

Working Paper Series

Forecast Combination による実質GDP の予測

大山 慎介

Working Paper 01-3

日本銀行調査統計局

〒100-8630 東京中央郵便局私書箱 203 号

(e-mail:shinsuke.ooyama@boj.or.jp)

本論文の内容や意見は執筆者個人のものであり、日本銀行あるいは調査統計局の見解を示すものではありません。

Forecast Combination による実質 GDP の予測*

2001 年 3 月

大山 慎介**

[要旨]

Forecast Combination とは、複数の予測を合成して予測パフォーマンスの改善を図る手法である。本稿では、その概要を紹介するとともに、応用事例として月次経済指標から同時期の実質 GDP 成長率を予測するモデルを提示する。Forecast Combination の方法として、Pooling Method、Regression Method、Pooling Method に Intercept Correction を組み合わせる方法という 3 つの方法を試みたところ、(1)Forecast Combination の導入は、本稿の予測パフォーマンスの評価基準である Root Mean Squared Error (RMSE) の改善に資すること、(2)より一般的な定式である Regression Method や、Intercept Correction で bias を修正した場合には、普通の Pooling Method に比べて RMSE を縮小できるが、実務的な観点に照らすと、本事例における違い (RMSE の差) はそれほど大きくないこと、また、(3)厳密な意味でのパフォーマンスの比較にはならないが、いずれの合成方法でも、民間予測機関の平均的な見通しに比べて良好な結果が得られた。このように、本稿のモデルは、直近期の実質 GDP 成長率の予測モデルとして有用である。

* 本稿の作成にあたって、鎌田康一郎氏 (調査統計局経済調査課)、関根敏隆氏 (同)、吉田知生氏 (同) をはじめ多くの行内スタッフから指導や有益なコメントを得た。また、分析に際して、金子智枝子氏 (同) から多大な協力を得た。なお、本稿の文責は全て筆者にあり、意見等にわたる部分は、日本銀行および調査統計局の見解ではない。

** 日本銀行調査統計局経済調査課 E-mail:shinsuke.ooyama@boj.or.jp

1. はじめに

経済指標の先行きを計量的に予測しようとする場合、何とおりかの説明変数の組み合わせや定式化を試みて、その中から予測パフォーマンスが最も高いものを選ぶのが普通である。これに対して Forecast Combination では、利用可能な予測を組み合わせると、個々の予測に比べてより優れた予測を生み出せるのではないかと考える。本稿では、この Forecast Combination の概要を紹介することを第一の目的としている。

本稿の第二の目的は、Forecast Combination の応用事例として、月次経済指標から同時期の実質 GDP 成長率を予測するモデルを提示することにある。実質 GDP はひとつの重要な経済指標であるが、速報（四半期別国民所得統計速報、以下「QE」と呼ぶ）であっても、当該四半期の終了後2ヶ月+10日程度遅れて公表されるため、速報性に劣るという問題がある。そこで、実質 GDP に先立ち公表される月次経済指標から実質 GDP を予測できるのであれば、QE 公表の約1ヶ月前にその成長率をイメージすることができる。また、主観的な調整を排除し過去の統計的な関係のみを用いて“機械的に”成長率を予測していくことは、経済の現状を分析するうえでひとつの客観的な“ものさし”としても有用である。

本稿はこうした問題意識から作成されており、以下の構成は次のとおりである。まず、2. で、Forecast Combination の概要を紹介した後、3. で、実質 GDP 成長率の予測モデルの枠組みを提示する。次に4. では、本稿モデルの予測結果から、Forecast Combination が予測精度の改善に有効であることを示す。また、同じモデルの中で、Pooling Method、Regression Method、Pooling Method に Intercept Correction を組み合わせる方法、という3つの方法を試み、比較することを通じて、予測パフォーマンスを引き上げるために実務上注意すべき点を議論している。さらに、本稿のモデルと民間予測機関の平均的な見通しの予測パフォーマンスを比較している。最後に5. では、本稿の検討結果と今後の課題をまとめている。

2. Forecast Combination の概要

(1) Forecast Combination とは

ある経済指標が一国経済の多面的な動きを描写している場合、その指標に関連する全ての要素を加味して予測することが望ましい。例えば、国民経済計算の生産・分配・支出の三面から一国経済を描写した実質 GDP を予測する際には、三面それぞれの information set から予測を行うのが妥当であろう。ただ、その場合には、結果として複数の予測が併存するため、「どれが最も優れた予測であるのか」という疑問が生じ、何らかの基準に照らしひとつの予測を選択するケースが少なくない。そうすると、基準次第で選択される予測が異なってしまうことがあるほか、最終的にひとつの予測のみを利用するのであれば、そもそも多面性を勘案し複数の予測を立てた意味が失われてしまう。こうした問題を踏まえると、予測をひとつに絞り込むことを目指すのではなく、むしろ、手元にある全ての予測を統合して最良の予測を生み出す方法を考えることこそ望ましいのではないかと、といった発想が出てくる。これをストレートに実現したのが Forecast Combination である。具体的には、ある被説明変数について属性が異なる（固有の情報を持つ）説明変数から複数の予測（以下、「原予測」と呼ぶ）を作成し、それらに比べて予測パフォーマンスが高くなるように原予測を組み合わせ、新たな予測（以下、「合成予測」と呼ぶ）を生み出す方法である。別の言い方をすると、本来であれば、異なる information set をひとつの予測式の中で直接的に統合するのが普通であるところを、代わりに原予測を合成して、複数の information set を簡便的に組み合わせる手段とも言い得る。

Clemen (1989)によれば、Forecast Combination は、Bates and Granger (1969)と Reid (1968)という2つの先駆的な研究が公表された後、多くの研究者により理論的、実践的な研究が積み重ねられ、Forecasting の分野では一般的な手法となっている（実証研究の代表例としては、Stock and Watson (1998)等を参照）。このため、現在に至るまでに、多くの組み合わせ方法（以下、「合成方法」と呼ぶ）が提唱されているが、それらを大別すると、Pooling Method (Variance-Covariance Method とも呼ばれる)と Regression Method に整理される。以下では、まず Pooling Method の概要を Granger and Newbold (1986)等に従い説明した後、Regression Method を Diebold (1998)等を踏まえつつ紹介する。

(2) Pooling Method の概要

まず最もシンプルなケースから議論を始めるために、被説明変数 Y_t について属性が異なる 2 つの説明変数 X_t^1 と X_t^2 による unbiased¹ な原予測があるケースを想定する (説明変数が 3 つ以上であるケースへの拡張は補論を参照)。

$$Y_t^1 \equiv f^1(X_t^1), \quad e_t^1 \equiv Y_t - Y_t^1$$

$$Y_t^2 \equiv f^2(X_t^2), \quad e_t^2 \equiv Y_t - Y_t^2$$

但し、 $(Y_t^i, e_t^i), i=1,2$ はそれぞれ原予測とその誤差。なお、誤差については、次の性質を仮定する。

$$E(e_t^i) = 0, \quad E[(e_t^i)^2] = \sigma_i^2, \quad i=1,2$$

$$E(e_t^1 e_t^2) = \rho \sigma_1 \sigma_2$$

原予測の加重平均である合成予測 Y_t^c とその誤差 e_t^c をウェイト k により以下のとおり定義するが、合成予測が unbiased であること、合成予測の誤差の variance σ_c^2 は原予測の variance と covariance から計算できることは自明である。

$$Y_t^c = kY_t^1 + (1-k)Y_t^2 \tag{1}$$

$$e_t^c = ke_t^1 + (1-k)e_t^2$$

$$\sigma_c^2 = k^2\sigma_1^2 + (1-k)^2\sigma_2^2 + 2k(1-k)\rho\sigma_1\sigma_2 \tag{2}$$

本稿では、比較的一般的と考えられる 1 期先予測の Root Mean Squared Error² (RMSE) で予測パフォーマンスを評価する。RMSE の定義式は次のとおり。

$$RMSE = \sqrt{E(e_t^2)} = \sqrt{[E(e_t)]^2 + V(e_t)}$$

但し、 $V(e_t)$ は予測誤差の variance。RMSE の定義式から分かるとおり、RMSE

¹ 本稿では、unbiasedness を forecast error の期待値がゼロであることと定義している。

² RMSE は、計算が簡単であるため、予測パフォーマンスの評価基準として頻繁に利用されているが、評価基準として不変性が確保されていないなどの問題を持つことはよく知られている。このため、RMSE があくまでも便宜的な基準であり、絶対的な基準ではないことに十分留意すべきである。なお、RMSE の問題点については、Clements and Hendry (1998) 等が詳しい。

は予測誤差の bias と variance に依存しているため、予測が unbiased であることを仮定すると、合成予測の RMSE の最小化は誤差の variance を最小化することに等しい。そこで、合成予測の誤差の variance を示す(2)式を最小化する加重ウェイト k^* を導出する。

$$k^* = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \quad (3)$$

$$\sigma_c^{*2} = \frac{\sigma_1^2\sigma_2^2(1-\rho^2)}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2}$$

(3)式の意味を直感的に捉えると、誤差の variance が相対的に小さい原予測により大きなウェイトを与えることで、合成予測の variance を個々の原予測よりも小さくしようとするものである。この点を理解するため、仮に $\rho=0$ (2つの原予測が無相関) という極端なケースを考えると、加重ウェイトが $\sigma_i^2, i=1,2$ の相対的な大きさに逆数的に依存していることが分かる。また、この点は、

$$\sigma_c^{*2} \leq \min(\sigma_1^2, \sigma_2^2) \quad (4)$$

という関係が成り立つ³ことから、確認できる。

(3) Regression Method の概要

Pooling Method では、(1)式で示したとおり、予測誤差の variance から計算した加重ウェイトで原予測を線形結合するものである。これに対して、Regression Method では、

$$Y_t = \beta_0 + \beta_1 Y_t^1 + \beta_2 Y_t^2 + \varepsilon_t \quad (5)$$

という一般的な定式で被説明変数の実現値を原予測で回帰することで、定数項 β_0 と Pooling Method の加重ウェイトにあたるパラメータ β_1 と β_2 を推計し、それらを原予測の合成に用いる。

