispiel verwenden wir zwölf Monate ($K = 12$).¹⁸ Ein weiterer wichtiger Punkt ist, ob die Gewichtungsfunktion restringiert werden soll oder nicht. In Abbildung 1 wurde gezeigt, dass der Verlauf der Gewichtungsfunktion sehr vielfältig ausfallen kann. Für den Prognostiker mag es jedoch unplausibel erscheinen, warum z.B. die Gewichte mit Anzahl der Verzögerungen ansteigen sollten (Panel B). Vielmehr lässt sich vermuten, dass die jüngsten Informationen den größten Einfluss auf die Prognose haben. In dieser Fallstudie wird die MIDAS-Gewichtsfunktion sowohl restringiert

(auf fallende Gewichte) und als auch unrestringiert geschätzt. Wohlrabe (2009c) diskutiert ausführlich den Aspekt der Restriktion der Gewichtungsfunktion und die Wahl der Anzahl der Verzögerungen sowohl für MIDAS als auch VAR-Zustandsraummodelle.

Die Beurteilung der Anpassungsgüte der Prognosen basiert auf dem RMSE (root mean squared error), welcher die Wurzel des mittleren quadratischen Prognosefehlers beschreibt:

$$RMSE_h = \sqrt{\frac{1}{T_2 - T_1 + 1} \sum_{t=T_1}^{T_2} (y_{t+h} - \hat{y}_{t+h})^2}$$

Der RMSE für den jeweiligen Prognosehorizont h berechnet sich auf Basis der einzelnen Prognosefehler zum Zeitpunkt t , also der Differenz aus dem prognostizierten Wert \hat{y}_{t+h} und dem tatsächlichen Wert der Variable y_{t+h} . Da die Prognosefehler sowohl positive als auch negative Werte annehmen können, werden über einen bestimmten Zeitraum hinweg die quadrierten Differenzen zur Berechnung des Gütemaßes verwendet. T_1 stellt den ersten und T_2 den letzten Zeitpunkt der Prognose dar. Mit Hilfe des RMSE können dann verschiedene Prognosen für eine Zielvariable miteinander verglichen werden. Je höher der RMSE einer Prognose ausfällt, umso geringer ist die Güte der Vorhersage.

Tabelle 1 stellt den RMSE für die verschiedenen Modellklassen dar. Die ersten Spalte zeigt den Prognosehorizont in Quartalen. Ein Horizont von $h = 1/3$ impliziert, dass nur noch ein Monat zur Vollendung des Quartals fehlt,

¹⁷ Das Pendant zur rekursiven Schätzung heißt rollierende Schätzungen, bei welchem der Schätzzeitraum konstant bleibt.

¹⁸ Die Ergebnisse für andere Anzahl von verzögerten Monaten unterscheiden sich nur geringfügig.

Tab. 1
RMSE für die verschiedenen Modellklassen

Prognosehorizont h	AR	VAR-Modelle		Brückengleichungen		MIDAS unrestringiert		MIDAS restringiert		VAR-Zustandsraummodelle	
		ifo	ZEW	ifo	ZEW	ifo	ZEW	ifo	ZEW	ifo	ZEW
$1/3$				0.52	0.86	0.62	0.69	0.61	0.54	0.49	0.52
$2/3$				0.54	0.91	0.62	0.88	0.62	0.61	0.49	0.61
1	0.78	0.59	0.69	0.58	1.00	0.72	0.95	0.63	0.69	0.50	0.64
2	0.95	0.74	0.81			1.04	1.12	0.70	0.97	0.58	0.79
3	1.01	0.93	0.94			1.19	1.22	1.06	1.18	0.64	0.79
4	1.05	1.11	1.07			1.23	1.22	1.16	1.21	0.70	1.01

Quelle: Berechnungen des ifo Instituts.


d.h., man befindet sich z.B. Februar im ersten Quartal (vgl. Abb. 2).

Zunächst zeigt sich, dass das Standardmodell für beide Indikatoren bis zu einem Prognosehorizont von drei Quartalen eine bessere Prognosegüte liefert als das AR-Modell. Dies bedeutet, dass die verwendeten Indikatoren einen Erklärungs- und Prognosegehalt für das deutsche Bruttoinlandsprodukt besitzen. Die Tabelle zeigt auch, dass mit den

Standardmodellen keine Prognose innerhalb des Quartals möglich ist. Für $h = 1/3$ und $h = 2/3$ sollten die Modelle mit gemischten Frequenzen den RMSE für $h = 1$ der Standardmodelle unterbieten.

