

Analyse

Zur Prognosegüte alternativer Konjunkturindikatoren

Zur Prognosegüte alternativer Konjunkturindikatoren

1. Motivation

744. Zur Unterstützung der Konjunkturanalyse und -prognose werden regelmäßig Konjunkturindikatoren herangezogen, um mit ihrer Hilfe die zukünftige wirtschaftliche Entwicklung besser abschätzen zu können. Generell sollte ein Konjunkturindikator in der Lage sein, die zukünftige Entwicklung der vorherzusagenden Variablen mit einem möglichst weiten und stabilen Vorlauf vorwegzunehmen und frühzeitig auf Besonderheiten im Konjunkturverlauf hinzuweisen, wie bevorstehende Wendepunkte anzukündigen. In der Praxis findet eine Reihe verschiedener Konjunkturindikatoren Verwendung, die entweder realwirtschaftlicher oder monetärer Natur sind und sowohl auf Daten der amtlichen Statistik als auch auf Umfrageergebnissen beruhen. Mitunter werden unterschiedliche Indikatoren kombiniert, um auf diese Weise bessere Prognoseeigenschaften zu erreichen.

745. In der Regel werden Konjunkturindikatoren auf Monatsbasis ermittelt. Die Referenzreihe, also die zu prognostizierende Reihe, sollte daher – im Idealfall – ebenfalls monatlich zur Verfügung stehen. Traditionell wird als Referenzreihe die (saisonbereinigte) Nettoproduktion der Industrie gewählt, da sie monatlich zur Verfügung steht. Eine Beschränkung auf die Nettoproduktion ist allerdings nicht zwingend, da eine Reihe von Konjunkturindikatoren mit dem Ziel konstruiert wurde, der am Bruttoinlandsprodukt gemessenen gesamtwirtschaftlichen Entwicklung voraus zu laufen. Allerdings liegen die Daten der Volkswirtschaftlichen Gesamtrechnungen, und damit die Zuwachsrate des Bruttoinlandsprodukts, lediglich vierteljährlich vor. Die Entwicklung des Bruttoinlandsprodukts lässt sich somit nicht unmittelbar mit Hilfe monatlicher Konjunkturindikatoren voraussagen. Eine Bildung von Quartalswerten aus monatlichen Indikatoren ist ohne Weiteres möglich, bedeutet jedoch einen Informationsverlust in zweierlei Hinsicht: Zum einen gehen durch die Aggregation direkt Informationen verloren, zum anderen stehen für die ökonometrische Schätzung des Prognosemodells und für die anschließende Bewertung der Prognosen – für eine gegebene Zeitspanne – weniger Datenpunkte (Freiheitsgrade) zur Verfügung, was sowohl die Qualität der Schätzung als auch die Qualität der statistischen Analyse der Prognosegüte beeinträchtigen dürfte. Es mag vor diesem Hintergrund nicht sonderlich verwundern, dass eine Vielzahl von Studien die Vorlaufeigenschaften alternativer Konjunkturindikatoren mit Blick auf die Industrieproduktion untersucht (Wolters und Lankes, 1989; Döpke et al., 1994; Breitung und Jagodzinski, 2001; Hüfner und Schröder, 2002; Dreger und Schumacher, 2005; Benner und Meier, 2004).

Obschon die Industrie weniger als ein Viertel zur gesamten Bruttowertschöpfung beiträgt, wird die gesamtwirtschaftliche Entwicklung mittels der Nettoproduktion der Industrie gut abgebildet. Die Industrie kann noch immer als „Zyklusmacher“ angesehen werden. So besteht eine vergleichsweise hohe Korrelation zwischen den Zuwachsraten der Nettoproduktion (auf Quartalsebene) und des Bruttoinlandsprodukts. Einzelne Studien kommen daher zum Ergebnis, dass die Beurteilung der Prognosefähigkeit vorlaufender Konjunkturindikatoren weitgehend unabhängig davon ist, ob die Nettoproduktion der Industrie oder das Bruttoinlandsprodukt als Referenzreihe gewählt wird (Hinze, 2003). Ungünstige Prognoseeigenschaften eines Konjunkturindikators bei der Prognose

der Industrieproduktion bedingen nicht zwangsläufig eine geringe Prognosegüte hinsichtlich des Bruttoinlandsprodukts.

Letztlich stellt sich im Rahmen der Konjunkturanalyse nur bedingt die Frage, welche der beiden Reihen als Referenz zu wählen ist. Wegen der monatlichen Veröffentlichungsweise hat die Produktionsstatistik primär Bedeutung für die kurzfristige Konjunkturanalyse, während das Bruttoinlandsprodukt ein umfassenderes Abbild des wirtschaftlichen Geschehens ermöglicht. Allerdings liegen die Angaben aus den Volkswirtschaftlichen Gesamtrechnungen erst mit einer gewissen zeitlichen Verzögerung vor. So besitzen bereits Einschätzungen zur aktuellen konjunkturellen Situation angesichts der zu diesem Zeitpunkt unvollständigen Datenlage prognostischen Charakter. Beide wirtschaftlichen Referenzreihen ergänzen sich daher, die Wahl der adäquaten Referenzreihe ist insbesondere vom Prognosehorizont abhängig.

746. In der nachfolgenden Analyse werden einige ausgewählte Konjunkturindikatoren auf ihre (kurzfristige) Prognosegüte hin untersucht, die speziell zum Zweck der Konjunkturprognose konstruiert wurden und die in der breiten Öffentlichkeit große Aufmerksamkeit genießen. Dies sind insbesondere die vom Münchner ifo-Institut publizierten Konjunkturtest-Ergebnisse. Sie beruhen auf monatlichen Umfragen bei über 7 000 Unternehmen der gewerblichen Wirtschaft. Daneben wird seit Anfang der neunziger Jahre der vom Zentrum für Europäische Wirtschaftsforschung (ZEW), Mannheim, ermittelte Index der Konjunkturerwartungen, der sich aus der monatlichen Befragung von über 300 Finanzanalysten nach ihrer Einschätzung der zukünftigen Entwicklung ableitet, sehr aufmerksam verfolgt. Ergänzend hierzu veröffentlichen eine Reihe von Zeitungen eigene Konjunkturindikatoren. Hierzu zählen beispielsweise der Konjunkturindikator der Frankfurter Allgemeinen Zeitung (FAZ) sowie der Handelsblatt-Frühindikator (in der Konstruktion, wie er bis Ende des Jahres 2004 vorlag). Neben diesen zusammengesetzten Indikatoren werden vielfach lediglich einzelne Zeitreihen als Konjunkturindikatoren verwendet, wie zum Beispiel Auftragseingänge oder Zinsdifferenzen.

747. Verschiedene empirische Untersuchungen haben den Informationsgehalt alternativer Konjunkturindikatoren für die Prognose der deutschen Industrieproduktion überprüft, wobei insbesondere den ifo-Geschäftserwartungen und den ZEW-Konjunkturerwartungen große Aufmerksamkeit beigemessen wurde. Dabei kommen die verschiedenen Studien zu uneinheitlichen Ergebnissen: Je nach Studie weisen die betrachteten Konjunkturindikatoren unterschiedliche Prognosefähigkeiten auf. Mitunter kommen die genannten Studien darüber hinaus zum Ergebnis, dass Prognosemodelle, die jeweils einen der genannten Indikatoren einbeziehen, häufig nicht bessere Prognosen liefern als so genannte naive Prognosen, die allein auf der Historie der zu prognostizierenden Größe beruhen.

748. Die bislang vorliegenden Analysen geben jedoch keine eindeutigen Hinweise darauf, ob ein spezifischer Konjunkturindikator, sei es ein Einzelindikator oder ein zusammengesetzter Indikator, systematisch andere Konjunkturindikatoren in dem Sinne dominiert, dass für unterschiedliche Prognosehorizonte signifikant geringere Prognosefehler zu verzeichnen sind. Der alleinige Vergleich der Prognosefehler lässt dabei die Frage unbeantwortet, inwieweit einzelne Konjunkturindikatoren spezifische Informationen enthalten, die andere Indikatoren entbehren. So lässt sich

zum Beispiel aus dem Befund, dass ein Konjunkturindikator generell eine signifikant bessere Prognosegüte aufweist als ein alternativer Indikator, nicht zwangsläufig ableiten, dass eine Kombination beider Indikatoren zu keiner Verbesserung der Prognosegüte führt. Letztlich ist ein solcher Befund unmittelbar einleuchtend: Spezifische Konjunkturindikatoren decken nur Teilbereiche des wirtschaftlichen Geschehens ab, so dass einzelne Konjunkturindikatoren, die auf unterschiedlichen und sich gegenseitig ausschließenden Informationsmengen beruhen, mitunter widersprechende Signale senden. Beispielsweise basieren die ifo-Ergebnisse allein auf Angaben der gewerblichen Wirtschaft, während die vom ZEW befragten Analysten mehrheitlich im Dienstleistungssektor tätig sind. Wenn nun diese Indikatoren auf unterschiedlichen Informationsmengen beruhen, sollte es prinzipiell für die Konjunkturprognose von Vorteil sein, unterschiedliche Zeitreihen und/oder Konjunkturindikatoren zu kombinieren. Tatsächlich verknüpfen der FAZ-Konjunkturindikator und der Handelsblatt-Frühindikator einige wenige Reihen zu einem (synthetischen) Konjunkturindikator. Ökonomische Intuition lässt erwarten, dass ein auf einer möglichst großen Informationsmenge beruhender Indikator prinzipiell eine höhere Prognosekraft besitzen sollte als Konjunkturindikatoren, die lediglich Teilbereiche der Gesamtwirtschaft abdecken.