Regression Method では、文字通り regression を利用して原予測を合成するため、Pooling Method に比べると柔軟な定式化が可能であるほか、予測の枠組みを拡張することも容易である。例えば、Time-Varying Combining Weights と呼ばれる可変ウェイトの利用も、パフォーマンス改善に向けた工夫のひとつである。これは、時間とともに変化する被説明変数と説明変数の関係を的確に捉えるべく、

³ (4)式の等号が成立するのは、 ρ が σ_1/σ_2 ないし σ_2/σ_1 と等しい場合。

パラメータを可変にすることで合成予測に経済構造の変化等を反映させていくものである。本稿のモデルでは、パラメータの推計・原予測の合成を逐次的に行い、Time-Varying Combining Weights を取り入れている⁴。

また、Diebold (1998)等が指摘しているとおり、理論上、Pooling Method は Regression Method に $\beta_0 = 0$ と $\beta_1 + \beta_2 = 1$ を仮定したケースと同値である。両者の違いを理解するうえでは、Regression Method で $\beta_0 = 0$ を仮定しないことは重要である。すなわち、Pooling Method では、原予測の unbiasedness を仮定していた。しかし、この前提が構造変化等により成り立たないケースに Pooling Method を用いると、原予測の bias 故に加重ウェイトひいては合成予測に歪みが生じる恐れがある。一方、Regression Method では、原予測に含まれる bias が非ゼロの定数項で修正されるため、合成予測には bias が残らないことになる。このように Regression Method は、予測パフォーマンスの改善を追求するうえで、有効な枠組みと言えよう。

(4) 実際の予測作業にかかる疑問

Forecast Combination の理論からは、原予測が被説明変数に対してそれなりに説明力を有する限り、Forecast Combination を導入したり、組み合わせる原予測の数を増やすことにより、合成予測の予測パフォーマンスの改善に結びつく(少なくとも悪化しない)ことが期待されるが、これは実際の予測作業でも成り立つのであろうか。ひとつのポイントとしては、追加する原予測が他の原予測と重複しない information set を有しているか否かという点がある。この点は、Forecast Encompassing Test で確認することができる。このテストでは、2つの原予測を比較する場合、Regression Method の(5)式⁵、あるいは

$$Y_{t+1} - Y_t = \beta_0 + \beta_1(Y_{t+1}^1 - Y_t) + \beta_2(Y_{t+1}^2 - Y_t) + \varepsilon_{t+1}$$

で説明変数と原予測の関係を回帰する。もし、 $(\beta_1, \beta_2) = (1, 0)$ となった場合には、原予測 Y_t^1 が原予測 Y_t^2 の代表する全ての情報を包含(encompass)しているため、

⁴ 当然、Pooling Method においても加重ウェイトを逐次的に計算・更新していくことにより、Time-Varying Combining Weights を実現できる。

⁵ 時系列分析のテキストをみると、Forecast Encompassing Test として、(5)式に定数項 β_0 を持たない $Y_t = \beta_1 Y_t^1 + \beta_2 Y_t^2 + \varepsilon_t$ という定式を示している場合が多い。これは、原予測の unbiasedness を仮定しているためである。これに対して、本稿では、原予測に bias がある可能性を排除していないため、 β_0 を含む定式で Test を行っている。

Forecast Combination の文脈では、 Y_t^2 を原予測として追加することにより何らゲインがないことになる。他方、 $(\beta_1, \beta_2) = (1, 0)$ または $(0, 1)$ 以外である場合には、2つの原予測が被説明変数に対して固有の情報を持っていることになるため、両者の合成からゲインが生じるはずである。

では、Forecast Encompassing Test で固有の情報の存在が確認できれば、原予測の追加は必ず予測パフォーマンスの改善に結びつくのであろうか。それには、幾つかの問題点が残っている。

まず、第一の問題としては、in-sample での最良のパフォーマンスが必ずしも out-of-sample (本稿では1期先予測)での最良のパフォーマンスを保証している訳ではないことが挙げられる。すなわち、Pooling Method では、in-sample における合成予測の誤差の variance を最小にする加重ウェイトを、Regression Method では、同じく合成予測の誤差の二乗和を最小にする定数項・パラメータを、それぞれ計算しているが、その結果が out-of-sample においても合成予測の誤差の variance や二乗和を最小にするとは限らない。例えば、経済構造が変化すると、原予測が不安定になったり、原予測の相対的な説明力が急速に変化したりする。その場合には、推計される加重ウェイトやパラメータ等に歪みが生じるため、out-of-sample で最良の予測パフォーマンスが必ず実現するとは言い難い。

第二の問題としては、予測パフォーマンスの評価基準との関係がある。本稿では、RMSE を評価基準として選択しているが、RMSE を二乗した Mean Squared Error (MSE)が、

$$MSE = [E(e_t)]^2 + V(e_t)$$

であることを踏まえると、Pooling Method において、bias が大きい原予測を追加した場合、原予測の追加により variance が縮小する一方で、合成予測の bias が増大する結果、合成予測の RMSE がむしろ悪化してしまう恐れがある。

また、Pooling Method と Regression Method は、実務上何が異なるのかという点も疑問になろう。原予測の unbiasedness と十分に大きい sample を仮定すると、事前的には両者のパフォーマンスに違いはない。しかし、実際の予測作業では、これらの条件を確保することが難しいケースが少なくない。そうしたケースでは、定数項で bias を修正できるうえ、制約条件が少ない Regression Method の方がより小さい RMSE を実現できる可能性が高い。ただ、原予測の bias が問題と

なるケースでは、Intercept Correction⁶と呼ばれる方法で原予測の bias を修正したうえで Pooling Method で合成すると、事実上、Regression Method と同じ結果が得られると予想される。この直感については、4. で、その妥当性を確認していく。

3. 予測方法とデータ

(用いた原予測の種類)

本稿では、Forecast Combination を用いて月次経済指標から実質 GDP⁷の前期比伸び率を予測するモデルを提示し、その推計を通じて原予測に比べて合成予測の予測パフォーマンスが改善することを示す。土台となる原予測は、大別して、「積み上げ方式」と、「直接予測方式」の2つである。

まず、積み上げ方式では、需要コンポーネント毎に密接に係る経済指標から前期比を予測し、それに需要コンポーネントが実質 GDP に占める割合を乗じて寄与度を計算したうえで、その総和である実質 GDP 前期比伸び率を求めている⁸。一方、直接予測方式では、a)経済活動全体に対するカバレッジが高いと

⁶ Intercept Correction とは、計量モデル等で予測を行う場合、予測パフォーマンスを引き上げるために、モデルの運用担当者が推計されたパラメータを、経験則等に照らして ad-hoc に手直しする行為であり、典型的には、定数項を修正することが多い。その目的は、予測の定式上、組み込まれていないが、先行きに影響を及ぼすと予測される要素の影響を予め修正すること、定式化が不完全であるため、先行きに一定の予測誤差が生じると予想される場合、その期待値を予め修正すること、の2つに整理される。その概要・理論については、Clements and Hendry (1998)等が詳しいため、本稿では、説明を省略する。

⁷ 実質 GDP 等国民経済計算のデータは、1968年に国連で採択・勧告された「1968年国民経済計算体系」(68SNA)を基にした計数であり、2000年10月以降順次公表された「1993年国民経済計算体系」(93SNA)に基づく計数ではない。なお、90/1Q~99/1Qの計数は確報値、99/2Q~4Qの計数は速報値。

⁸ 説明変数として選択した経済指標を整理すると、次のとおり(詳細は Appendix 参照)。なお、複数の予測を合成する場合には、原予測の合成方法に準じて合成している。

	説明変数(経済指標)	予測方法
公的需要	公共工事請負金額 公共工事出来高	名目前年比を、それぞれから予測し、合成。それを実質前期比に換算。
個人消費	販売指標(百貨店売上高等) 家計調査・実質消費支出額 家計調査・消費水準指数	実質前期比を、それぞれから予測し、合成。
純輸出	国際収支統計(輸出、輸入)	輸出、輸入の実質前期比をそれぞれ予測し、純輸出を計算。

考えられる3種類の雇用統計と、b)供給サイドから一国経済を捉える統計を1つ採用した。具体的には、マクロ生産関数の労働投入量の代理変数である常用雇用指数×1人当たり総労働時間指数(いずれも毎月勤労統計)、伝統的に「景気」との相関が高いといわれる有効求人倍率(職業安定業務統計)、Okun's Lawを意識した完全失業率(労働力調査)に加えて、一国経済の供給サイドに注目した全産業活動指数の4つである。

(原予測を推計する際の基本的なルール)

いずれの原予測においても、実質季調値の前期比(公的需要のみ名目原計数の前年比)をOLS(誤差に1次の自己相関を仮定した場合を除く)で推計している(用いた原予測のスペック⁹とデータの詳細については、Appendixの予測式一覧とデータ一覧を参照)。また、原予測を作成する場合にも複数の予測を組み合わせる積み上げ方式と完全失業率については、原予測の合成方法に準じて、この段階から、Pooling Method、Regression Method、Pooling MethodとIntercept Correctionを併用する方法という3通りの合成方法を使い分けている。被説明変数の先行きを予測する際、まずパラメータ等を推計した後、推計期間の1期先(以下、「予測対象期間」と呼ぶ)における説明変数を外挿して、予測値を計算している。予測対象期間は90/1Q~99/4Qの10年間。各々の予測において、推計期間を10年間で固定し、予測対象期間が1四半期ずれる毎に推計期間の始点・終点を1四半期ずらしている¹⁰。