Betrachtet man zusätzlich die Brückengleichungen, so zeigt sich, dass die Qualität der Intra-Quartalsprognose mit Hilfe des ifo Geschäftsklimas sich weiter verbessert, während sie sich für das ZEW verschlechtert. Die Ergebnisse für die

Abb. 3
Durchschnittlich geschätzte MIDAS-Gewichtsfunktionen



MIDAS-Modelle zeichnen ein heterogenes Bild. Für den ZEW-Indikator im restringierten Fall ergibt sich eine Verbesserung, während im unrestringierten Fall eine Verschlechterung eintritt im Vergleich zum VAR-Modell für $h = 1$. Für den ifo-Indikator ergeben sich in beiden Fällen für $h = 1/3$ und $h = 2/3$ marginale Verschlechterungen im Vergleich zum VAR-Modell. Dieses Beispiel zeigt, dass die Evaluierung eines Indikators auch von der Modellwahl abhängen kann.

Die im Durchschnitt besten Prognosen liefern die VAR-Zustandsraummodelle. Für beide Indikatoren ist mit diesem Modell die Prognosegüte für alle betrachteten Horizonte und Modell/Indikatorkombinationen besser. Das VAR-Zustandsraummodell mit dem ifo Geschäftsklima liefert die höchste Prognosequalität über alle Horizonte. In diesem Zusammenhang zeigt sich, dass Prognosen für größere Horizonte auf Basis gemischter Frequenzen besser sein können.

Zum Abschluss sollen die geschätzten Gewichtsfunktionen illustriert werden. Zu diesem Zweck wird der Durchschnitt der geschätzten Gewichtsfunktionen über alle Iterationen gebildet. Abbildung 3 stellt diese sowohl für die restringierte als unrestringierte Gewichtsfunktion jeweils für $h = 1/3$ und $h = 4$ dar. Im Panel A sind die Gewichte der Indikatoren nahezu identisch. Es zeigt sich, dass nahezu das komplette Gewicht auf den ersten vier verzögerten Monaten liegt, wobei der erste Monat 74% Gewicht auf sich vereint. Das heißt, ein Großteil der Information für die Prognose basiert auf der neuesten zur Verfügung stehenden Information.

Noch ausgeprägter ist die Gewichtskonzentration für den entsprechenden unrestringierten Fall, in dem sowohl für das ifo Geschäftsklima als auch den ZEW-Indikator mehr als 90% des Gewichts dem ersten verzögerten Monat zugewiesen werden. Es zeigt sich, dass auch in der unrestringierten Alternative fallende Gewichte aus den Daten geschätzt werden. Insgesamt bestätigt sich die *A-priori*-Erwartung, dass für die Kurzfristprognose die neusten verfügbaren Informationen den größten Anteil haben.

Die Ergebnisse für die Einjahresprognose zeichnen ein anderes Bild. Für den restringierten Fall verteilen sich die Gewichte jetzt fallend auf alle zwölf verzögerten Monate. Im unrestringierten Fall ergibt sich ein heterogenes Bild. Für beide Indikatoren sind dem ersten verzögerten Monat zunächst zwischen 15% und 24% zugewiesen. Danach fällt für beide der Anteil dramatisch ab (auf etwa 3%), um danach für das ifo Geschäftsklima einen Hügel zu beschreiben und für den ZEW-Indikator am Ende wieder auf etwa 25% anzusteigen.

Zusammenfassung

Die (Kurzfrist-)Prognose makroökonomischer Kenngrößen mit Standardzeitreihenmodellen, insbesondere des Brutto-

inlandsproduktes, sieht sich oft dem Problem gegenüber, dass viele Indikatoren auf einer höheren Frequenz erhoben werden als die Zielreihe. Die Aggregation der Indikatoren führt zu einem Informationsverlust. Zudem ist es nicht möglich, die Informationen, die innerhalb eines Quartals veröffentlicht werden, in die Prognose einfließen zu lassen.