749. Im Folgenden wird daher mit Hilfe einer Hauptkomponentenanalyse im Rahmen eines Faktormodells ein Konjunkturindikator abgeleitet, der neben dem ifo- und dem ZEW-Indikator eine Vielzahl zusätzlicher Variablen berücksichtigt. Im Anschluss daran werden dieser synthetische Konjunkturindikator, der nachfolgend als Konjunkturindikator-Faktormodell (KiFa) bezeichnet wird, und die genannten einschlägigen Konjunkturindikatoren auf ihre Prognosegüte hinsichtlich der Nettoproduktion der Industrie überprüft.

2. Konstruktion eines Konjunkturindikators auf Grundlage eines Faktormodells

750. Die grundlegende Idee, einen Konjunkturindikator aus einem Faktormodell abzuleiten, besteht darin, auf Grundlage einer Vielzahl von Variablen, die ein möglichst repräsentatives Bild der gesamtwirtschaftlichen Lage geben, diejenigen unbeobachtbaren Zeitreihen (Faktoren) zu identifizieren, die maßgeblich für die Schwankungen der betrachteten Variablen im Zeitverlauf verantwortlich sind. In den verwendeten Faktormodellen lässt sich jede Variable annahmegemäß als Summe aus einem allen Zeitreihen gemeinsamen Teil darstellen, das heißt einer Linearkombination der Faktoren und einem für die jeweilige Variable typischen Teil, die so genannte idiosynkratische Komponente. Indem simultan eine große Anzahl von Variablen betrachtet wird, diese aber auf wenige Faktoren zurückgeführt werden, kann eine breite Informationsbasis effizient genutzt werden. Die nicht direkt beobachtbaren Faktoren werden hierbei mittels einer Hauptkomponentenanalyse empirisch ermittelt. Ein Vorteil dieses Analyseverfahrens gegenüber einem parametrischen Ansatz besteht insbesondere darin, selbst für eine sehr große Zahl von Variablen die Faktoren konsistent schätzen zu können. Das Ziel der Hauptkomponentenanalyse ist es letztlich, die Faktoren so zu bestimmen, dass sie einen möglichst großen Anteil der Varianz der beobachtbaren Variablen erklären. Dies ist äquivalent dazu, den Anteil der Varianz der idiosynkratischen Schocks zu minimieren.

Für die Schätzung der Faktoren stehen unterschiedliche Verfahren zur Verfügung. In der neueren Literatur werden große Faktormodelle sowohl auf Basis statischer als auch dynamischer Hauptkomponentenanalysen berechnet. Aktuelle empirische Studien, die die Prognoseeigenschaften

dieser unterschiedlichen Techniken der Faktoranalyse untersuchen, lassen erkennen, dass keines der aktuell diskutierten Verfahren zu signifikant besseren Prognoseergebnissen führt (Boivin und Ng, 2005; Schumacher, 2005).

751. In der vorliegenden Klasse von Faktormodellen wird jede Variable X_{it} , $i = 1, \dots, N$; $t = 1, \dots, T$, dargestellt als die Summe von zwei voneinander unabhängigen latenten (unbeobachtbaren) Komponenten: der gemeinsamen Komponente C_{it} und der idiosynkratischen Komponente u_{it} . Hierbei bezeichnet N die Anzahl der in das Faktormodell einbezogenen Variablen und T die Anzahl der betrachteten Zeitpunkte. Die gemeinsame Komponente C_{it} hängt annahmegemäß von q dynamischen Faktoren f_{t1}, \dots, f_{tq} und möglicherweise verzögerten Werten dieser Faktoren ab. Die idiosynkratische Komponente u_{it} steht dagegen für variablenspezifische Schocks. Kennzeichnend für den vorliegenden Analyserahmen ist hierbei, dass die Anzahl der einbezogenen Variablen N größer sein kann als die Anzahl der Beobachtungspunkte T und dass insbesondere die Anzahl der q dynamischen Faktoren deutlich kleiner ist als N . Das dynamische Faktormodell lässt sich formal wie folgt darstellen

$$\begin{aligned} X_{it} &= C_{it} + u_{it} \\ &= \lambda_i(L) \mathbf{f}_t + u_{it}, \end{aligned} \quad (1)$$

$i = 1, \dots, N$; $t = 1, \dots, T$. Hierbei bezeichnen $\mathbf{f}_t = (f_{t1}, \dots, f_{tq})'$ den q -dimensionalen Spaltenvektor der unbeobachtbaren dynamischen Faktoren, L den Lagoperator und $\lambda_i(L)$ das folgende Vektor-Lagpolynom

$$\begin{aligned} \lambda_i(L) \cdot \mathbf{f}_t &= (\lambda_{i1}(L), \dots, \lambda_{iq}(L)) \mathbf{f}_t \\ &= \lambda_{i1}(L) f_{t1} + \dots + \lambda_{iq}(L) f_{tq}, \end{aligned} \quad (2)$$

wobei zusätzlich unterstellt wird, dass die Lagpolynome $\lambda_{ij}(L)$, $j = 1, \dots, q$ jeweils endlich sind und höchstens die Ordnung p besitzen, das heißt $\lambda_{ij}(L) = \lambda_{ij0} + \lambda_{ij1}L + \dots + \lambda_{ijp}L^p$. Zudem wird angenommen, dass die dynamischen Faktoren zu keinem Zeitpunkt mit der idiosynkratischen Komponente korreliert sind, somit gilt $E(f_{tj} \cdot u_{ts}) = 0$ für alle i, j, s, t . Eine Korrelation zwischen den variablenspezifischen idiosynkratischen Komponenten ist hingegen prinzipiell zulässig.

Jede Variable X_{it} lässt sich somit als Summe der Linearkombination der q Faktoren sowie jeweils bis zu p verzögerten Werten dieser Faktoren und der idiosynkratischen Schocks darstellen

$$\begin{aligned} X_{it} &= \lambda_{i1}(L) f_{t1} + \dots + \lambda_{iq}(L) f_{tq} + u_{it} \\ &= (\lambda_{i10} + \lambda_{i11}L + \dots + \lambda_{i1p}L^p) f_{t1} + \dots + (\lambda_{iq0} + \lambda_{iq1}L + \dots + \lambda_{iqp}L^p) f_{tq} + u_{it}. \end{aligned} \quad (3)$$

Das Lagpolynom $\lambda_{ij}(L)$ zeigt somit den Einfluss des j -ten Faktors und dessen p Lags auf die Variable i .

Die Annahme endlicher Lagpolynome $\lambda_{ij}(L)$ ermöglicht es, die dynamische Form des Faktormodells $X_{it} = \lambda_i(L)\mathbf{f}_t + u_{it}$ durch Umformungen in eine statische Form zu transformieren (Dreger und Schumacher, 2004). Das statische Faktormodell lautet dann

$$X_{it} = \Lambda_i \mathbf{F}_t + u_{it}, \quad (4)$$

oder in kompakter Form

$$\mathbf{X}_t = \Lambda \mathbf{F}_t + \mathbf{u}_t, \quad (5)$$

$t = 1, \dots, T$. Hierbei bezeichnet $\mathbf{X}_t = (X_{1t}, \dots, X_{Nt})'$ den N -dimensionalen Spaltenvektor der Variablen; die so genannte Matrix der Faktorladungen Λ enthält die Parameter λ_{ijk} , $i = 1, \dots, N$; $j = 1, \dots, q$; $k = 0, \dots, p$ und ist von der Ordnung $N \times r$, wobei $r = q(p+1)$. Der r -dimensionale Spaltenvektor $\mathbf{F}_t = (\mathbf{f}'_t, \dots, \mathbf{f}'_{t-p})'$ enthält die q dynamischen Faktoren und jeweils deren verzögerte Werte, und $\mathbf{u}_t = (u_{1t}, \dots, u_{Nt})'$ steht für den N -dimensionalen Spaltenvektor der idiosynkratischen Komponenten.