(米国における先行研究と本稿の予測モデルの比較)

米国では、“Current Quarter Model”と呼ばれる、直近期ないし翌四半期の実質

設備投資	機械受注額 建築着工予定額 リース契約額 鉱工業出荷・資本財除く輸送 機械	実質前期比を ~ それぞれから予測し、合成。
住宅投資	新設住宅着工戸数	実質前期比を予測。

⁹ 原予測の定式は、被説明変数の前期比を定数項、説明変数の前期比(ラグ項が有意である場合には数次のラグを持たせた説明変数の前期比)で回帰したものを基本型として、各項の有意性(t値)やAIC等を勘案して決定した。

¹⁰ 本稿で行うように推計期間を固定する代わりに、推計期間の始点を固定し、予測対象期間の更新に伴って推計期間を延長する方法もある。もっとも、本稿では、推計期間の始点を固定した場合には、推計期間の延長、サンプル数の増加により直近のサンプルの説明力が相対的に低下することを恐れ、推計期間を固定する方法を選択した。

GDP 成長率を予測するモデルの研究が進んでおり、地区連銀を中心に幾つかの論文が公表されている。例えば、Trehan (1989)、同(1992)では、雇用者数、小売販売高、鉱工業生産等から実質 GDP 成長率を予測する San Francisco 連銀の “ Monthly Indicators Model ” の枠組みを示しており、Ingenito and Trehan (1996)は、その延長線上で若干の調整を施している。また、Braun (1990)は、実質 GDP と雇用統計の関係に注目し、総労働投入量と完全失業率 (Okun’s Law) により実質 GDP 成長率を予測し、その結果を Pooling Method で合成している。この間、Miller and Chin (1996)では、月次経済指標を扱う Bayesian VAR モデルを構築し、その予測結果と Minneapolis 連銀の四半期 Bayesian VAR モデルの結果を Regression Method で組み合わせて、同時期と翌四半期の実質 GDP 成長率の予測パフォーマンスがどれだけ改善するかを検証している。さらに、Stark (2000)では、Miller and Chin (1996)の枠組みに基づいて、Bayesian VEC モデルの応用可能性を検証している。

これらの先行研究と比較すると、本稿で提示しているモデルの特徴点として、次の3点が指摘できる。すなわち、積み上げ方式を用いていること、また、その結果として、需要コンポーネント別の要因分析が可能になっていること、雇用統計以外に全産業活動指数というわが国特有の包括的な供給統計を利用していること、原予測の作成段階でも Forecast Combination を用いて数多くの変数を取り込む努力をしていること、である。また、先行研究では、ad-hoc に Forecast Combination の方法を選択しているのに対して、3つの合成方法を試み、その違い等を議論している点も、本稿の特徴点と言えよう。

4. 予測パフォーマンスの比較

(1) Pooling Method のパフォーマンス

本節では、実際に月次経済指標から同時期の実質 GDP 成長率を予測することを通じて、2. で提示された疑問等を検討する。以下では、Pooling Method で合成したケース、Regression Method で合成したケース、Intercept Correction により原予測の bias を修正した後に Pooling Method で合成したケースを順に推計し、比較・検討する。

図表1では、Pooling Method で用いた原予測のパフォーマンスを示している。まず、原予測の1期先予測 (out-of-sample) の RMSE をみると、積み上げ方式が原予測中最小の RMSE を実現しており、積み上げ方式が予測方法として有用で

あることが分かる。一方、雇用統計を用いた3つの原予測については、bias、varianceともに大きいほか、総労働投入量と完全失業率による原予測については、他の原予測に比べて out-of-sample における予測パフォーマンスの悪化（1期先予測の RMSE と in-sample の S.E.の差）が大きく、実質 GDP 成長率の予測式として相対的に不安定であることが指摘できる。

次に、原予測が固有の情報を有しているかをチェックするため、Forecast Encompassing Test を行う。ここでは、予測対象期間（90/1Q～99/4Q）において2つの原予測を(5)式のかたちに合わせて、Test を行った。パラメータ等を見ると、積み上げ方式は、総労働投入量、有効求人倍率、完全失業率といった雇用統計による原予測を包含していること、総労働投入量と組み合わせた4つの原予測全てについてパラメータが1近傍となっており、総労働投入量による原予測には固有の情報がほとんどないこと、有効求人倍率を完全失業率や全産業活動指数と組み合わせた場合、定数項 β_0 が有意になっており、これらの組み合わせに bias が存在することなどが見て取れる。なお、この点は、bias を修正すべく Pooling Method に Intercept Correction を組み合わせる方法が、ひとつの望ましい対応であることを示唆しているとみなし得る。

図表2では、「Forecast Combination の導入や原予測の追加は、実際に合成予測のパフォーマンスの改善に結びつくのか」という問題を検討するため、5つの原予測を全て合成したケース、4つの原予測を順繰りに組み合わせたケース、そして結果として1期先予測の RMSE を最小にする組み合わせ（以下、「最適な組み合わせ」と呼ぶ）を比較している。

まず、全ての原予測を合成したケースをみると、in-sample では、原予測に多少の bias があるにも拘わらず、Pooling Method の理論が含意するとおり、in-sample でみた時には最小の S.E.を実現している。もっとも、1期先予測では、雇用統計のいずれかを除く4つの原予測を合成したケースに比べて RMSE が小さくなっていない。この点から、Forecast Combination の導入や原予測数の増加が必ずしも out-of-sample における合成予測の改善に結びつかないケースがあり得ることが分かる。また、1期先予測の MSE を bias の二乗と variance に分解してみると、全ての原予測を合成したケースでは、積み上げ方式に比べて bias、variance ともに拡大している。このように1期先予測のパフォーマンスが悪化した原因のひとつは、1期先予測の RMSE と in-sample の S.E.の差から推察できる。すなわち、総労働投入量と完全失業率による原予測が out-of-sample での予測パフォーマンスが悪い（予測として不安定である）にも拘わらず、非ゼロの加重ウェイトが

与えられている結果、原予測の不安定性が合成予測に持ち込まれて1期先予測のRMSEがむしろ拡大してしまったと考えられる。

次に、最適な組み合わせについて検討する。Forecast Encompassing Testの結果から、積み上げ方式が3つの雇用統計による原予測を包含していること、積み上げ方式と全産業活動指数の組み合わせでは、両者にかかるパラメータが有意であることが分かった。これらを踏まえると、1期先予測のRMSEが最小になる最適な組み合わせは、積み上げ方式と全産業活動指数から構成されると考えられ、事実、2つ以上の原予測を順次組み合わせてRMSEを比較すると、この組み合わせのRMSEが最小になることが確認されている。この最適な組み合わせのパフォーマンスをみると、全ての原予測を合成したケースに比べて、in-sampleのS.E.の改善幅は見劣りするものの、予測としての安定性が改善し、1期先予測では誤差のvarianceの縮小等を梃子に最小のRMSEを実現している。また、時系列でも、予測対象期間である90/1Q~99/4Qの間で、一種の信頼区間に相当する合成予測 \pm RMSE \times 2の範囲から実績が逸脱したのは、公共投資と個人消費が実質GDPを大きくスイングさせた96/1Q¹¹と99/4Q¹²の2回のみであり、それ以外の時期では概ね良好なパフォーマンスとなっている。ただ、予測対象である実質GDPの前期比が \pm 2%程度の範囲内で推移する中、RMSEが0.683と比較的大きな値であるため、合成予測の値をpoint estimateとして用いることには一定の留保が必要となろう¹³。

最後に図表3でPooling Methodにおける加重ウェイトの推移をチェックする。全ての原予測を合成したケースでは、予測対象期間を通じて、3つの雇用指標の加重ウェイトのうち少なくともひとつが負になるとともに、2つのウェイトがsymmetricに動いている。具体的には、90~95年は総労働投入量と有効求人

¹¹ 96/1Q(確報値)は、95年9月の経済対策の効果顕現化から、政府支出が実質GDP前期比寄与度+0.9%(前期比+4.9%)と大幅に増加したほか、個人消費も、パソコン、携帯電話や旅行の好調に閏年要因や自動車の期末販促の効果が加わり、同+0.6%(同+1.1%)と増加した。この結果、実質GDP全体で前期比+2.6%と、73/1Q(前期比+3.3%)以来の高成長となった。

¹² 99/4Q(二次速報改訂値)は前期比1.6%と大幅に落ち込んでいるが、これは、冬期賞与の減少等を映じて個人消費が実質GDP前期比寄与度1.0%(前期比1.6%)と落ち込んだほか、政府支出が98年10月の「緊急経済対策」の効果一巡等から同0.6%(同3.2%)と減少したためと考えられる。

¹³ また、統計量をみると、MeanやMedianでは合成予測が実績をよくmimicしているが、SkewnessやKurtosisでは実績に比べて合成予測がasymmetricでfat tailsである。この点からも、合成予測が実績を十分に再現しているとは言い難い。

倍率が、96～98年央は有効求人倍率と完全失業率が、98年央～99年は完全失業率と総労働投入量が、それぞれ、前者のウェイトが正、後者が負となり、symmetricに動いている。これには予測誤差の相関¹⁴が影響していると考えられる。すなわち、実質GDPが労働市場に大きな影響を及ぼさずに変動した場合、3つの原予測はいずれも実質GDPの動きをフォローできないため、予測誤差が強く相関することになる。こうした場合には、ある原予測に正のウェイトを、もうひとつに負のウェイトを与えて、予測誤差の相関の影響を打ち消すように、加重ウェイトが計算されたものと考えられる。他方、最適な組み合わせでは、他の原予測との予測誤差の相関が相対的に弱い積み上げ方式と全産業活動指数を合成している結果、加重ウェイトが予測対象期間を通じて正で推移しており、予測誤差の相関による歪みが回避されていることが見て取れる。なお、最適な組み合わせでは、90年代後半から積み上げ方式の加重ウェイトが上昇しており、原予測の相対的な説明力が大きく変化していることが直感的に理解できる。