Der vorliegende Artikel stellt zwei neue Verfahren vor, die am ifo Institut für die Konjunkturprognosen verwendet werden und eine Schätzung mit gemischten Frequenzen erlauben: MIDAS-Modelle und VAR-Zustandsraummodelle. In einer kleinen Fallstudie für Deutschland wurde demonstriert, wieso insbesondere in der kurzen Frist (innerhalb eines Quartals) die Prognosegüte des Bruttoinlandsproduktes, verbessert werden kann. Auch für langfristige Prognosen sind die neuen Modelle teilweise den Standardmodellen überlegen, da die Zeitreihen nicht transformiert werden müssen und somit keine Informationen verlorengehen.

Die weitere Forschung mit diesen Modellklassen beschäftigt sich u.a. damit, inwieweit Hochfrequenzzeitreihen (z.B. Tagesdaten) für die Prognose verwendet werden können.

Literatur

- Angelini, E., J. Henry und M. Marcellino (2006), »Interpolation and backdating with a large information set«, *Journal of Economic Dynamics and Control* 30(12), 2693–2724.
- Aruoba, S., F. Diebold und C. Scotti (2009), »Real-Time Measurement of Business Conditions«, *Journal of Business and Economic Statistics* 27(4), 417–427.
- Baffigi, A., R. Golinelli und G. Parigi (2004), »Bridge models to forecast the Euro area GDP«, *International Journal of Forecasting* 20(3), 447–460.
- Chow, G. und A. Lin (1971), »Best linear unbiased interpolation, distribution, and extrapolation of time series by related series«, *The Review of Economics and Statistics* 53(4), 372–375.
- Clements, M.P. und A.B. Galvao (2008), »Macroeconomic forecasting with mixed-frequency data«, *Journal of Business and Economic Statistics* 26(4), 546–554.
- Clements, M.P. und A.B. Galvao (2009), »Forecasting US output growth using leading indicators: An appraisal using MIDAS models«, *Journal of Applied Econometrics* 24(7), 1187–1206.
- Diron, M. (2006), »Short-term forecasts of Euro area real GDP growth – An Assessment of real-time performance based on vintage data«, ECB Working Paper No. 622.
- Durbin, J. und S. Koopman (2001), *Time series analyses by state space methods*, Oxford University Press, New York.
- Evans, M. (2005), »Where are we now? Real-time estimates of the macro-economy«, *International Journal of Central Banking* 1(2), 127–175.
- Fitzgerald, T. und P. Miller (1989), »A simple way to estimate current-quarter GNP«, *Federal Reserve Bank of Minneapolis Quarterly Review* 13(Fall), 27–31.
- Forsberg, L. und E. Ghysels (2007), »Why do absolute returns predict volatility so well?«, *Journal of Financial Econometrics* 5(1), 31–67.
- Ghysels, E., P. Santa-Clara und R. Valkanov (2004), »The MIDAS touch: Mixed Data Sampling regression models«, mimeo Chapel Hill, N.C.
- Ghysels, E., A. Sinko und R. Valkanov (2007), »MIDAS regressions: Further results and new directions«, *Econometric Reviews* 26(1), 53–90.
- Ghysels, E. und R. Valkanov (2006), »Linear time series processes with mixed data Sampling and MIDAS regressions models«, mimeo, Chapel Hill, N.C.
- Golinelli, R. und G. Parigi (2007), »The use of monthly indicators to forecast quarterly GDP in the short-run: An application to the G7 countries«, *Journal of Forecasting* 26, 77–94.
- Greene, M., E. Howrey und S. Hymans (1986), »The use of outside information in econometric forecasting«, in: D. Belsely und E. Kuh (Hrsg.), *Model Reliability*, MIT Press, Cambridge MA., 90–116.