Da zwischen den Faktoren und den idiosynkratischen Schocks annahmegemäß weder kontemporäre noch serielle Korrelation vorliegt, lässt sich die Kovarianzmatrix Σ_X der beobachtbaren Variablen wie folgt angeben:

$$\Sigma_X = \Lambda \Sigma_F \Lambda' + \Sigma_u, \quad (6)$$

mit Σ_F als Kovarianzmatrix des Vektors der Faktoren und Σ_u als Kovarianzmatrix des Vektors der idiosynkratischen Schocks.

Abschließend sei darauf hingewiesen, dass der Vektor der Faktoren nicht eindeutig identifiziert ist, da für eine beliebige nichtsinguläre $(r \times r)$ -Matrix \mathbf{Q} gilt, dass $\Lambda \mathbf{F}_t = \Lambda \mathbf{Q} \mathbf{Q}^{-1} \mathbf{F}_t = \Lambda^* \mathbf{F}_t^*$. Aufgrund dieses Identifikationsproblems können die Faktoren nicht unmittelbar (ohne weitere Annahmen) interpretiert werden. Da der Fokus hier jedoch letztlich auf der Prognose mittels dieser Faktoren liegt, hat die Nichteindeutigkeit der Faktoren in diesem Zusammenhang keine Konsequenzen.

Die Grundidee der betrachteten Faktormodelle besteht darin, dass Schwankungen einer Vielzahl von ökonomischen Variablen X_1, \dots, X_N durch einige wenige Faktoren f_1, \dots, f_r erklärt werden können; somit sollte die Anzahl der statischen Faktoren r deutlich geringer sein als die Anzahl der im Modell berücksichtigten Variablen N . Gleichzeitig sollten diese Faktoren aber den Großteil der Varianz der Variablen erklären. Das Grundproblem bei der Schätzung eines Faktormodells besteht demnach in der Bestimmung der Faktoren in \mathbf{F}_t und der Faktorladungen in Λ . Mittels der nicht-parametrischen Hauptkomponentenanalyse kann das statische Faktormodell konsistent geschätzt werden (Stock und Watson, 2002a, 2002b). Dieses Verfahren wird im Folgenden skizziert.

752. Die r Faktoren in \mathbf{F}_t sind mittels der Hauptkomponentenanalyse so zu bestimmen, dass sie möglichst viel der Kovarianz der Variablen \mathbf{X}_t erklären. Dies bedeutet im Umkehrschluss, dass die Parametermatrix \mathbf{A} und der Faktorenvektor \mathbf{F}_t so zu ermitteln sind, dass der Beitrag der Kovarianz des Störgrößenvektors \mathbf{u}_t minimiert wird. Dieses nichtlineare Maximierungsproblem oder Minimierungsproblem (unter einer Nebenbedingung) führt zu einem Eigenwertproblem, wie im Folgenden kurz gezeigt wird.

Für die folgende Darstellung ist es hilfreich zu unterstellen, dass die Faktoren in \mathbf{F}_t jeweils als Linearkombinationen der Variablen X_{1t}, \dots, X_{Nt} dargestellt werden können, das heißt, die Methode der Hauptkomponenten dient letztlich dazu, Linearkombinationen von Variablen mit einer möglichst großen Varianz zu finden und statt einer Vielzahl von Variablen nur wenige Faktoren für eine weitergehende Analyse zu verwenden. Anders ausgedrückt, einige wenige Faktoren sind so zu bestimmen, dass sie möglichst einen großen Anteil der Kovarianz der im Modell enthaltenen Variablen erklären.

Die r statischen Faktoren sind darstellbar als Linearkombinationen der N Variablen, so dass sich in kompakter Schreibweise ergibt

$$\mathbf{F}_t = \mathbf{B} \mathbf{X}_t, \quad (7)$$

wobei $\mathbf{B} = (\boldsymbol{\beta}_1, \dots, \boldsymbol{\beta}_r)'$ die $(r \times N)$ -dimensionale Parametermatrix \mathbf{B} symbolisiert, mit $\mathbf{F}_t = (f_{1t}, \dots, f_{rt})'$ und $\mathbf{X}_t = (X_{1t}, \dots, X_{Nt})'$. Für einen ausgewählten Faktor f_{jt} , $j = 1, \dots, r$ ergibt sich somit $f_{jt} = \boldsymbol{\beta}'_j \mathbf{X}_t$. Es gilt nun diese r Faktoren so zu bestimmen, dass deren Varianz maximiert wird, das heißt der Schätzer des Faktors j , $\hat{f}_{jt} = \hat{\boldsymbol{\beta}}'_j \mathbf{X}_t$, ist so zu berechnen, dass die Varianz von \hat{f}_{jt} maximiert wird. Bezeichnet man mit $\text{Var}(\mathbf{X}_t) = \frac{1}{T} \sum_{t=1}^T \mathbf{X}_t \mathbf{X}'_t = \hat{\boldsymbol{\Omega}}$ den Schätzer für die Kovarianzmatrix des Variablenvektors, ergibt sich die Varianz von \hat{f}_{jt} zu

$$\text{Var}(\hat{f}_{jt}) = \text{Var}(\hat{\boldsymbol{\beta}}'_j \mathbf{X}_t) = \hat{\boldsymbol{\beta}}'_j \hat{\boldsymbol{\Omega}} \hat{\boldsymbol{\beta}}_j, \quad (8)$$

wobei als Nebenbedingung $\boldsymbol{\beta}'_j \boldsymbol{\beta}_j = 1$ zu berücksichtigen ist. Die Nebenbedingung dient dabei der Standardisierung. Die Maximierung dieser Varianz unter Nebenbedingung erfolgt mittels einer Lagrange-Funktion, die zu folgendem Eigenwertproblem führt (Anderson, 2003, S. 460 f.):

$$\hat{\boldsymbol{\beta}}'_j \hat{\boldsymbol{\Omega}} = \hat{\mu}_j \hat{\boldsymbol{\beta}}'_j. \quad (9)$$

Hierbei bezeichnet $\hat{\mu}_j$ den j -ten Eigenwert und $\hat{\boldsymbol{\beta}}'_j$ den zugehörigen N -dimensionalen Eigenvektor. Zur Schätzung der Faktoren werden die zu den r ersten Eigenwerten, sortiert nach ihrer Größe, gehörigen Eigenvektoren verwendet; Schätzwerte für die einzelnen Faktoren ergeben sich somit als:

$$\hat{f}_{jt} = \hat{\boldsymbol{\beta}}_j' \mathbf{X}_t, \quad j = 1, \dots, r \quad (10)$$

oder in kompakter Schreibweise

$$\hat{\mathbf{F}}_t = \hat{\mathbf{B}} \mathbf{X}_t, \quad (11)$$

mit $\hat{\mathbf{B}} = (\hat{\boldsymbol{\beta}}_1, \dots, \hat{\boldsymbol{\beta}}_r)'$ als Matrix der Eigenvektoren. Ruft man sich in Erinnerung, dass obiges Maximierungsproblem äquivalent ist zur Minimierung der Varianz der idiosynkratischen Komponente (Gleichung (6)), lässt sich zeigen, dass $\boldsymbol{\Lambda}' = \mathbf{B}$ (Dreger und Schumacher, 2004b; Stock und Watson, 2004).

753. Die mit Hilfe der Hauptkomponentenanalyse ermittelten Faktoren stellen die Grundlage der Konstruktion des Konjunkturindikators dar. In der jüngeren Vergangenheit wurden verschiedene Alternativen gewählt (prominente Beispiele sind der von der Federal Reserve Bank of Chicago ermittelte Konjunkturindikator CFNAI oder der vom Centre of Economic Policy Research auf Basis einer dynamischen Faktoranalyse ermittelte Index EuroCOIN). Der in der vorliegenden Studie berechnete Indikator, der methodisch weitgehend dem CFNAI-Index entspricht, lässt sich unmittelbar aus den geschätzten Faktoren ableiten. Er ist gerade mit dem Faktor identisch, der sich aus demjenigen Eigenvektor ergibt, der auf dem größten Eigenwert basiert. Einfach gesprochen, KiFa ist gerade derjenige (einzelne) Faktor, der den größten Anteil der Varianz der in das Faktormodell einbezogenen Zeitreihen erklärt.