以上の議論を踏まえると、合成予測のパフォーマンスを改善するための条件としては、原予測にbiasがないこと、原予測が予測式として安定していることに加え、Forecast Encompassing Testにより他の原予測に包含されていないことが確認された原予測を組み合わせること、予測誤差の相関が低く、全ての原予測の加重ウェイトが正であることなどが挙げられよう。

(2) Regression Method のパフォーマンス

次に、Regression Methodで合成したケースのパフォーマンスをみる。まず、原予測のパフォーマンスやForecast Encompassing Testの結果を確認する(図表4)と、原予測の作成段階でForecast Combinationを行っている積み上げ方式と完全失業率については、Pooling Methodにおける結果と大きな違いはないことが分かる。そのうえで、図表5、図表6をみると、次の特徴点が指摘できよう。

¹⁴ 予測対象期間の実績値で予測誤差の相関係数の(期間平均)を求めると、次のとおり。

	積み上げ方式	総労働投入量	有効求人倍率	完全失業率	全産業活動指数	平均
積み上げ方式	0.501	0.514	0.446	0.593	0.513
総労働投入量	0.501	0.880	0.819	0.643	0.711
有効求人倍率	0.514	0.880	0.882	0.676	0.738
完全失業率	0.446	0.819	0.882	0.604	0.688
全産業活動指数	0.593	0.643	0.676	0.604	0.629

積み上げ方式と全産業活動指数を合成した最適な組み合わせが、Pooling Method と同様、予測としての安定性と bias の小ささ等により 1 期先予測の RMSE を最小にしている。また、RMSE が 0.651 と、Pooling Method に比べて若干縮小しており、bias を定数項で修正し得る Regression Method の方がより良い予測パフォーマンスを示した。

推計された定数項・パラメータをみると、最適な組み合わせでは、定数項の絶対値がほぼゼロ近傍まで縮小しており、bias が相当程度小さいものであることが分かる。

最適な組み合わせを Regression Method で合成した結果(図表 6)をみると、RMSE の縮小から予想されるとおり、合成予測が実績値を“再現する”程度が増している¹⁵。

(3) Pooling Method に Intercept Correction を組み合わせたケース

2.(2) 同(3)の議論から明らかなように、原予測の unbiasedness を仮定する Pooling Method では、bias のある原予測を合成した場合、(3)式で計算される加重ウェイトが最適ではなくなる惧れがあるほか、bias を持つ原予測の加重ウェイトがゼロでない限り、合成予測に bias が“転移”してしまうため、予測パフォーマンスは Regression Method に及ばないことになる。そこで 2.(4)では、原予測の bias を Intercept Correction で予め修正した後、Pooling Method で合成すると、予測パフォーマンスを Regression Method に近づけることができるのではないかとの問題提起を行った。以下では、実際に Pooling Method に Intercept Correction を組み合わせて、どの程度予測パフォーマンスが向上するかを検証する。

具体的には、1 期先予測の bias の期待値が in-sample の予測誤差の平均と等しいと仮定し、推計期間(10 年間)を通じた予測誤差の平均を原予測から控除することで、原予測の Intercept Correction を行っている¹⁶。図表 7 をみると、最適な組み合わせの RMSE が 0.672 と、Intercept Correction をしなかった場合の 0.683

¹⁵ Regression Method の合成結果を Pooling Method の合成結果と比較すると、グラフでも、96/1Q、97/2Q、99/4Q といった実質 GDP 成長率が大きく振れた時期において実績値と予測値の乖離が縮小しているほか、統計量に照らしても、実績値と予測値のズレが縮小している。

¹⁶ 原予測を作成する際に複数の予測系列を合成している場合についても、原予測の合成と同様に、予め bias を修正した後に Pooling Method で合成する方法を用いている。

に比べて僅かに改善したものの、Regression Method の 0.651 には及ばなかった。また、MSE を分解してみると、RMSE の改善が variance の縮小で実現する一方、bias の絶対値は逆に拡大している。このことは、Intercept Correction の実効性が、1 期先予測の bias をどの程度的確に予測できるのかに依存していることを示している。すなわち、原予測の定式が安定していれば、そこに含まれる bias も安定しているはずである。その場合には、1 期先予測の bias の期待値が bias の実現値に等しいとみなし得るため、Intercept Correction で 1 期先予測の bias を軽減できる。反対に、原予測の定式が不安定なものであれば、1 期先予測の bias の期待値と bias の実績値の関係も不安定であるため、Intercept Correction が結果として 1 期先予測の bias を増幅させる恐れがある。また、何らかのショックにより実績値の予測誤差が膨らんだ時期がある場合には、当該期を含む bias の実績値は、1 期先予測の bias の期待値としては過大であるため、同様の懸念が生じる¹⁷。これらの点を踏まえると、Pooling Method に Intercept Correction を組み合わせることは、Pooling Method の予測パフォーマンスを引き上げるひとつの工夫であるが、如何に bias を修正するかという点にその実効性がかかっていよう。

(4) パフォーマンスの比較

(3つの合成手法の比較)

本稿では、3つの Forecast Combination の方法を試みた。改めて整理すると、理屈のうえでは、Regression Method が Pooling Method に比べてより高い予測パフォーマンス（本稿ではより小さい RMSE）を実現することが予想される。これは、理論上、Regression Method がより一般的な定式化であるうえ、パフォーマンスの改善を目指した工夫がしやすいこと、構造変化等から原予測に bias が生じている状況であっても、Regression Method であれば、bias を修正しつつ原予測を合成できることなどを考えれば、明らかである。しかし、実際のデータを用いて検証してみると、その差はそれほど大きなものではない。図表 8 で予測対象期間（90/1Q～99/4Q）を通じた RMSE のほか、8 四半期分の RMSE を逐次計算した結果を示している。これをみると、殆どの期間で Regression Method の RMSE が Pooling Method を下回っているが、前者と後者の差は、RMSE の絶対値で 0.03（比率で 5%弱）に過ぎない。この点を踏まえると、実務的な観点

¹⁷ こうした問題を回避するために、Clements and Hendry (1998)では、直近期の bias により大きなウェイトを置いた Intercept Correction を提案している。

に照らせば、本事例では、3つの Forecast Combination の手法の間に大きな違いがないように思われる。むしろこれまでの実証結果は、どの合成手法を選ぶかよりも、bias の小ささや予測式としての安定性という意味で原予測の予測パフォーマンスを引き上げていくことが、モデルの予測パフォーマンスを改善していくうえで、より重要なポイントであることを示している。

（Consensus Forecast との比較）

次に、Forecast Combination を用いた本稿のモデルが、実質 GDP の予測モデルとしてどの程度有用なものであるかを検証する。比較対象として民間予測機関の予測を集めた Consensus Forecasts (C.F.) を選択。対象期間は、C.F. が日本の四半期別実質 GDP 成長率の見通しを掲載した 96/4Q ~ 99/4Q とした。C.F. は、年間 4 回、日本の四半期別成長率の予測を更新するが、1 期先予測については、予測時点の違いから 2 種類のものがある。すなわち、予測対象期間の最終月のデータが入手できない時点での予測（例えば 96/12 月時点での 96/4Q の予測、掲載データ：96/4Q ~ 99/4Q の 13 四半期分）と、最終月のデータが入手できる時点での予測（例えば 97/3 月初時点での 96/4Q の予測、掲載データ：96/4Q ~ 97/2Q、97/4Q ~ 98/1Q、98/4Q の 6 四半期分）の 2 つである。これらの RMSE を計算すると、C.F. がいずれも 2 % 近くなる一方、本稿の合成予測の RMSE は 1 % 未満となっている（図表 8）。評価基準としての RMSE の問題点に加え、C.F. が様々な予測の平均値であることや、C.F. が real-time-data を用いた予測である一方、本稿は revised data を用いた予測であり、厳密には同じ競争条件にないことなどを勘案しても、積み上げ方式と Forecast Combination を導入した本稿のモデルは、直近期の実質 GDP 成長率の予測モデルとしてある程度有用なものであると評価できるだろう。

5. 結び

（検討結果のまとめ）

本稿の検討結果を整理すると、以下のとおりである。

- Forecast Combination は RMSE の改善に資する。直感的には、原予測の数を増やす程、RMSE が改善すると予想されたが、実際の予測作業では、パフォーマンスの悪い原予測を追加した場合には、合成予測の安定性等が阻害される結果、逆に RMSE が増大するケースが起り得る。

- 合成予測のパフォーマンスを改善するためには、原予測の bias の小ささと安定性に加えて、Forecast Encompassing Test で他に包含されていないことが確認された原予測を組み合わせるなどことが重要である。
- Pooling Method に比べてより一般的な定式である Regression Method の方が、より小さい RMSE を実現できる。また、原予測の bias を Intercept Correction で修正することは、Pooling Method を用いるうえでのひとつの工夫である。ただ、実務的な観点からは、本稿で紹介した 3 つの合成手法の違い (RMSE の差) は、それほど大きくない。
- 本稿のモデルは、RMSE が民間予測機関の平均的な予測値の半分未満であり、直近期の実質 GDP 成長率の予測モデルとして有用である。

(今後の課題)

