



日本銀行ワーキングペーパーシリーズ

## オルタナティブデータを用いた GDPナウキャストモデリングの構築

中澤崇\*

takashi.nakazawa@boj.or.jp

No.22-J-1  
2022年3月

日本銀行  
〒103-8660 日本郵便（株）日本橋郵便局私書箱30号

\* 調査統計局

日本銀行ワーキングペーパーシリーズは、日本銀行員および外部研究者の研究成果をとりまとめたもので、内外の研究機関、研究者等の有識者から幅広くコメントを頂戴することを意図しています。ただし、論文の中で示された内容や意見は、日本銀行の公式見解を示すものではありません。

なお、ワーキングペーパーシリーズに対するご意見・ご質問や、掲載ファイルに関するお問い合わせは、執筆者までお寄せ下さい。

商用目的で転載・複製を行う場合は、予め日本銀行情報サービス局 (post.prd8@boj.or.jp) までご相談下さい。転載・複製を行う場合は、出所を明記して下さい。

# オルタナティブデータを用いた GDP ナウキャストモデリングモデルの構築\*

中澤 崇<sup>†</sup>

2022年3月

## 【要旨】

新型コロナウイルス感染症が経済活動に大きな影響を及ぼす中、従来の月次・四半期の経済データのみを用いた GDP ナウキャストモデリングモデルでは、精度の高い予測が困難になっている。本稿では、速報性の高いオルタナティブデータを用いて、ナウキャストモデリングモデルの精度向上を試みる。具体的には、従来の月次の経済データに加えて、速報性の高い週次の小売販売額データと数百系列に及ぶ日次のインターネットの検索数データを用いて、Elastic Net によるスパース推定を組み込んだナウキャストモデリングモデルを構築する。モデルの定式化とデータ系列の選択については、複数の予測モデルを組み合わせる予測平均 (Forecast Combination) 法を用いて多数の候補を用意し、感染症拡大後のデータも含めた予測誤差を最小化するようにモデル選択を行う。分析の結果、オルタナティブデータを用いるとナウキャストモデリングモデルの予測精度が、特に利用できる伝統的な経済データに限られる GDP 公表 2 か月前時点で大きく向上することが分かった。

JEL 分類番号 : C52、C53、C55

キーワード : ナウキャストモデリング、オルタナティブデータ、Elastic Net、  
予測平均 (Forecast Combination)

---

\* 本稿の作成にあたり、稲次春彦氏、亀田制作氏、川本卓司氏、倉知善行氏、桜健一氏、中島上智氏、長野哲平氏、三上朝晃氏、山縣広晃氏および日本銀行スタッフから有益なコメントを頂戴した。ただし、本稿のあり得べき誤りは全て筆者個人に属する。なお、本稿に示される内容や意見は、筆者個人に属するものであり、日本銀行の公式見解を示すものではない。

<sup>†</sup> 日本銀行調査統計局 (takashi.nakazawa@boj.or.jp)

## 1. はじめに

新型コロナウイルス感染症を巡る動向が経済活動に大きな影響を及ぼす中、直近の経済状況をリアルタイムに、かつ正確に把握する重要性が高まっている。とりわけ、一国の経済活動を包括的に捉える指標である GDP は、様々な経済政策運営を行う際の重要なメルクマールである一方、その公表までにはタイムラグがあり、わが国では1次速報値の公表まで約1か月半を要する。足許の GDP を、直近までに公表されている情報を用いてリアルタイムに予測する試みは、GDP ナウキャストイング（Nowcasting）と呼ばれ、近年、世界的にその注目度が増している。