3. Datengrundlage

754. Grundlage für die Konstruktion des aus dem Faktormodell abgeleiteten Konjunkturindikators sind sowohl Daten der amtlichen Statistik als auch Umfragedaten. Hierzu werden monatliche Zeitreihen von Januar 1994 bis Februar 2005 verwendet. Der Konjunkturindikator basiert auf einem Datensatz, der rund 150 Variablen umfasst. Er wurde dabei so zusammengestellt, dass die Gesamtwirtschaft – soweit dies die Datenverfügbarkeit auf Monatsbasis zulässt – möglichst breit abgedeckt wird. Einbezogen wurden unter anderem Produktionsindizes, Indizes des Auftragseingangs, Zeitreihen aus der Außenhandelsstatistik, Indikatoren aus Geld-, Kapital-, Öl- und Devisenmärkten, Zeitreihen aus der Arbeitsmarktstatistik, Preisindizes sowie Umfrageergebnisse von ifo, ZEW und Europäischer Kommission. Hinzu genommen wurden schließlich noch ausgewählte internationale Zeitreihen.

Vor der eigentlichen Berechnung der Faktoren werden die Zeitreihen zunächst saisonbereinigt, soweit keine amtlichen saisonbereinigten Daten zur Verfügung stehen. Da die Hauptkomponentenanalyse stationäre Zeitreihen voraussetzt, werden anschließend nichtstationäre Zeitreihen logarithmiert und differenziert (Saldengrößen werden nur differenziert), so dass der überwiegende Teil der Variablen als Zuwachsraten in die Berechnung der Faktoren eingeht. Abschließend werden die Variablen standardisiert, so dass sie einen Mittelwert von null und eine Varianz von eins aufweisen. Die Faktoren wurden mittels des Programmpakets GAUSS berechnet.

4. Spezifikation der Prognosemodelle

755. Inwieweit die bislang genannten Konjunkturindikatoren einen signifikanten Beitrag leisten, die zukünftige Entwicklung der Nettoproduktion der Industrie auf Monatsebene zu prognostizieren, lässt sich nur im Rahmen adäquat spezifizierter Prognosemodelle beantworten.

Aus theoretischer Sicht ist die optimale Prognose einer Variablen unter Verwendung einer quadratischen Verlustfunktion ihr Erwartungswert, gegeben die verfügbare Informationsmenge (Hamilton, 1994, Kapitel 4). Unter diesem Aspekt sind univariate oder multivariate Prognosemodelle mit nur wenigen Variablen prinzipiell suboptimal. Die Einbindung einer überschaubaren Anzahl von Variablen kann jedoch insofern begründet sein, als die Berücksichtigung einer Vielzahl von Variablen im Kontext von Kleinste-Quadrate-Schätzungen den Nachteil birgt, dass der Beitrag des Schätzfehlers einer Kleinste-Quadrate-Schätzung zum mittleren quadratischen Prognosefehler einer solchen Vorhersage mit wachsendem Stichprobenumfang nicht verschwindet (Stock und Watson, 2004). In diesem Sinn ist es „traditionellen“ Prognosemodellen nur begrenzt möglich, die Vielzahl an Informationen bei der Prognose zu berücksichtigen. Diejenigen Prognosemodelle, die auf einige wenige geschätzte Faktoren zurückgreifen, überwinden potenziell dieses Problem in dem Sinn, dass sie einen Großteil der im vorliegenden Datenkranz enthaltenen Informationen in komprimierter Form enthalten. Kurz gefasst berücksichtigen Prognosemodelle, die auf Faktoren zurückgreifen, einen großen Datensatz und können gleichwohl sehr sparsam parametrisiert werden. Eine Reihe jüngerer Arbeiten weist insbesondere für die Vereinigten Staaten und für den Euro-Raum darauf hin, dass die Verwendung von geschätzten Faktoren in Prognosemodellen zu einer Verbesserung der Prognosegüte führt (Forni et al., 2003; Marcellino, Stock und Watson, 2003).

756. Um den Prognosegehalt der oben genannten Konjunkturindikatoren untersuchen zu können, ist für die Durchführung eines Prognoseexperiments (Prognosesimulation) die Wahl des Prognosedesigns von zentraler Bedeutung. Dies wiederum erfordert die Beantwortung einer Reihe einzelner Fragen. Zunächst ist zu klären, welches Prognosemodell zugrunde gelegt werden soll: In Frage kommen sowohl Einzelgleichungsansätze oder auch Mehrgleichungsansätze (Vektorautoregressive (VAR-) Modelle). Hierbei stellt sich die Frage, ob für einen gegebenen Prognosehorizont h iterativ (mittels Ein-Schritt-Prognosen) oder dynamisch (mittels h -Schritt-Prognosen) prognostiziert werden soll. Weiterhin ist zu entscheiden, nach welchen Kriterien die Spezifikation des Prognosemodells erfolgt: Prinzipiell ist es möglich, Prognosemodelle auf Grundlage des gesamten zur Verfügung stehenden Zeitraums zu spezifizieren oder – alternativ – auf Grundlage eines Teilzeitraums; die Spezifikation erfolgt dann rekursiv. Darüber hinaus kann alternativ die Spezifikation eines Modells auf Grundlage der Prognoseperformance vorgenommen werden. Schließlich können für die Beurteilung der Prognosegüte alternativer Konjunkturindikatoren rekursive oder rollierende Prognosen außerhalb des für die Schätzung der Parameter verwendeten Stichprobenbereichs herangezogen werden. Bislang liegt in der Literatur kein Konsens hinsichtlich der Festlegung des Prognosedesigns vor. Es mag daher nicht sonderlich überraschen, wenn in verschiedenen Studien divergierende Ergebnisse hinsichtlich der Prognosegüte einzelner Konjunkturindikatoren auftreten.

757. Das nachfolgende Prognoseexperiment beruht auf der ökonometrischen Schätzung einer Reihe von Einzelgleichungen, wobei die jeweiligen Prognosen als h -Schritt-Prognosen modelliert

werden: Das Prognosemodell wird spezifiziert und geschätzt als lineare Projektion der um h Schritte in die Zukunft „verschobenen“ Variablen y_{t+h} , gegeben den zum Zeitpunkt t vorliegenden Konjunkturindikator. Formal lässt sich ein solches h -Schritt-Prognosemodell wie folgt darstellen:

$$y_{t+h} = \alpha(L)y_t + \gamma(L) \text{indikator}_t + \varepsilon_{t+h}, \quad (12)$$

wobei $\alpha(L) = \sum_{i=0}^m \alpha_i L^i$ und $\gamma(L) = \sum_{j=0}^n \gamma_j L^j$ endliche Lagpolynome darstellen und die Modellparameter mit der Methode der kleinsten Quadrate geschätzt werden. Etwaige autoregressive Terme werden durch die Koeffizienten in $\alpha(L)$ berücksichtigt, die Parameter γ_j geben den kontemporären und verzögerten Einfluss des jeweiligen Konjunkturindikators an; y_{t+h} ist die zu prognostizierende Zuwachsrate der gewählten Referenzreihe (im Folgenden die Nettoproduktion der Industrie), wobei nachfolgend sowohl laufende Zuwachsraten ($y_t = \log Y_t - \log Y_{t-1}$, mit Y_t als Nettoproduktion der Industrie) als auch Zuwachsraten gegenüber dem Vorjahresmonat ($y_t = \log Y_t - \log Y_{t-12}$) zugrunde gelegt werden. Die Out-of-Sample Prognose der Variablen y_{T+h} zum Zeitpunkt T ist gegeben durch $y_{T+h|T} = \alpha(L)y_T + \gamma(L) \text{indikator}_T$. Als Messlatte für die Evaluierung der Prognosen wird zum einen ein einfaches autoregressives Modell herangezogen

$$y_{t+h} = \alpha(L)y_t + \varepsilon_{t+h}, \quad (13)$$

und zum anderen wird die Prognosegüte der verschiedenen Konjunkturindikatoren direkt miteinander verglichen.

Im Unterschied zu den gängigen Ein-Schritt-Prognosemodellen ist es im Rahmen des obigen h -Schritt-Prognosemodells nicht notwendig, für einen gegebenen Prognosehorizont h das Modell entsprechend häufig zu iterieren, da für jeden Prognosehorizont h ein eigenes Prognosemodell spezifiziert wird. Bei einer Ein-Schritt-Prognose wird demgegenüber lediglich eine gemeinsame, nicht vom Prognosehorizont abhängige Spezifikation gewählt. Einer solchen iterativen Vorgehensweise folgen etwa Hüfner und Schröder (2002) sowie Benner und Meier (2004), während Breitung und Jagodzinski (2001), Stock und Watson (2004) sowie Boivin und Ng (2005) h -Schritt-Prognosen wählen.