- Harvey, A.C. (1989), *Forecasting, structural time series and the Kalman Filter*, Cambridge University Press, Cambridge MA.
- Henzel, S. und J. Mayr (2009), »The Virtues of VAR Forecast Pooling – A DSGE Model Based Monte Carlo Study«, *Ifo Working Paper* Nr. 65.
- Hogrefe, J. (2008), »Forecasting data revisions of GDP: A mixed frequency approach«, *Advances in Statistical Analysis* 92(3), 271–296.
- Hülsewig, O., J. Mayr und S. Sorbe (2007), »Assessing the Forecast Properties of the CESifo World Economic Climate Indicator: Evidence for the Euro Area«, *Ifo Working Paper* Nr. 46.
- Hyung, N. und C. Granger (2008), »Linking series generated at different frequencies«, *Journal of Forecasting* 27(2), 95–108.
- Kitchen, J. und R. Monaco (2003), »Real-time forecasting in practice: The US Treasury Staff's real-time GDP forecast system«, *Business Economics*, 10–19.
- Koenig, E., S. Dolmas und J. Piger (2003), »The use and abuse of real-time data in economic forecasting«, *Review of Economics and Statistics* 85(3), 618–628.
- Kurzin, V., M. Marcellino und C. Schumacher (2009a), »Pooling versus model selection for nowcasting with many predictors: An application to German GDP«, Bundesbank Discussion Paper 03/2009.
- Kurzin, V., M. Marcellino und C. Schumacher (2009b), »MIDAS vs. Mixed-frequency VAR: Nowcasting GDP in the Euro Area«, *International Journal of Forecasting*, im Druck.
- Marcellino, M. und C. Schumacher (2007), »Factor nowcasting of German GDP with ragged-edge data. A model comparison using MIDAS projections«, Bundesbank Discussion Paper, Series 1 No. 34.
- Marcellino, M., J. Stock und M. Watson (2006), »A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series«, *Journal of Econometrics* 135(1–2), 499–526.
- Mariano, R. und Y. Murasawa (2003), »A new coincident index of business cycles based on monthly and quarterly series«, *Journal of Applied Econometrics* 18(4), 427–443.
- Mitnik, S. und P. A. Zadrozny (2005), »Forecasting quarterly German GDP at monthly intervals using monthly Ifo business conditions data«, in: J.-E. Sturm und T. Wollmershäuser (Hrsg.), *Ifo survey data in business cycle and monetary policy analysis*, Physica-Verlag, Heidelberg, 19–48.
- Nunes, L. (2005), »Nowcasting quarterly GDP growth in a monthly coincident indicator model«, *Journal of Forecasting* 24(8), 575–592.
- Parigi, G. und G. Schlitzer (1995), »Quarterly forecasts of the Italian business cycle by means of monthly indicators«, *Journal of Forecasting* 14(2), 117–141.
- Robinsonov, N. und K. Wohlrabe (2010), »Freedom of Choice in Macroeconomic Forecasting«, *CESifo Economic Studies*, im Druck.
- Rünstler, G. und F. Sedillot (2003), »Short-term estimate of Euro area real GDP growth by means of monthly indicators«, European Central Bank Working Paper No. 276.
- Seiler, C. (2009), »Prediction Qualities of the Ifo Indicators on a Temporal Disaggregated German GDP«, *Ifo Working Paper* Nr. 67.,
- Shen, C. (1996), »Forecasting macroeconomic variables using data of different periodicities«, *International Journal of Forecasting* 12(2), 269–282.
- Stock, J. und M. Watson (1989), »New indexes of coincident and leading indicators«, *NBER Macroeconomics Annual* 4, 351–394.
- Timmermann, A. (2006), »Forecast combinations«, in: C. Granger, G. Elliott und A. Timmermann (Hrsg.), *Handbook of Economic Forecasting*, North Holland, Amsterdam, 135–196.
- Trehan, B. (1989), »Forecasting growth in current quarter real GNP«, *Federal Reserve Bank of San Francisco Economic Review*, Winter, 39–51.
- Trehan, B. (1992), »Predicting contemporaneous output«, *Federal Reserve Bank of San Francisco Economic Review* 2, 3–11.
- Trehan, B. und R. Ingenito (1996), »Using monthly data to predict quarterly output«, *Federal Reserve Bank of San Francisco Economic Review* (3), 3–11.
- Wohlrabe, K. (2009a), *Forecasting with mixed frequency time series models*, Inaugural-Dissertation, Ludwig-Maximilians-Universität München, 2009.
- Wohlrabe, K. (2009b), »Forecasting with mixed frequency time series models: A case study for Germany«, mimeo.
- Wohlrabe, K. (2009c), »Specification issues in mixed-frequency time series models«, mimeo.
- Zadrozny, P.A. (1988), »Gaussian-Likelihood of continuous-time ARMAX models when data are stocks and flows at different frequencies«, *Econometric Theory* 4(1), 108–124.
- Zadrozny, P.A. (1990), »Estimating a multivariate ARMA model with mixed-frequency data: An application to forecasting U.S. GNP at monthly intervals«, Federal Reserve Bank of Atlanta Working Paper Series No. 90-6.