本稿で示した Forecast Combination による予測の改善には、実質 GDP 以外にも様々な応用可能性がある。例えば、物価についてはフィリップス曲線を始め多くの理論が存在するが、そうした理論に基づく原予測を Forecast Combination で合成することによって、予測パフォーマンスの改善が図られるかもしれない。また、加重ウェイトの移り変わりをみれば、どの理論がどの時期の物価変動を説明するのに有効であったのか、を分析できよう。

また、本稿のモデルに説明変数の先行きを予測する手法を取り込めば、当該四半期の最終月の説明変数が出揃うのを待たずに、当該四半期の実質 GDP 成長率の予測が可能になる。さらに、説明変数の予測期間を延ばせば、同時期のみならず翌四半期の実質 GDP 成長率を予測することが可能になる。事実、米国の先行研究では、欠損する説明変数の補完方法¹⁸に深い関心を寄せている。これらの先行研究のわが国経済への応用については、今後の検討課題としていきたい¹⁹。

以 上

¹⁸ 具体的には、AR (Braun (1990))、Bivariate ARMA (Zadrozny (1990))、Bayesian VAR (Trehan (1989)、同 (1992))、Miller and Chin (1996)、Bayesian VEC (Stark (2000)) など。

¹⁹ なお、課題としては、先行研究のわが国への応用のほかに、本稿モデルを、先般公表された 93SNA ベースの成長率に対応させることがあるが、それについては目下必要な改訂作業を行っている。

【参考文献】

- Bates and Granger (1969), "The Combination of Forecasts," *Operational Research Quarterly*, 20, 451-468.
- Braun, S. (1990), "Estimation of Current-Quarter Gross National Product by Pooling Preliminary Labor-Market Data," *Journal of Business & Economic Statistics*, Vol.8 No.2, 293-304
- Clemen, R.T. (1989), "Combining Forecasts: A Review and Annotated Bibliography," *International Journal of Forecasting* 5 (1989) 559-583
- Clements, M.P., and Hendry, D.F. (1998), *Forecasting Economic Time Series*, Cambridge: Cambridge University Press.
- Diebold, F. (1998), *Elements of Forecasting*, Cincinnati: South-Western College Publishing.
- Diebold, F. and Lopez, J.A. (1995), "Forecast Evaluation and Combination," Manuscript (Department of Economics, University of Pennsylvania).
- Granger, C.W.J., and Newbold, P. (1986), *Forecasting Economic Time Series*, 2nd Edition, New York: Academic Press.
- Ingenito, R. and Trehan B. (1996), "Using Monthly Data to Predict Quarterly Output," *Federal Reserve Bank of San Francisco Economic Review* (1996), Number 3.
- Miller, P.J. and Chin, D.M. (1996), "Using Monthly Data to Improve Quarterly Model Forecasts," *Federal Reserve Bank of Minneapolis Quarterly Review*, spring 1996.
- Reid (1968), "Combining Three Estimates of Gross Domestic Product," *Economica*, 35, 431-444.
- Stark, T. (2000), "Does Current-Quarter Information Improve Quarterly Forecasts for the U.S. Economy?" *Federal Reserve Bank of Philadelphia Working Paper No.00-2*, January 2000.
- Stock, J.H, and Watson M.W. (1998), "A Comparison of Linear and Nonlinear Univariate Models For Forecasting Macroeconomic Time Series," *NBER Working Paper* 6607.
- Trehan, B. (1992), "Predicting Contemporaneous Output," *Federal Reserve Bank of San Francisco Economic Review* (1992), Number 2.
- Trehan, B. (1989), "Forecasting Growth in Current Quarter Real GNP," *Federal Reserve Bank of San Francisco Economic Review*, winter, 1989.
- Zadrozny (1990), "Forecasting U.S. GNP at Monthly Intervals with an Estimated Bivariate Time Series Model," *Federal Reserve Bank of Atlanta Economic Review*, November/December 1990.

【補論】説明変数が3つ以上あるケースへのPooling Methodの拡張

説明変数が3つ以上であるケースは、2つのケースの単純な拡張である。被説明変数 Y_t について、 m 個の unbiased な原予測があると仮定する。

$$Y_t^i \equiv f^i(X_t^i), \quad e_t^i \equiv Y_t - Y_t^i, \quad i = 1, \dots, m$$

これら m 個の式を行列式で表現し、合成予測を加重ウェイト $k' = [k^1, \dots, k^m]$ に基づく加重平均として求める。

$$F_t' = [f^1(X_t^1), \dots, f^m(X_t^m)]$$

$$e_t = Y_t I - F_t$$

$$Y_t^c = k' F_t \tag{補 1}$$

但し、 $E(e_t e_t') = \Sigma$ 、 $I' = [1, \dots, 1]$ である。


(補 1)式に係る誤差項の variance は、(3)式を拡張した

$$k^* = (\Sigma^{-1} I) / (I' \Sigma^{-1} I) \tag{補 2}$$

により最小化される。

Pooling Methodで用いた原予測のパフォーマンス

1. 原予測の推移



2. 原予測のパフォーマンス (90/1Q~99/4Q)

	1期先予測					in-sample (参考)	
	RMSE	Bias	MSE	Biasの2乗	Variance	S.E.	-
積み上げ方式	0.726	0.038	0.527	0.001	0.525	0.601	0.125
総労働投入量	1.034	-0.187	1.069	0.035	1.034	0.646	0.388
有効求人倍率	0.950	-0.222	0.902	0.049	0.853	0.646	0.304
完全失業率	1.021	-0.232	1.042	0.054	0.989	0.620	0.401
全産業活動指数	0.826	-0.150	0.682	0.022	0.659	0.545	0.281

3. Forecast Encompassing Testsの結果 (90/1Q~99/4Q)

第1項、第2項	0		1		2	
	定数項	S.E.	第1項	S.E.	第2項	S.E.
積み上げ方式、総労働投入量	0.197	0.181	1.027	0.176	-0.325	0.297
積み上げ方式、有効求人倍率	0.107	0.221	0.979	0.202	-0.115	0.393
積み上げ方式、完全失業率	-0.114	0.152	0.837	0.164	0.474	0.255
積み上げ方式、全産業活動指数	-0.137	0.141	0.723	0.174	0.534	0.215
総労働投入量、有効求人倍率	-0.216	0.270	-0.253	0.452	1.227	0.520
総労働投入量、完全失業率	-0.165	0.247	0.238	0.344	0.882	0.317
総労働投入量、全産業活動指数	-0.403	0.227	0.487	0.294	1.007	0.217
有効求人倍率、完全失業率	-0.535	0.260	0.924	0.362	0.847	0.289
有効求人倍率、全産業活動指数	-0.530	0.229	0.778	0.334	0.901	0.213
完全失業率、全産業活動指数	-0.321	0.182	0.588	0.280	0.842	0.224

(注) シャドー部分は係数がゼロとの仮説が95%信頼区間で棄却されたことを示す。


Pooling Methodによる合成予測の結果

1. 合成予測のパフォーマンス (90/1Q ~ 99/4Q)

	1期先予測					in-sample	(参考)
	RMSE	Bias	MSE	Biasの2乗	Variance	S.E.	-
全ての原予測	0.752	-0.134	0.566	0.018	0.548	0.457	0.295
積み上げ方式以外の4つ	0.850	-0.208	0.722	0.043	0.679	0.491	0.359
総労働投入量以外の4つ	0.742	-0.132	0.551	0.017	0.533	0.465	0.277
有効求人倍率以外の4つ	0.746	-0.099	0.557	0.010	0.548	0.475	0.272
完全失業率以外の4つ	0.713	-0.102	0.509	0.010	0.498	0.480	0.233
全産業活動指数以外の4つ	0.818	-0.107	0.669	0.011	0.658	0.492	0.326
最適な組み合わせ	0.683	-0.070	0.467	0.005	0.462	0.499	0.184

(注) 最適な組み合わせとは、積み上げ方式と全産業活動指数を合成したものの。

2. 最適な組み合わせによる合成予測と実績の比較




3. 統計面からの比較 (90/1Q ~ 99/4Q)


	平均値	中位値	最大値	最小値	S.D.	Skewness	Kurtosis
実績	0.327	0.429	2.616	-2.006	1.017	-0.123	2.892
合成予測	0.396	0.485	1.564	-1.266	0.566	-0.771	4.152

Pooling Methodにおける加重ウェイトの推移

1. 全ての原予測を合成した場合の加重ウェイト




2. 最適な組み合わせの加重ウェイト



Regression Methodで用いた原予測のパフォーマンス

1. 原予測の推移



2. 原予測のパフォーマンス (90/1Q ~ 99/4Q)

	1 期先予測					in-sample (参考)	
	RMSE	Bias	MSE	Biasの2乗	Variance	S.E.	-
積み上げ方式	0.719	0.068	0.517	0.005	0.513	0.588	0.131
完全失業率	1.015	-0.190	1.031	0.036	0.995	0.618	0.397

(注) ここでは、原予測においてForecast Combinationを用いている積み上げ方式と完全失業率の予測結果を掲載している。他の3つの原予測の予測結果は、Pooling Methodと同じである。

3. Forecast Encompassing Testsの結果 (90/1Q ~ 99/4Q)

第1項、第2項	0		1		2	
	定数項	S.E.	第1項	S.E.	第2項	S.E.
積み上げ方式、総労働投入量	0.287	0.176	0.941	0.150	-0.396	0.290
積み上げ方式、有効求人倍率	0.199	0.220	0.900	0.173	-0.190	0.385
積み上げ方式、完全失業率	-0.032	0.150	0.759	0.145	0.389	0.258
積み上げ方式、全産業活動指数	-0.084	0.139	0.663	0.150	0.502	0.212
総労働投入量、有効求人倍率	-0.216	0.270	-0.253	0.452	1.227	0.520
総労働投入量、完全失業率	-0.166	0.247	0.237	0.344	0.887	0.317
総労働投入量、全産業活動指数	-0.403	0.227	0.487	0.294	1.007	0.217
有効求人倍率、完全失業率	-0.536	0.260	0.923	0.362	0.851	0.289
有効求人倍率、全産業活動指数	-0.530	0.229	0.778	0.334	0.901	0.213
完全失業率、全産業活動指数	-0.322	0.182	0.592	0.280	0.841	0.224