ナウキャストイングの取り組みは、これまで「相対的に公表が早い月次・四半期の経済指標を用いて公表が遅い GDP を予測する」という考え方に基づいて、進められてきた。例えば、米国連邦準備制度（Federal Reserve System）では、複数の地区連銀から、こうした考え方に基づくナウキャストイングモデルが提案されている。具体的には、アトランタ地区連銀は「GDP Now」、ニューヨーク地区連銀は「Nowcasting Report」という名でそれぞれナウキャストイングモデルを運用しており、GDP の予測値を随時更新し、ウェブサイトに掲載している<sup>1</sup>。わが国でも、Hara and Yamane (2013)、Bragoli (2017)、Chikamatsu et al. (2018, 2021)、Hayashi and Tachi (2021)、浦沢 (2021) などが、こうした考え方に基づいたナウキャストイングモデルを提案している。

もともと、月次・四半期指標を利用する従来のナウキャストイングモデルは、2020年の新型コロナウイルス感染症の拡大以降、パフォーマンスが悪化傾向にある<sup>2</sup>。これは、公衆衛生上の措置の導入と解除の繰り返しもあって、経済変動の振幅は大きくなっているもとの、従来のナウキャストイングモデルでは、公表までに（相対的に短いとはいえ）ラグを伴う伝統的な経済データの利用を前提としていることから、直近の状況を予測値に十分織り込むことが難しくなったためである。

---

<sup>1</sup> GDP Now では、ファクターモデルを組み込んだ Bridge モデルと Bayesian VAR の併用により予測を行っている（Higgins (2014)）。一方、Nowcasting Report では、状態空間モデルにより予測を行っている（Bok et al. (2018)）。

<sup>2</sup> 浦沢 (2021) は、わが国における GDP ナウキャストイングにおいて、2020年以降の時期をサンプル期間に含めるとモデルの予測精度が顕著に悪化することを示しており、2020年の新型コロナウイルス感染症の拡大以降、伝統的な経済データのみでは経済変動の大きな振幅をリアルタイムに捉えることが難しくなっている点に言及している。

そこで、こうした問題を克服するために、最近では、各国で日次や週次といった高頻度で利用可能な「オルタナティブデータ」を導入して、より経済変動を早期に捉えるナウキャストモデルを構築する試みが、盛んに行われている<sup>3</sup>。例えば、Jardet and Meunier (2020) は、世界 GDP のナウキャストのために、バルチック海運指数や米国のガソリン消費量といった日次・週次データを予測モデルに組み込み、従来の月次・四半期の経済データのみを用いたモデルよりも精度が改善することを示している。また、Woloszko (2020) は、日次での利用が可能なインターネットの検索数データを用いて、46か国の国別 GDP のナウキャストモデルを構築している。これに対して、わが国については、そもそも感染症が拡大した2020年以降のナウキャストモデルの予測精度を検証した研究自体が少数に留まっている<sup>4</sup>。また、筆者の知る限りは、わが国にスポットを当てた GDP のナウキャストに関する先行研究について、これまでのところオルタナティブデータをモデルに組み込んだものは存在しない。

こうした状況を踏まえ、本稿では、オルタナティブデータを活用してわが国の GDP をナウキャストする手法を提案し、2020年以降のデータも含めて最適なナウキャストモデルの構築を行う。具体的には、以下の分析では、日本銀行調査統計局で運用され、情勢判断に活用されてきた Chikamatsu et al. (2018) をベースとした既存の GDP ナウキャストモデルを出発点とする。当モデルは、月次・四半期指標から GDP を予測する標準的なモデルであり、本稿で構築する新モデルの予測精度を評価するベンチマークとなるという意味で、以降ではベンチマークモデルと呼ぶ。このモデルは、①Bridge モデルによる推計値、②CMIDAS (Combined Mixed-Data Sampling) モデルによる推計値、③エコノミストによる GDP 予測値 (E S P フォーキャスト) の3つを単純平均して求める予測平均 (Forecast Combination) モデルとなっている<sup>5</sup>。

これに対して、本稿で構築する新モデルは、ベンチマークモデルから、次の2点を改良している。第1に、Bridge モデルの推計の一部にオルタナティブデータを利用する。具体的には、(1) インターネット上の検索数データである Google Trends