Mit der Formulierung eines h -Schritt-Prognosemodells sind zwei Vorteile verbunden: Es wird keine zusätzliche Gleichung benötigt, um den Indikator zu prognostizieren. Dies erklärt, weshalb es im vorliegenden Ansatz genügt, ein Einzelgleichungsmodell an Stelle eines vektorautoregressiven Modells zu verwenden. Darüber hinaus wird der potentielle Einfluss etwaiger Spezifikationsfehler im Ein-Schritt-Prognosemodell verringert, da Schätzung und Prognose derselbe Horizont h zugrunde liegt (Schumacher, 2005). Zum jetzigen Zeitpunkt ist jedoch nicht endgültig geklärt, ob h -Schritt-Prognosen generell Ein-Schritt-Prognosen überlegen sind (Marcellino, Stock und Watson, 2005; Boivin und Ng, 2005). Da in der jüngeren Vergangenheit eine Reihe von empirischen Studien zur Aussagekraft von Konjunkturindikatoren auf Ein-Schritt-Prognosen beruht,

lassen sich die nachfolgenden h -Schritt-Prognosesimulationen als Komplement zu bereits existierenden Studien werten.

5. Evaluierung der Prognosen

758. Um die Prognosegüte alternativer Prognosemodelle zu beurteilen, werden in der vorliegenden Analyse rekursive Prognosen außerhalb des für die Schätzung der Parameter verwendeten Stichprobenbereichs, so genannte Out-of-Sample Prognosen, herangezogen. Für die Ermittlung der Out-of-Sample Prognosen wird das Modell in einem ersten Schritt bis zu einem Zeitpunkt T^* geschätzt, der deutlich vor dem Ende des Beobachtungszeitraums T liegt. Basierend auf dieser Schätzung werden h -Schritt-Prognosen für den Zeitraum jenseits des Zeitpunkts T^* berechnet. Anschließend werden der Stützbereich um eine Beobachtung erweitert, die Schätzung erneut durchgeführt und die h -Schritt-Prognosen für den Zeitraum jenseits des Zeitpunkts $T^* + 1$ ermittelt. Dieses rekursive Vorgehen wird bis zum Zeitpunkt T wiederholt.

759. Der Modellauswahlprozess, das heißt die Bestimmung der Lag-längen m und n in Gleichung (12), beruht sowohl auf dem Schwarz- als auch alternativ auf dem Akaike-Informationskriterium, wobei sowohl für die autoregressiven Terme als auch für die Konjunkturindikatoren eine variable Lag-länge zugrunde gelegt wird. Dabei werden – ausgehend von einer exogen vorgegebenen maximalen Verzögerungsstruktur – sämtliche Lag-kombinationen geprüft und für einen gegebenen Prognosehorizont h wird diejenige Spezifikation gewählt, die das jeweilige Informationskriterium minimiert.

Die hier verwendeten Informationskriterien bewerten bei der Auswahl des Prognosemodells den Zielkonflikt zwischen einer möglichst guten Anpassung des Prognosemodells an die Daten und einer möglichst sparsamen Parametrisierung des Modells. Die Berücksichtigung zusätzlicher verzögerter Variablen reduziert die Summe der quadrierten Residuen und führt zu einer besseren Anpassung des Modells an die Daten. Allerdings steigt mit zunehmender Anzahl von Lags die Zahl der zu schätzenden Parameter, was für sich genommen mit einer Reduktion der Freiheitsgrade einhergeht. Dies dürfte die Prognosegüte des Modells verschlechtern. Beide Informationskriterien sind so konstruiert, dass sie ein Modell für eine bessere Anpassung „belohnen“, für die Verwendung eines zusätzlichen Regressors hingegen „bestrafen“. Optimal im Sinne des Informationskriteriums ist dann das Modell, das die beiden widerstreitenden Ziele am besten in Einklang bringt.

Formal lassen sich die hier verwendeten Selektionskriterien wie folgt angeben:

$$AIC = \frac{-2 \ln L}{T} + 2 \frac{k}{T}, \quad (14)$$

$$SC = \frac{-2 \ln L}{T} + \frac{k \ln T}{T}, \quad (15)$$

mit $k = m + n + 2$ als der Anzahl der zu schätzenden Parameter und $\ln L$ als der logarithmierten Likelihood-Funktion. Für beide Informationskriterien gilt, dass dasjenige Modell gewählt wird, welches das (jeweilige) Kriterium minimiert. Wie aus der formalen Darstellung der beiden Kriterien unmittelbar hervorgeht, wählt das Schwarz-Kriterium (SC) für $T > 7$ eine sparsamere Parametrisierung als das Akaike-Kriterium (AIC), die „marginalen Kosten“ eines zusätzlichen Regressors sind beim Schwarz-Kriterium in diesem Fall höher als beim Akaike-Kriterium. Hinsichtlich der Wahl des geeigneten Informationskriteriums lässt sich keine eindeutige Aussage treffen. Für

sehr große Stichproben erweist sich das Schwarz-Kriterium als überlegen, demgegenüber wählt das Akaike-Kriterium in diesem Fall ein überparametrisiertes Modell. Für kleinere Stichproben hingegen schneidet mitunter das Akaike-Kriterium besser ab (Lütkepohl, 1993).

760. Die Evaluierung der Prognosegüte zweier Konjunkturindikatoren A und B erfordert in einem ersten Schritt die Berechnung eines Gütemaßes, das die Treffgenauigkeit der jeweiligen Prognose in einem Wert zusammenfasst. In der vorliegenden Analyse wird, wie im Rahmen solcher Untersuchungen üblich, die Wurzel aus dem mittleren quadrierten Prognosefehler (Root Mean Square Error, RMSE) verwendet. Angenommen, man hat zwei h -Schritt-Prognosereihen $\hat{y}_{A,t}(h)$ und $\hat{y}_{B,t}(h)$ sowie die Zeitreihe y_t mit den zugehörigen Prognosefehlern $e_{A,t}(h)$ und $e_{B,t}(h)$; $t = 1, \dots, T_f$ und die Anzahl der Prognosezeitpunkte T_f , so berechnet sich die Wurzel aus dem mittleren quadrierten Prognosefehler für die Prognose (das Prognosemodell) i wie folgt:

$$RMSE_i(h) = \sqrt{\frac{1}{T_f} \sum_{t=1}^{T_f} (e_{i,t}(h))^2}, \quad i = A, B. \quad (16)$$

Als Maß zur Evaluierung der Prognosegüte zweier Prognosen A und B wird der Theilsche Ungleichheitskoeffizient (Theilsches U) verwendet, also der Quotient aus der Wurzel des mittleren quadrierten Prognosefehlers des Modells A und dem entsprechenden Term für das Prognosemodell B :

$$THEIL_{A,B}(h) = \frac{RMSE_A(h)}{RMSE_B(h)}. \quad (17)$$

Ein Theilscher Ungleichheitskoeffizient kleiner eins zeigt in diesem Fall an, dass die Treffgenauigkeit der h -Schritt-Prognose A höher ist als die der Prognose B . Der Theilsche Ungleichheitskoeffizient lässt jedoch noch keine Aussage darüber zu, ob die Prognose A im oben genannten Fall eine signifikant höhere Treffgenauigkeit besitzt als die Prognose B . Zur Beantwortung dieser Frage wird in der vorliegenden Analyse die modifizierte Diebold-Mariano-Teststatistik herangezogen (Diebold und Mariano, 1995; Harvey et al., 1997). Diese entspricht grob gesprochen dem Durchschnitt aus der Differenz der quadrierten Prognosefehler (der zwei betrachteten Prognosen) dividiert durch die Varianz dieses Terms. Der Diebold-Mariano-Test erlaubt letztlich eine Aussage darüber, ob die Unterschiede zwischen den RMSE zweier Prognosen statistisch signifikant sind. Die modifizierte Diebold-Mariano-Teststatistik ist (asymptotisch) t -verteilt.