(注) シャドー部分は係数がゼロとの仮説が95%信頼区間で棄却されたことを示す。

Regression Methodによる合成予測

1. 合成予測のパフォーマンス (90/1Q ~ 99/4Q)

	1 期先予測					in-sample	(参考)
	RMSE	Bias	MSE	Biasの2乗	Variance	S.E.	-
全ての原予測	0.721	0.012	0.521	0.000	0.520	0.427	0.295
積み上げ方式以外の4つ	0.825	-0.083	0.680	0.007	0.673	0.470	0.354
総労働投入量以外の4つ	0.710	-0.013	0.504	0.000	0.504	0.440	0.270
有効求人倍率以外の4つ	0.722	0.038	0.521	0.001	0.520	0.433	0.289
完全失業率以外の4つ	0.691	0.012	0.478	0.000	0.478	0.451	0.240
全産業活動指数以外の4つ	0.793	0.020	0.629	0.000	0.629	0.462	0.331
最適な組み合わせ	0.651	-0.039	0.424	0.002	0.423	0.486	0.165

(注) 最適な組み合わせとは、積み上げ方式と全産業活動指数を合成したものの。


2. 推計された定数項・パラメータ

原予測の組み合わせ方	定数項	積み上げ 方式	総労働 投入量	有効求人 倍率	完全 失業率	全産業 活動指数
全ての原予測	-0.310	0.328	0.369	-0.223	0.426	0.465
積み上げ方式以外の4つ	-0.345	0.427	-0.091	0.347	0.721
総労働投入量以外の4つ	-0.218	0.349	-0.068	0.496	0.491
有効求人倍率以外の4つ	-0.375	0.325	0.290	0.363	0.453
完全失業率以外の4つ	-0.314	0.330	0.470	0.058	0.505
全産業活動指数以外の4つ	-0.224	0.505	0.427	-0.182	0.520
最適な組み合わせ	-0.025	0.404	0.633


(注) 最適な組み合わせとは、積み上げ方式と全産業活動指数を合成したものの。
予測期間 (1990/1Q ~ 1999/4Q) の平均値。

最適な組み合わせをRegression Methodで合成した場合

1. 最適な組み合わせによる合成予測と実績の比較



2. 定数項・パラメータ



3. 統計面からの比較 (90/1Q ~ 99/4Q)

	平均値	中位値	最大値	最小値	S.D.	Skewness	Kurtosis
実績	0.327	0.429	2.616	-2.006	1.017	-0.123	2.892
合成予測	0.366	0.432	1.692	-1.514	0.635	-0.721	4.138

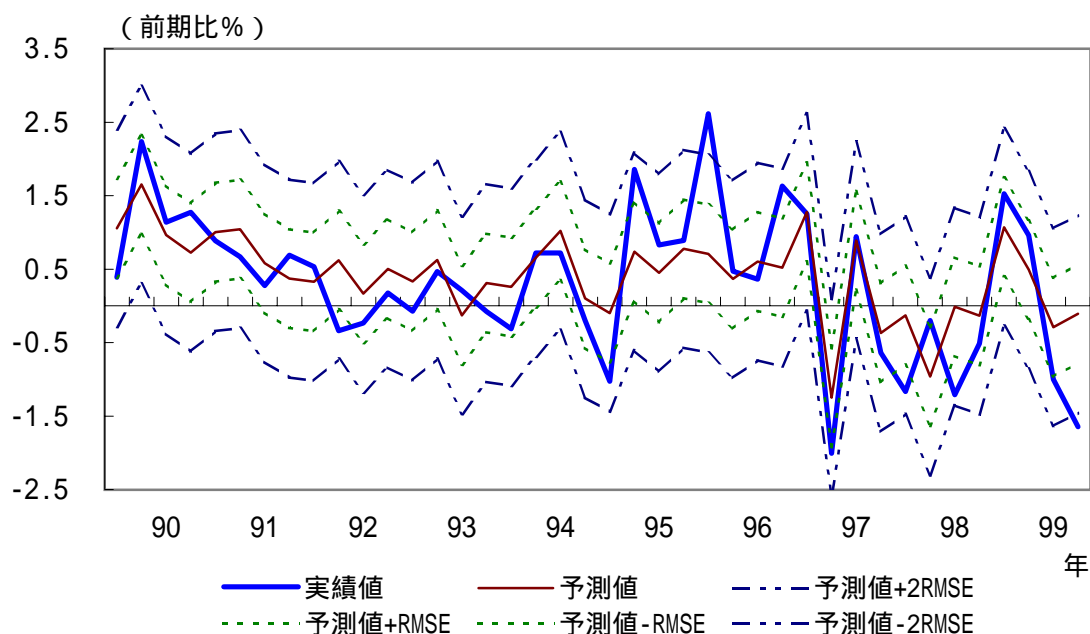
Pooling MethodにIntercept Correctionを組み合わせた場合

1. 合成予測のパフォーマンス (90/1Q~99/1Q)

	1期先予測					in-sample	(参考)
	RMSE	Bias	MSE	Biasの2乗	Variance	S.E.	-
全ての原予測	0.746	-0.149	0.556	0.022	0.534	0.452	0.293
積み上げ方式以外の4つ	0.851	-0.207	0.724	0.043	0.682	0.491	0.360
総労働投入量以外の4つ	0.737	-0.149	0.543	0.022	0.520	0.460	0.277
有効求人倍率以外の4つ	0.738	-0.113	0.545	0.013	0.532	0.470	0.269
完全失業率以外の4つ	0.706	-0.118	0.499	0.014	0.485	0.475	0.232
全産業活動指数以外の4つ	0.812	-0.134	0.659	0.018	0.641	0.487	0.325
最適な組み合わせ	0.672	-0.091	0.452	0.008	0.444	0.494	0.179

(注) 最適な組み合わせとは、積み上げ方式と全産業活動指数を合成したものの。

2. 最適な組み合わせによる合成予測と実績の比較



< 参考 > 統計面からの比較 (90/1Q~99/4Q)

	平均値	中位値	最大値	最小値	S.D.	Skewness	Kurtosis
実績	0.327	0.429	2.616	-2.006	1.017	-0.123	2.892
合成予測	0.418	0.498	1.650	-1.250	0.577	-0.659	3.850

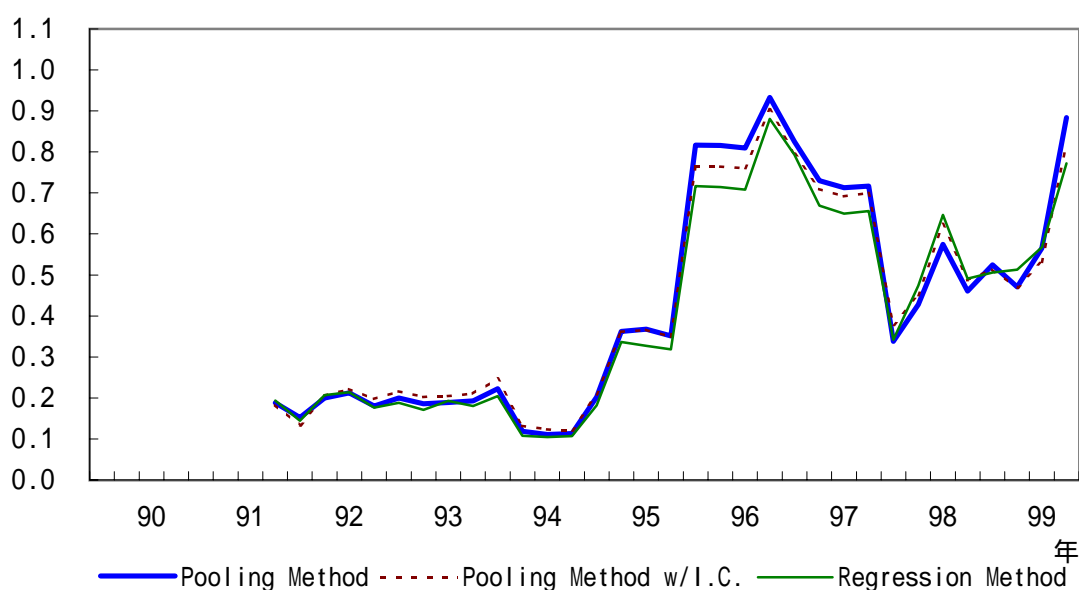
パフォーマンスの比較

1 . 予測対象期間 (90/1Q ~ 99/4Q) を通じた平均的な予測パフォーマンス 最適な組み合わせ (積み上げ方式 + 全産業活動指数)

	RMSE	Bias	MSE	Biasの2乗	Variance
Pooling Method	0.683	-0.070	0.467	0.005	0.462
Pooling Method w/I.C.	0.672	-0.091	0.452	0.008	0.444
Regression Method	0.651	-0.039	0.424	0.002	0.423

(注) Pooling Method w/I.C. とは、原予測のbiasをIntercept Correctionで修正した後、Pooling Methodで合成したケース。

2 . RMSEの推移



(注) それぞれの合成方法について、後方 8 四半期でRMSEを順次計算している。

3 . Consensus Forecastsとの比較

比較対象期間 : 96/4Q ~ 99/4Q

	RMSE
Consensus Forecasts	1.920
Consensus Forecasts	1.891
Pooling Method	0.820
Pooling Method w/I.C.	0.805
Regression Method	0.781