---

<sup>3</sup> ここでのオルタナティブデータは、亀田 (2021) の定義と同様に、月次・四半期のマクロ経済指標や上場企業の決算開示データのような伝統的な経済データ以外のデータの総称である。

<sup>4</sup> 上記の先行研究の中では、Hayashi and Tachi (2021)、浦沢 (2021) が、2020年以降のデータも含めたナウキャストモデルの予測値を評価している。

<sup>5</sup> ベンチマークモデルは、Chikamatsu et al. (2018) では利用されていなかった実質輸出入をモデルの説明変数に加えている。

のカテゴリー検索指数と、(2) 小売店の POS 販売データである METIPOS 小売販売額指標を用いる。いずれのオルタナティブデータも、公表までのタイムラグが1～9日間と従来の指標よりも速報性が高い点に強みがあり、早期に GDP の動きを捕捉できる可能性がある。第2に、直近までのデータサンプルを含めて、予測精度が最も高いモデルの組み合わせを検討する。一般的に、予測モデルの候補は、どの経済データを推計に用いるか、どの回帰モデルを利用するか、それらのモデルをどのように組み合わせるか、をそれぞれ選択しなければならず、その組み合わせは天文学的な数に膨れ上がる。本稿では先行研究を踏まえて、利用する説明変数の候補を7つに絞ったうえで、それらを利用したモデルの組み合わせである約26万通りを総当たりで検討し、その中で予測誤差が最も小さくなる「最良モデル」を求めた。これらの予測誤差を算出するためのサンプル期間の終期は2021年第1四半期としており、感染症拡大下での急速な経済変動も含めたうえで、予測精度の高いモデルを選択した点が特徴である。

本稿の構成は以下の通りである。第2節では、本稿の分析のベースとなっている、ベンチマークモデルについて紹介したうえで、感染症拡大前後の予測精度の変遷を分析する。第3節では、インターネット検索データ、POS 小売販売データを用いたナウキャスト手法を説明する。第4節では、最も予測力の高いモデルを総当たりで検討する。第5節では、第4節で選択された最良モデルの予測結果を、ベンチマークモデルとの比較を交えて評価する。第6節は結びである。

## 2. ベンチマークモデル

### 2-1. モデルの概要

本節では、Chikamatsu et al. (2018)によるナウキャストモデルの一部を改良したベンチマークモデルを紹介する。前述したように、このモデルの予測値は、2つの計量モデル (Bridge モデル、CMIDAS モデル) から得られる予測値とエコノミストの GDP 予測値を単純平均したものである。2つの計量モデルでは、月次の経済指標を説明変数として、四半期計数である被説明変数の GDP を予測する定式化を行う。

#### 2-1-1. Bridge モデル

Bridge モデルは、月次計数から四半期計数を予測する代表的な手法の1つである

(例えば、Baffigi et al. (2004)などを参照)。説明変数に使用する月次計数を四半期計数に換算し、被説明変数と説明変数の計数周期を統一したうえで、線形回帰を行っている。具体的には、以下の(1)式のような回帰式をOLS(最小二乗法)で推計する。

$$y_t = \alpha + \sum_{i=1}^N \beta_i x_{i,t}^Q + \epsilon_t \quad (1)$$

ここで、 $y_t$ は四半期の実質GDP成長率、 $x_{i,t}^Q$ は各経済指標( $i = 1, \dots, N$ )の月次計数を四半期換算したものである。ナウキャストリングで説明変数として用いられる指標はその多くが変化率(前月比)であり、その場合、 $x_{i,t}^Q$ の四半期換算の方法は、Mariano and Murasawa (2003)に基づき、以下の(2)式で算出する<sup>6</sup>。

$$x_{i,t}^Q = \frac{1}{3}(x_{i,3t}^M + 2x_{i,3t-1}^M + 3x_{i,3t-2}^M + 2x_{i,3t-3}^M + x_{i,3t-4}^M) \quad (2)$$