6. Ergebnisse der Prognoseevaluierung bei konstanter Modellspezifikation

761. Wählt man die Zuwachsraten der Nettoproduktion gegenüber dem Vorjahr als Referenzreihe, so ergeben sich für den gesamten Prognosezeitraum von Januar 1999 bis Dezember 2004 – aktuellere Angaben für den hier verwendeten Handelsblatt-Konjunkturindikator liegen nicht vor – für die Auftragseingänge, den Indikator der FAZ und dem KiFa vergleichsweise gute Resultate (Tabelle 50, Seite 506). Innerhalb eines Prognosehorizonts von neun Monaten liefern diese Indikatoren mit Blick auf das Theilsche U und die modifizierte Diebold-Mariano-Statistik signifikant bessere Prognosen als die naive Prognose. Der Spezifikation der Prognosemodelle liegt dabei das

in der Literatur häufig verwendete Schwarz-Informationskriterium zugrunde. Auch die ifo-Geschäftserwartungen, die ZEW-Konjunkturerwartungen und der Handelsblatt-Indikator schneiden besser ab als die naive Prognose, wenngleich die höhere Treffgenauigkeit dieser Indikatoren im Vergleich zur naiven Prognose nicht signifikant ausfällt.

Tabelle 50

Prognose der Zuwachsrate der Nettoproduktion gegenüber dem Vorjahresmonat Benchmark: naive Prognose, Schwarz-Informationskriterium Prognosezeitraum von Januar 1999 bis Dezember 2004										
Prog- nose - horizont (Monate)	Naive Prognose RMSE ¹⁾	ifo-Er- wartungen RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	ZEW- Er- wartungen RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	Faktor- modell RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾
1	0,0152	0,0143	0,94	0,73	0,0140	0,92	1,20	0,0141	0,93	1,34
2	0,0172	0,0150	0,87	1,27	0,0152	0,88	1,44	0,0108	0,63	3,37
3	0,0169	0,0160	0,94	0,63	0,0159	0,94	0,60	0,0112	0,66	3,93
4	0,0182	0,0162	0,89	1,25	0,0164	0,90	0,93	0,0130	0,72	2,68
5	0,0194	0,0166	0,85	1,31	0,0175	0,90	0,81	0,0145	0,75	2,18
6	0,0208	0,0181	0,87	1,14	0,0189	0,91	0,67	0,0153	0,74	2,32
7	0,0217	0,0194	0,89	0,98	0,0198	0,91	0,68	0,0160	0,74	2,35
8	0,0234	0,0200	0,86	1,38	0,0215	0,92	0,67	0,0166	0,71	2,44
9	0,0248	0,0222	0,90	0,82	0,0223	0,90	0,79	0,0175	0,71	2,20
10	0,0258	0,0222	0,86	1,15	0,0223	0,87	0,98	0,0187	0,73	1,93
11	0,0266	0,0240	0,90	1,44	0,0250	0,94	0,36	0,0205	0,77	1,54
12	0,0268	0,0247	0,92	1,16	0,0255	0,95	0,30	0,0232	0,86	0,80
Prog- nose - horizont (Monate)	Naive Prognose RMSE ¹⁾	Auftrags- eingänge RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	Handels- blatt RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	FAZ RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾
1	0,0152	0,0109	0,71	3,30	0,0145	0,96	1,31	0,0107	0,70	3,34
2	0,0172	0,0115	0,67	3,03	0,0134	0,78	2,61	0,0114	0,66	3,26
3	0,0169	0,0119	0,70	3,25	0,0147	0,87	1,83	0,0115	0,68	3,44
4	0,0182	0,0133	0,73	2,61	0,0157	0,87	1,54	0,0132	0,72	2,80
5	0,0194	0,0147	0,76	2,07	0,0165	0,85	1,45	0,0151	0,78	1,99
6	0,0208	0,0154	0,74	2,15	0,0179	0,86	1,35	0,0159	0,77	2,00
7	0,0217	0,0173	0,80	1,81	0,0191	0,88	1,26	0,0173	0,79	2,02
8	0,0234	0,0186	0,80	1,94	0,0210	0,90	1,15	0,0188	0,80	1,60
9	0,0248	0,0196	0,79	1,94	0,0228	0,92	0,97	0,0201	0,81	1,69
10	0,0258	0,0207	0,80	2,06	0,0247	0,96	0,69	0,0216	0,84	1,87
11	0,0266	0,0221	0,83	1,39	0,0260	0,98	0,47	0,0228	0,86	1,24
12	0,0268	0,0252	0,94	0,48	0,0247	0,92	0,61	0,0239	0,89	0,98

1) Wurzel aus dem mittleren quadrierten Prognosefehler (Root Mean Square Error), siehe Ziffer 760. - 2) Quotient aus der Wurzel des mittleren quadrierten Prognosefehlers des Indikators und dem RMSE der naiven Prognose, siehe Ziffer 760. - 3) Die modifizierte Diebold-Mariano-Statistik ist (asymptotisch) t-verteilt; Werte größer 1,96 zeigen eine Signifikanz zum Niveau von $\alpha = 0,05$ an, siehe Ziffer 760.

762. Ein Vergleich der Indikatoren untereinander zeigt, dass der aus der Faktoranalyse abgeleitete KiFa für einen Prognosehorizont von bis zu neun Monaten in der Regel eine signifikant bessere Prognosegüte für die Nettoproduktion aufweist als die ifo-Geschäftserwartungen und die ZEW-Konjunkturerwartungen (Tabelle 51).

Hinsichtlich der Auftragseingänge und dem FAZ-Indikator zeigt sich ebenfalls eine höhere Treffgenauigkeit der Prognose, diese erweist sich aber nicht als signifikant. Legt man der Modellselektion alternativ das Akaike-Informationskriterium zugrunde, bleiben die wesentlichen Ergebnisse erhalten. Auffällig ist indes, dass für alle mittels des Akaike-Informationskriteriums spezifizierten

Prognosemodelle die mittleren quadrierten Prognosefehler geringer ausfallen. KiFa weist nunmehr lediglich für einen Prognosehorizont von über vier Monaten gegenüber den Auftragseingängen und dem FAZ-Indikator eine bessere Prognosegüte auf.

Tabelle 51

Prognose der Zuwachsrate der Nettoproduktion gegenüber dem Vorjahresmonat Benchmark: Konjunkturindikator-Faktormodell, Schwarz-Informationskriterium Prognosezeitraum von Januar 1999 bis Dezember 2004									
Prognosehorizont (Monate)	Auftragseingänge RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾	FAZ RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾	ifo-Erwartungen RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾
1	0,0109	0,0141	-2,44	0,0107	0,0141	-2,51	0,0143	0,0141	0,20
2	0,0115	0,0108	0,54	0,0114	0,0108	0,53	0,0150	0,0108	3,28
3	0,0119	0,0112	0,62	0,0115	0,0112	0,30	0,0160	0,0112	3,98
4	0,0133	0,0130	0,19	0,0132	0,0130	0,12	0,0162	0,0130	2,00
5	0,0147	0,0145	0,11	0,0151	0,0145	0,36	0,0166	0,0145	1,34
6	0,0154	0,0153	0,10	0,0159	0,0153	0,41	0,0181	0,0153	1,68
7	0,0173	0,0160	0,84	0,0173	0,0160	0,95	0,0194	0,0160	1,90
8	0,0186	0,0166	1,46	0,0188	0,0166	1,28	0,0200	0,0166	2,30
9	0,0196	0,0175	0,84	0,0201	0,0175	1,15	0,0222	0,0175	2,14
10	0,0207	0,0187	0,55	0,0216	0,0187	0,69	0,0222	0,0187	1,57
11	0,0221	0,0205	0,42	0,0228	0,0205	0,52	0,0240	0,0205	0,96
12	0,0252	0,0232	0,30	0,0239	0,0232	0,17	0,0247	0,0232	0,46
Prognosehorizont (Monate)	ZEW- Erwartungen RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾	Handelsblatt RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾			
1	0,0140	0,0141	-0,07	0,0145	0,0141	0,49			
2	0,0152	0,0108	3,66	0,0134	0,0108	1,83			
3	0,0159	0,0112	3,51	0,0147	0,0112	2,04			
4	0,0164	0,0130	2,09	0,0157	0,0130	1,27			
5	0,0175	0,0145	1,49	0,0165	0,0145	0,91			
6	0,0189	0,0153	1,82	0,0179	0,0153	1,33			
7	0,0198	0,0160	1,80	0,0191	0,0160	1,72			
8	0,0215	0,0166	3,02	0,0210	0,0166	2,10			
9	0,0223	0,0175	3,12	0,0228	0,0175	1,90			
10	0,0223	0,0187	2,92	0,0247	0,0187	1,94			
11	0,0250	0,0205	2,31	0,0260	0,0205	1,63			
12	0,0255	0,0232	2,07	0,0247	0,0232	0,72			

1) Wurzel aus dem mittleren quadrierten Prognosefehler (Root Mean Square Error), siehe Ziffer 760. - 2) Die modifizierte Diebold-Mariano-Statistik ist (asymptotisch) t-verteilt; Werte größer 1,96 zeigen eine Signifikanz zum Niveau von $\alpha = 0,05$ an, siehe Ziffer 760.