(注) Consensus Forecastsが、日本の四半期別実質GDP成長率のForecastを初めて掲載した96/12月 (96/4Qが予測対象期間の始期) から99/4Qまでを比較。Consensus Forecasts は、予測対象期間の最終月のデータがない時点での予測について、同 は、最終月のデータがある状態での予測 (96/4Q ~ 97/2Q、97/4Q ~ 98/1Q、98/4Qの 6 回) について、それぞれRMSEを計算した。

予測式一覧 (1)

全ての予測式は99/4Qの予測用（推計期間は89/4Q～99/3Q、サンプル数40）。

1. 積み上げ方式

(1) 公的需要 (= 公共投資 + 政府消費)

公的需要は、政府消費が一定と仮定したうえで、名目前年比の伸び率を予測。公共工事請負金額、公共工事出来高という2つの説明変数から2つの予測値を作成し、合成。その後、合成した予測値を実質前期比に転換。

公共工事請負金額による予測

Dependent Variable: RRT_G

説明変数	係数	S.E.	t 値	Prob.	R ²	0.791
RRT_UKEO1	0.130	0.027	4.857	0.000	Adj. R ²	0.774
RRT_UKEO1(-1)	0.128	0.029	4.403	0.000	S.E.	2.405
RRT_UKEO1(-2)	0.090	0.030	2.971	0.005	D.W.	2.289
AR(1)	0.704	0.130	5.401	0.000		

但し、

RRT_Gは名目公的需要前年比

RRT_UKEO1は公共工事請負額の前年比、当期から2期前まで

AR(1)は1次の自己相関を持つ誤差項（以下同じ）

公共工事出来高による予測

Dependent Variable: RRT_G

説明変数	係数	S.E.	t 値	Prob.	R ²	0.792
C	2.606	1.147	2.273	0.029	Adj. R ²	0.775
RRT_GDEKI	0.245	0.055	4.452	0.000	S.E.	2.399
RRT_GDEKI(-1)	0.104	0.055	1.900	0.065	D.W.	1.906
AR(1)	0.652	0.127	5.132	0.000		

但し、

Cは定数項（以下同じ）

RRT_GDEKIは公共工事出来高の前年比、当期から1期前まで

公的需要デフレータの予測

Dependent Variable: RRT_DG

説明変数	係数	S.E.	t 値	Prob.	R ²	0.801
C	0.336	0.261	1.288	0.206	Adj. R ²	0.785
RRT_DG(-1)	0.557	0.109	5.136	0.000	S.E.	1.089
RTT_WPIALLOR	0.385	0.116	3.323	0.002	D.W.	2.662
RTT_GENKINK	0.125	0.076	1.642	0.109		

但し、

RRT_DGは公的需要デフレータの前年比

RTT_WPIALLORは国内卸売物価指数の前年比

RTT_GENKINKは毎勤の建設業現金給与総額の前年比

予測式一覧(2)

1.(2)個人消費

個人消費は、実質前期比伸び率を、販売指標、家計調査の実質消費支出額、消費水準指数の3つから予測し、合成。

名目値の説明変数は個人消費デフレータ及びその予測値で実質化。

販売指標による予測

Dependent Variable: RT_C

説明変数	係数	S.E.	t 値	Prob.	R ²	0.784
C	0.396	0.093	4.241	0.000	Adj. R ²	0.753
RT_DSS	0.097	0.041	2.385	0.023	S.E.	0.580
RT_TRVL3	0.063	0.024	2.589	0.014	D.W.	2.031
RT_KJNSVC3	0.141	0.036	3.873	0.001		
RT_KURUMA	0.038	0.029	1.342	0.189		
DUMMY	1.412	0.615	2.297	0.028		

但し、

RT_Cは実質個人消費の前期比

RT_DSSは実質百貨店売上高の前期比

RT_TRVL3は第3次産業活動指数・旅行業の前期比

RT_KJNSVC3は第3次産業活動指数・対個人サービスの前期比

RT_KURUMAは乗用車新車登録台数の前期比

DUMMYは消費税ダミー(89/1Q・97/1Qが1、翌期が-1、それ以外は0)

実質消費支出額による予測

Dependent Variable: RT_C

説明変数	係数	S.E.	t 値	Prob.	R ²	0.651
C	0.487	0.114	4.290	0.000	Adj. R ²	0.622
RT_CESA	0.296	0.095	3.125	0.004	S.E.	0.717
RT_KURUMA	0.076	0.032	2.387	0.022	D.W.	2.523
DUMMY	1.573	0.700	2.247	0.031		

但し、

RT_CESAは家計調査・実質消費支出額の前期比

消費水準指数による予測

Dependent Variable: RT_C

説明変数	係数	S.E.	t 値	Prob.	R ²	0.658
C	0.470	0.112	4.180	0.000	Adj. R ²	0.630
RT_CISA	0.308	0.094	3.275	0.002	S.E.	0.709
RT_KURUMA	0.074	0.032	2.336	0.025	D.W.	2.437
DUMMY	1.535	0.693	2.216	0.033		

但し、

RT_CISAは消費水準指数の前期比

消費デフレータの予測

Dependent Variable: RRT_DC

説明変数	係数	S.E.	t 値	Prob.	R ²	0.959
RRT_CPIALLOR	0.772	0.061	12.636	0.000	Adj. R ²	0.958
AR(1)	0.752	0.118	6.377	0.000	S.E.	0.239
					D.W.	1.811

但し、

RRT_DCは個人消費デフレータの前年比

RRT_CPIALLは消費者物価指数の前年比

予測式一覧(3)

1.(3) 純輸出

純輸出は、国際収支統計から輸出、輸入の実質前期比伸び率を予測したうえで、前期比伸び率から計算された輸出と輸入の差分から、純輸出の実質前期比伸び率を求めている。

名目値の説明変数は輸出・輸入デフレータ及びそれらの予測値で実質化。

a. 実質輸出の予測

Dependent Variable: RT_EX

説明変数	係数	S.E.	t 値	Prob.		R ²	
RT_EXZAI	0.760	0.063	12.011	0.000	Adj. R ²	0.751	
RT_EXSVC	0.098	0.037	2.633	0.012		S.E.	1.032
						D.W.	2.100

但し、

RT_EXは実質輸出の前期比

RT_EXZAIは財の実質輸出の前期比

RT_EXSVCはサービスの実質輸出の前期比

a. 輸出デフレータの予測

Dependent Variable: RRT_DEX

説明変数	係数	S.E.	t 値	Prob.		R ²	
C	-0.512	0.152	-3.372	0.002	Adj. R ²	0.967	
RRT_EPI	0.849	0.025	33.600	0.000		S.E.	0.917
						D.W.	0.351

但し、

RRT_DEXは輸出デフレータの前年比

RRT_EPIは輸出物価の前年比

b. 実質輸入の予測

Dependent Variable: RT_IM

説明変数	係数	S.E.	t 値	Prob.		R ²	
RT_IMZAI	0.493	0.059	8.303	0.000	Adj. R ²	0.691	
RT_IMSVC	0.372	0.062	6.014	0.000		S.E.	1.276
						D.W.	2.004

但し、

RT_IMは実質輸入の前期比

RT_IMZAIは財の実質輸入の前期比

RT_IMSVCはサービスの実質輸入の前期比

b. 輸入デフレータの予測

Dependent Variable: RRT_DIM

説明変数	係数	S.E.	t 値	Prob.		R ²	
RRT_IPIEX	0.810	0.048	16.795	0.000	Adj. R ²	0.962	
RRT_IPIOIL	0.142	0.016	8.888	0.000		S.E.	1.573
						D.W.	0.547

但し、

RRT_DIMは輸入デフレータの前年比

RRT_IPIEXは輸入物価除く石油・石炭の前年比

RRT_IPIOILは輸入物価・石油石炭の前年比

予測式一覧 (4)

1 . (4) 設備投資

設備投資は、実質前期比伸び率を、機械受注額、建築着工予定額、リース契約額、一般資本財出荷の4つから予測し、合成。

名目値の説明変数は設備投資入デフレータ及びそれらの予測値で実質化。

機械受注額・民需除く船舶による予測

Dependent Variable: RT_IF

説明変数	係数	S.E.	t 値	Prob.	R ²	0.717
RT_IFJU	0.088	0.046	1.892	0.067	Adj .R ²	0.693
RT_IFJU(-1)	0.210	0.045	4.643	0.000	S.E.	1.411
RT_IFJU(-2)	0.269	0.046	5.858	0.000	D.W.	2.140
RT_IFJU(-3)	0.156	0.043	3.599	0.001		

但し、

RT_IFは実質設備投資の前期比

RT_IFJUは機械受注額・民需除く船舶の実質前期比、当期から - 3 期まで

建築着工予定額・非居住用による予測

Dependent Variable: RT_IF

説明変数	係数	S.E.	t 値	Prob.	R ²	0.525
RT_IFTYA	0.044	0.048	0.928	0.360	Adj .R ²	0.470
RT_IFTYA(-1)	0.086	0.048	1.764	0.086	S.E.	1.853
RT_IFTYA(-2)	0.114	0.047	2.431	0.020	D.W.	2.194
RT_IFTYA(-3)	0.100	0.045	2.240	0.032		
AR(1)	0.379	0.161	2.353	0.024		

但し、

RRT_IFTYAは建築着工予定額・非居住用の実質前期比、当期から - 3 期まで

リース契約額による予測

Dependent Variable: RT_IF

説明変数	係数	S.E.	t 値	Prob.	R ²	0.324
RT_LEASE	0.209	0.079	2.660	0.011	Adj .R ²	0.307
RT_LEASE(-1)	0.175	0.064	2.740	0.009	S.E.	2.120
					D.W.	1.097