763. Für die Prognosen der laufenden Zuwachsraten zeigen sich für den oben genannten Prognosezeitraum gegenüber den Jahreszuwachsraten durchaus bemerkenswerte Unterschiede. Zunächst fällt auf, dass unter Zugrundelegung des Schwarz-Informationskriteriums die Prognosemodelle nur in Ausnahmefällen in der Lage sind, die naive Prognose signifikant zu übertreffen. Eine Überprüfung der für den jeweiligen Prognosehorizont h gewählten Verzögerungsstruktur (nicht abgebildet) zeigt, dass bei Verwendung des Schwarz-Kriteriums eine sehr sparsame Verzögerungsstruktur gewählt wird. Dieses Ergebnis ändert sich deutlich, wenn das Akaike-Informationskriterium zugrunde gelegt wird. Die mittleren quadrierten Prognosefehler reduzieren sich dann spürbar, und die Prognosemodelle weisen im Vergleich zur naiven Prognose eine höhere

Treffgenauigkeit auf. Im Vergleich zur Prognose der Jahreszuwachsrate zeigt sich jedoch ein etwas uneinheitlicheres Bild (Tabelle 52).

Tabelle 52

Prognose der Zuwachsrate der Nettoproduktion gegenüber dem Vormonat
Benchmark: naive Prognose, Akaike-Informationskriterium
 Prognosezeitraum von Januar 1999 bis Dezember 2004

Prog- nose - horizont (Monate)	Naive Prognose RMSE ¹⁾	ifo-Er- wartungen RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	ZEW- Er- wartungen RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	Faktor- modell RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾
1	0,0104	0,0089	0,85	2,21	0,0093	0,89	1,91	0,0077	0,74	3,08
2	0,0111	0,0111	1,00	0,13	0,0115	1,03	-0,65	0,0098	0,88	2,39
3	0,0110	0,0107	0,97	0,54	0,0109	0,98	1,86	0,0092	0,83	2,39
4	0,0113	0,0103	0,92	1,88	0,0110	0,98	1,68	0,0099	0,88	2,21
5	0,0113	0,0105	0,93	1,56	0,0112	0,99	1,10	0,0101	0,90	2,11
6	0,0112	0,0104	0,93	1,75	0,0111	0,99	1,21	0,0098	0,87	2,17
7	0,0113	0,0107	0,95	1,28	0,0112	0,99	0,68	0,0099	0,88	2,03
8	0,0114	0,0109	0,96	1,14	0,0098	0,86	3,82	0,0103	0,91	1,35
9	0,0114	0,0111	0,97	1,05	0,0102	0,90	2,43	0,0107	0,94	0,84
10	0,0114	0,0111	0,97	1,00	0,0103	0,90	2,48	0,0106	0,92	1,13
11	0,0115	0,0114	0,99	0,47	0,0109	0,95	1,99	0,0107	0,93	1,10
12	0,0116	0,0113	0,98	0,93	0,0115	1,00	0,21	0,0107	0,92	1,17

Prog- nose - horizont (Monate)	Naive Prognose RMSE ¹⁾	Auftrags- eingänge RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	Handels- blatt RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾	FAZ RMSE ¹⁾	Theilsches $U^{2)}$	Mod. DM- Statistik ³⁾
1	0,0104	0,0075	0,72	3,88	0,0102	0,98	1,18	0,0070	0,68	4,06
2	0,0111	0,0095	0,85	2,38	0,0110	0,99	0,75	0,0091	0,82	2,91
3	0,0110	0,0095	0,86	2,21	0,0110	0,99	0,67	0,0090	0,81	3,15
4	0,0113	0,0100	0,89	1,81	0,0111	0,99	1,51	0,0098	0,87	2,35
5	0,0113	0,0097	0,86	1,97	0,0111	0,99	2,70	0,0096	0,85	2,42
6	0,0112	0,0101	0,90	1,75	0,0111	0,99	2,94	0,0100	0,89	2,16
7	0,0113	0,0104	0,92	1,47	0,0112	0,99	2,63	0,0102	0,90	2,21
8	0,0114	0,0109	0,96	1,07	0,0113	1,00	0,57	0,0107	0,94	2,29
9	0,0114	0,0098	0,87	2,67	0,0114	1,01	-0,31	0,0107	0,94	1,23
10	0,0114	0,0100	0,88	2,48	0,0114	1,00	-0,08	0,0104	0,91	1,94
11	0,0115	0,0101	0,87	2,77	0,0114	0,99	1,52	0,0104	0,91	2,18
12	0,0116	0,0100	0,87	2,79	0,0114	0,99	0,58	0,0104	0,90	2,32

1) Wurzel aus dem mittleren quadrierten Prognosefehler (Root Mean Square Error), siehe Ziffer 760. - 2) Quotient aus der Wurzel des mittleren quadrierten Prognosefehlers des Indikators und dem RMSE der naiven Prognose, siehe Ziffer 760. - 3) Die modifizierte Diebold-Mariano-Statistik ist (asymptotisch) t-verteilt; Werte größer 1,96 zeigen eine Signifikanz zum Niveau von $\alpha = 0,05$ an, siehe Ziffer 760.

Die Verwendung der Auftragseingänge erhöht in den ersten fünf Monaten die Prognosegüte, während KiFa und der FAZ-Indikator für die ersten sieben beziehungsweise acht Monate zu signifikant besseren Ergebnissen als die naive Prognose führen. Hinsichtlich der ifo-Geschäftserwartungen, der ZEW-Konjunkturerwartungen und des Handelsblatt-Indikators lässt sich lediglich für einzelne Perioden eine signifikant höhere Prognosegüte als bei der naiven Prognose feststellen.

764. Ein Vergleich der Indikatoren untereinander zeigt, dass zwischen KiFa, den Auftragseingängen und dem FAZ-Indikator keine signifikanten Unterschiede in der Prognosegüte bestehen, während KiFa gegenüber den ifo-Geschäftserwartungen in den ersten drei Monaten signifikant besser abschneidet (Tabelle 53). Im Vergleich zu den ZEW-Konjunkturerwartungen und zum

Handelsblatt-Indikator weist KiFa im ersten halben Jahr eine signifikant höhere Treffgenauigkeit auf.

Tabelle 53

Prognose der Zuwachsrate der Nettoproduktion gegenüber dem Vormonat
Benchmark: Konjunkturindikator-Faktormodell, Akaike-Informationskriterium
 Prognosezeitraum von Januar 1999 bis Dezember 2004

Prog-nose - horizont (Monate)	Auftrags-eingänge RMSE ¹⁾	Faktor-modell RMSE ¹⁾	Mod. DM-Statistik ²⁾	FAZ RMSE ¹⁾	Faktor-modell RMSE ¹⁾	Mod. DM-Statistik ²⁾	ifo-Er-wartungen RMSE ¹⁾	Faktor-modell RMSE ¹⁾	Mod. DM-Statistik ²⁾
1	0,0075	0,0077	-0,28	0,0070	0,0077	-1,04	0,0089	0,0077	1,74
2	0,0095	0,0098	-0,49	0,0091	0,0098	-1,19	0,0111	0,0098	2,38
3	0,0095	0,0092	0,37	0,0090	0,0092	-0,24	0,0107	0,0092	1,72
4	0,0100	0,0099	0,19	0,0098	0,0099	-0,37	0,0103	0,0099	0,52
5	0,0097	0,0101	-0,68	0,0096	0,0101	-0,90	0,0105	0,0101	0,58
6	0,0101	0,0098	0,42	0,0100	0,0098	0,30	0,0104	0,0098	0,97
7	0,0104	0,0099	0,46	0,0102	0,0099	0,34	0,0107	0,0099	1,09
8	0,0109	0,0103	0,60	0,0107	0,0103	0,40	0,0109	0,0103	0,74
9	0,0098	0,0107	-1,11	0,0107	0,0107	0,05	0,0111	0,0107	0,40
10	0,0100	0,0106	-0,84	0,0104	0,0106	-0,20	0,0111	0,0106	0,62
11	0,0101	0,0107	-1,31	0,0104	0,0107	-0,42	0,0114	0,0107	0,88
12	0,0100	0,0107	-1,40	0,0104	0,0107	-0,44	0,0113	0,0107	0,80

Prog-nose - horizont (Monate)	ZEW- Erwartungen RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾	Handelsblatt RMSE ¹⁾	Faktormodell RMSE ¹⁾	Mod. DM-Statistik ²⁾
1	0,0093	0,0077	2,46	0,0102	0,0077	2,85
2	0,0115	0,0098	2,81	0,0110	0,0098	2,18
3	0,0109	0,0092	2,33	0,0110	0,0092	2,31
4	0,0110	0,0099	1,96	0,0111	0,0099	1,99
5	0,0112	0,0101	1,80	0,0111	0,0101	1,89
6	0,0111	0,0098	1,96	0,0111	0,0098	1,97
7	0,0112	0,0099	1,85	0,0112	0,0099	1,82
8	0,0098	0,0103	-0,58	0,0113	0,0103	1,25
9	0,0102	0,0107	-0,41	0,0114	0,0107	0,93
10	0,0103	0,0106	-0,27	0,0114	0,0106	1,10
11	0,0109	0,0107	0,21	0,0114	0,0107	0,89
12	0,0115	0,0107	1,07	0,0114	0,0107	0,93

1) Wurzel aus dem mittleren quadrierten Prognosefehler (Root Mean Square Error), siehe Ziffer 760. - 2) Die modifizierte Diebold-Mariano-Statistik ist (asymptotisch) t-verteilt; Werte größer 1,96 zeigen eine Signifikanz zum Niveau von $\alpha = 0,05$ an, siehe Ziffer 760.