但し、

RT_LEASEはリース契約額の実質前期比、当期から - 1 期まで

鉱工業出荷・資本財除く輸送機械による予測

Dependent Variable: RT_IF

説明変数	係数	S.E.	t 値	Prob.	R ²	0.429
C	0.032	0.308	0.105	0.917	Adj .R ²	0.413
RT_IFSYU	0.514	0.096	5.338	0.000	S.E.	1.950
					D.W.	1.409

但し、

RT_IFSYUは鉱工業出荷・資本財除く輸送機械の前期比

設備投資デフレータの予測

Dependent Variable: RRT_DIF

説明変数	係数	S.E.	t 値	Prob.	R ²	0.861
RRT_DIF(-1)	0.859	0.060	14.299	0.000	Adj .R ²	0.858
RRT_WPIALLOR	0.254	0.073	3.451	0.001	S.E.	0.824
					D.W.	1.934

但し、

RRT_DIFは設備投資デフレータの前年比

RRT_WPIALLORは国内卸売物価の前年比

予測式一覧 (5)

1 . (5) 住宅投資

住宅投資は、実質前期比伸び率を、新設住宅着工戸数から予測。

Dependent Variable: RT_IH

説明変数	係数	S.E.	t 値	Prob.	R ²	0.679
RT_KOSUU	0.470	0.104	4.540	0.000	Adj. R ²	0.670
RT_KOSUU(-1)	0.570	0.104	5.504	0.000	S.E.	2.801
					D.W.	1.954

但し、

RT_IHは実質住宅投資の前期比

RT_KOSUUは新設住宅着工戸数の前期比、当期から - 1 期まで

2 . 総労働投入量 (毎勤統計) による予測

実質 GDP の前期比伸び率を、総労働投入量 (= 毎勤統計の常用雇用・季調済指数 × 一人当たり総労働時間・季調済指数) と、前期の労働生産性のトレンドからの乖離率、前期の労働生産性のトレンド成長率から、予測。

本来であれば、被説明変数と同時期の労働生産性を用いるべきであるが、労働生産性そのものが当該期の実質 GDP を用いて計算されるため、説明変数として用いるのは妥当ではない。そこで、代理変数として、前期実績値から求めたトレンド成長率と乖離率を用いた。

Dependent Variable: RT_GDP

説明変数	係数	S.E.	t 値	Prob.	R ²	0.250
DELTA_PROD(-1)	-0.469	0.195	-2.405	0.021	Adj. R ²	0.187
RT_PRODHP(-1)	0.973	0.508	1.917	0.063	S.E.	0.883
RT_THOUR	0.175	0.440	0.398	0.693	D.W.	2.017
AR(1)	0.474	0.225	2.106	0.042		

但し、

RT_GDPは実質 GDP の前期比

DELTA_PROD(-1)は前期の労働生産性のトレンドからの乖離率

RT_PRODHP(-1)は前期の労働生産性のトレンド成長率

RT_THOURは総労働投入量後方 3 期移動平均の前期比

(注) 99/2Q ~ 4Q以外の予測対象期間の予測式では、RT_THOURのt値は有意である。

3 . 有効求人倍率 (職業安定業務統計) による予測

有効求人倍率の前期比、前期の (先行指標である) 新規求人倍率の前期比に、総労働時間による予測と同様、前期の労働生産性のトレンドからの乖離率、前期の労働生産性のトレンド成長率を組み合わせ、実質 GDP の前期比伸び率を予測。

Dependent Variable: RT_GDP

説明変数	係数	S.E.	t 値	Prob.	R ²	0.450
C	-1.346	0.761	-1.769	0.086	Adj. R ²	0.387
DELTA_PROD(-1)	-0.258	0.102	-2.534	0.016	S.E.	0.767
RT_PRODHP(-1)	3.655	1.355	2.698	0.011	D.W.	2.040
RT_UK	0.081	0.028	2.913	0.006		
AR(1)	-0.099	0.203	-0.487	0.630		

但し、

RT_UKは有効求人倍率後方 3 期移動平均の前期比

予測式一覧 (6)

4 . 完全失業率等 (労働力調査) による予測

実質 GDP の前期比伸び率を、完全失業率、完全失業者数の 2 つから予測し、合成。

完全失業率による予測

Dependent Variable: RT_GDP

説明変数	係数	S.E.	t 値	Prob.	R ²	0.372
DELTA_PROD(-1)	-0.394	0.140	-2.817	0.008	Adj.R ²	0.319
RT_PRODHP(-1)	1.540	0.336	4.583	0.000	S.E.	0.809
RT_UEM	-0.194	0.061	-3.191	0.003	D.W.	1.962
AR(1)	0.138	0.218	0.633	0.531		

但し、

RT_UEMは完全失業率後方 3 期移動平均の前期比

就業者数、失業者数による予測

Dependent Variable: RT_GDP

説明変数	係数	S.E.	t 値	Prob.	R ²	0.291
DELTA_PROD(-1)	-0.344	0.156	-2.208	0.034	Adj.R ²	0.232
RT_PRODHP(-1)	1.290	0.347	3.720	0.001	S.E.	0.859
RT_UEMSHI(-1)	-0.102	0.049	-2.098	0.043	D.W.	1.974
AR(1)	0.170	0.241	0.705	0.485		

但し、

RT_UEMSHIは完全失業者数の前期比、1 期前

5 . 全産業活動指数による予測

実質 GDP の前期比伸び率を、全産業活動指数から予測。

Dependent Variable: RT_GDP

説明変数	係数	S.E.	t 値	Prob.	R ²	0.418
C	0.239	0.124	1.932	0.061	Adj.R ²	0.402
RT_ZENSAN	0.680	0.130	5.221	0.000	S.E.	0.758

但し、

RT_ZENSANは全産業活動指数の前期比

D.W. 2.258

データ一覧

1. 説明変数

略号	名称	出典	作成元
N_UKEO1	公共工事請負金額OR	公共工事前払金保証統計	保証事業会社協会
N_GDEKI	公共工事出来高OR	建設総合統計	国土交通省
GSF	公共投資季節要素	(注3)	
N_DSS	全国百貨店売上高SA	商業販売統計	経済産業省
TRVL3	第3次産業活動指数・旅行業SA	第3次産業活動指数	経済産業省
KJNSVC3	同・対個人サービスSA	第3次産業活動指数	経済産業省
KURUMA	乗用車新車登録台数SA	自動車国内販売	日本自動車販売協会連合会
N_CESA	消費支出額・全世帯SA	家計調査報告	総務省
CISA	消費水準指数・全世帯SA	家計調査報告	総務省
N_EXZAI	貿易収支・輸出SA	国際収支統計	日本銀行
N_EXSVC	サービス収支・受取SA	国際収支統計	日本銀行
N_IMZAI	貿易収支・輸入SA	国際収支統計	日本銀行
N_IMSVC	サービス収支・支払SA	国際収支統計	日本銀行
N_IFJU	機械受注額・民需除く船舶SA	機械受注統計	内閣府
N_IPTYA	建築物着工工事費予定額・非居住用SA	建設統計月報	国土交通省
N_LEASESA	リース取扱高SA	リース取扱高	リース事業協会
IFSYU	鉱工業出荷・資本財除く輸送機械SA	鉱工業指数統計	経済産業省
KOSUU	新設住宅着工戸数SA	建設統計月報	国土交通省
CPIALLOR	全国消費者物価指数総合OR	消費者物価指数	総務省
WPIALLOR	国内卸売物価指数OR	卸売物価指数	日本銀行
EPIOR	輸出物価・総平均OR	卸売物価指数	日本銀行
IPIOR	輸入物価・総平均OR	卸売物価指数	日本銀行
GENKINK	現金給与総額指数・建設業SA	毎月勤労統計	厚生労働省
MAIKIN_L	常用雇用指数SA	毎月勤労統計	厚生労働省
MAIKIN_H	総労働時間指数・30人以上SA	毎月勤労統計	厚生労働省
THOUR	総労働投入量	(注4)	
PROD	労働生産性	(注5)	
UK	有効求人倍率SA	職業安定業務統計	厚生労働省
UKNEWR	新規求人倍率SA	職業安定業務統計	厚生労働省
UEM	完全失業率SA	労働力調査	総務省
UEMSYU	就業者数SA	労働力調査	総務省
UEMSHI	完全失業者数SA	労働力調査	総務省
ZENSAN	全産業活動指数SA	全産業活動指数	経済産業省
DUMMY	消費税導入・税率引き上げダミー	(注6)	

(注1) 名称末のORは原計数を、SAは季調済計数を示す。原計数のみ公表の場合はX-11で季節調整。予測・推計にあたっては、原則実質値の季調済前期比ベースに換算。

(注2) 国際収支統計(85/1Q~)を除く全ての変数は80/1Q~99/4Qまでの期間をカバー。

(注3) GSF=名目公的需要OR/名目公的需要SAで計算。

(注4) THOUR=MAIKIN_L*MAIKIN_Hで計算。

(注5) PROD=R_GDP(実質国内総支出SA)/THOURで計算。

(注6) 89/1Q、97/1Qが+1、89/2Q、97/2Qが-1、それ以外の期間は0。

2. 被説明変数

略号	名称	出典	作成元
G	公的需要	以下全て国民経済計算	内閣府
C	個人消費		
NEX	純輸出		
EX	輸出		
IM	輸入		
IF	設備投資		
IH	住宅投資		
GDP	国内総支出		

(注7) 各コンポーネントについて、名目原計数(N_***)、実質季調済計数(R_***)、デフレータ(D_***)を利用し、略号の頭にN、R、Dの符号をつけることで区別(例:名目公的需要ORはN_G)。