765. Die dargestellten Ergebnisse sind im Wesentlichen robust gegenüber einer Variation des Prognoseverfahrens, bei der alternativ zum bisherigen und in der Praxis gängigen Vorgehen die Auswahl der Prognosemodelle nicht einmalig auf der Basis des gesamten Beobachtungszeitraums vorgenommen wird, sondern rekursiv, das heißt zu jedem Prognosezeitpunkt anhand der bis dahin „verfügbaren“ Daten. Dieses rekursive Vorgehen simuliert dann die Situation eines Prognostikers, der im Zeitverlauf sein Prognosemodell sukzessiv an neu hinzukommende Informationen anpasst. Anders als bei einer Modellspezifikation auf Basis der gesamten Stichprobe gehen folglich keine Informationen ein, die zum Prognosezeitpunkt noch nicht verfügbar sind. Dies kann dazu führen, dass aufgrund des geringeren Informationsstandes die mittleren quadrierten Prognosefehler höher ausfallen. Bei der Beurteilung der beiden Vorgehensweisen ist jedoch zu beachten, dass auch mit der beschriebenen rekursiven Spezifikation des Prognosemodells der Anspruch, bei der Evaluation

der unterschiedlichen Indikatoren nur die zu jedem Prognosezeitpunkt vorhandenen Informationen zu nutzen, nur bedingt eingelöst werden kann. Denn dies würde die Verwendung von Echtzeitdaten anstelle der revidierten, heute verfügbaren Zeitreihen erfordern. Angesichts der häufig nicht unerheblichen Datenrevisionen ist daher unklar, inwieweit eine rekursive Modellspezifikationen mit Ex-post-Daten wirklich zu einer deutlich besseren Prognoseevaluation führt.

7. Fazit

766. Die Ergebnisse der Prognoseevaluierung zeigen, dass einige der untersuchten Indikatoren die Prognosegüte der naiven Prognose hinsichtlich der Nettoproduktion der Industrie signifikant verbessern. So weisen insbesondere KiFa, der FAZ-Konjunkturindikator und die Auftragseingänge (zumindest) für einen Prognosehorizont von einem halben Jahr – also eher für die kurze Frist – eine höhere Treffgenauigkeit auf als die naive Prognose.

Vor allem der FAZ-Konjunkturindikator und KiFa lassen erkennen, dass es prinzipiell von Vorteil ist, Informationen aus verschiedenen Zeitreihen systematisch zu bündeln. Gleichwohl illustriert das vorliegende Prognoseexperiment auch, dass die bislang vorliegenden synthetischen Konjunkturindikatoren für Deutschland nicht generell besser abschneiden als einzelne Zeitreihen wie beispielsweise die Auftragseingänge, die sowohl im FAZ-Konjunkturindikator, dem Handelsblatt-Frühindikator als auch im KiFa enthalten sind. Dies deutet darauf hin, dass insbesondere die Kriterien einer geeigneten Auswahl von ökonomischen Zeitreihen, die einem synthetischen Konjunkturindikator zugrunde gelegt werden sollten, noch nicht hinreichend bestimmt sind.

Die Prognosegüte der betrachteten Prognosemodelle, die grundsätzlich von der Spezifikation der Verzögerungsstruktur der Prognosemodelle abhängt, erweist sich in zweierlei Hinsicht als robust. Zum einen bleiben die wesentlichen Ergebnisse unberührt, wenn man alternativ zum Akaike-Informationskriterium das Schwarz-Informationskriterium zugrunde legt. Zum anderen hängt die qualitative Bewertung der Konjunkturindikatoren nicht davon ab, ob die Auswahl der Modellstruktur auf dem gesamten Stichprobenzeitraum beruht oder stattdessen rekursiv vorgenommen wird.

Literatur

- Anderson, T. W. (2003) *An Introduction to Multivariate Statistical Analysis*, 3rd Edition, John Wiley, New Jersey.
- Benner, J. und C.-P. Meier (2004) *Prognosegüte alternativer Frühindikatoren für die Konjunktur in Deutschland*, Jahrbücher für Nationalökonomie und Statistik, 224/6, 639 - 652.
- Boivin, J. und S. Ng (2005) *Understanding and Comparing Factor-Based Forecasts*, mimeo.
- Breitung, J. und D. Jagodzinski (2001) *Prognoseeigenschaften alternativer Indikatoren für die Konjunktur in Deutschland*, Konjunkturpolitik, 47, 292 - 314.
- Diebold, F. X. und R. S. Mariano (1995) *Comparing Predictive Accuracy*, Journal of Business and Economic Statistics, 13, 253 - 63.
- Döpke, J., J. W. Krämer und E. Langfeld (1994) *Konjunkturelle Frühindikatoren in Deutschland*, Konjunkturpolitik, 40, 135 - 153.
- Dreger, C. und C. Schumacher (2004) *Estimating Large-Scale Factor Models for Economic Activity in Germany: Do they Outperform simpler Models?*, Jahrbücher für Nationalökonomie und Statistik, 224/6, 731 - 750.

- Dreger, C. und C. Schumacher (2005) *The Out of Sample Performance of Leading Indicators for the German Business Cycle: Single vs. Combined Forecasts*, Journal of Business Cycle Measurement and Analysis, 2 (1), 71 - 88.
- Forni, M., M. Hallin, M. Lippi, und L. Reichlin (2003) *Do Financial Variables Help Forecasting Inflation and Real Activity in the Euro Area?*, Journal of Monetary Economics, 50, 1 243 - 1 255.
- Hamilton, J. D. (1994) *Time Series Analysis*, Princeton University Press Princeton.
- Harvey, D., S. Leybourne und P. Newbold (1997) *Testing the Equality of Prediction Mean Squared Errors*, International Journal of Forecasting, 13, 281 - 91.
- Hinze, J. (2003) *Prognoseleistung von Frühindikatoren*, HWWA Discussion Paper, 236.
- Hüfner, F. P. und M. Schröder (2002) *Prognosegehalt von ifo-Geschäftserwartungen und ZEW-Konjunkturerwartungen: Ein ökonometrischer Vergleich*, Jahrbücher für Nationalökonomie und Statistik, 222/3, 316 - 336.
- Lütkepohl, H. (1993) *Introduction to Multiple Time Series Analysis*, 2nd Edition. Springer-Verlag, Berlin u. a.
- Marcellino, M., J. Stock und M. W. Watson (2003) *Macroeconomic Forecasting in the Euro Area: Country Specific versus Area-Wide Information*, European Economic Review, 47, 1 - 18.
- Marcellino, M., J. Stock und M. W. Watson (2005) *A Comparison of Direct and Iterated Multistep AR Methods for Forecasting Macroeconomic Time Series*, IGIER Working Paper, 285.
- Schumacher, C. (2005) *Forecasting German GDP Using Alternative Factor Models Based on Large Datasets*, Deutsche Bundesbank Discussion Paper, Economic Studies, 24/05.
- Stock, J. H. und M. W. Watson (2002a) *Forecasting Using Principal Components from a Large Number of Predictors*, Journal of the American Statistical Association, 97, 1 167 - 1 179.
- Stock, J. H. und M. W. Watson (2002b) *Macroeconomic Forecasting Using Diffusion Indexes*, Journal of Business and Economic Statistics, 20, 147 - 162.
- Stock, J. H. und M. W. Watson (2004) *Forecasting with Many Predictors*, mimeo.
- Wolters, J. und F. Lankes (1989) *Das ifo-Geschäftsklima als Konjunkturindikator*, ifo-Studien, 35, 198 - 209.