ここで、 $x_{i,3t-h}^M$ は、予測する四半期の最終月から $h$ か月前の前月比である。

ベンチマークモデルのBridgeモデルにおける説明変数((1)式の $x_{i,t}^Q$ )は、①第3次産業活動指数(3活、前月比)、②実質輸出(前月比)、③実質輸入(前月比)、④ロイター短観(第1主成分)の4変数である<sup>7</sup>。もっとも、予測を行う時点で、全ての変数について(2)式右辺の月次計数が揃っているとは限らない。そこで、Bridgeモデルでは、未公表の月次計数がある場合は、その部分を既に公表されている別の経済変数で補外予測している。この補外予測は、その予測精度がベンチマークモデル全体の予測精度に影響するため、Bridgeモデルの定式化の重要な側面となっている<sup>8</sup>。

例えば、説明変数の1つである3活( $ita_t$ 、前月比)について、ある月の計数が未公表である場合、ベンチマークモデルでは、下記の(3)式のように、3活より

<sup>6</sup> 指標の水準を説明変数に用いる場合は、四半期中の単純平均を利用する。

<sup>7</sup> ロイター短観(第1主成分)については、Zou et al. (2006)のスパース主成分分析を用いて、業種別のロイター短観指数計18系列から、第1主成分を抽出したもの。

<sup>8</sup> なお、未公表の月次計数を別の経済変数で補外する方法以外に、変数が何らかの時系列モデル(例えば、ARIMAモデルなど)に従うと仮定して補外する方法もある(Bañbura et al. (2013)などを参照)。この方法では、補外に際して、別の経済変数との関係を先験的に仮定する必要がない一方、感染症拡大下における経済変動のように、データの変動パターンが過去と比べて大きく変化する場合、補外の精度が低下しやすいと考えられる。

早く公表される鉱工業生産指数 ( $IIP_t$ 、前月比)、景気ウォッチャー指数 ( $watcher_t$ 、家計動向関連の現状判断DI)、実質卸売業販売額 ( $csc_t$ 、前月比) を説明変数とした線形回帰式を推計し、その回帰式の予測値を3活の補外値 ( $\widehat{ita}_t$ ) とする。

$$\widehat{ita}_t = \alpha + \beta_1 IIP_t + \beta_2 watcher_t + \beta_3 csc_t \quad (3)$$

そのうえで、月次の実績値と補外値を組み合わせることで四半期計数を作成し、Bridgeモデルの説明変数として用いる。

## 2-1-2. CMIDAS モデル

Bridgeモデルと並んで、月次計数から四半期のGDPを予測する代表的な手法の1つにMIDAS (Mixed-Data Sampling) モデルがあり、ナウキャストモデルとして広く利用されている (Foroni and Marcellino (2014)、Kuzin et al. (2013))。MIDASモデルを用いたGDPナウキャストの場合、次の(4)式のように、月次計数そのものを説明変数とし、被説明変数である四半期の実質GDP成長率を予測する<sup>9</sup>。

$$y_t = \alpha + \sum_{i=1}^N \sum_{j=0}^{l_i} \beta_{i,j} x_{i,3t-j}^M + \epsilon_t \quad (4)$$

(4)の右辺は公表された月次計数のみで構成されるため、前述のBridgeモデルと異なり、未公表の月次計数を補外する必要がない。一方で、説明変数が新たに1か月分公表される度に、説明変数の数が増加するため、MIDASモデルを単独で用いると予測値が更新の度に大きく変わりやすいことが指摘されている。これを回避するため、先行研究では複数のMIDASモデルを組み合わせたForecast Combinationを提案している文献がみられる (例えば、Andreou et al. (2013)、Anesti et al. (2017))。こうしたモデルは、Combined MIDAS (CMIDAS) モデルと呼ばれており、ベンチマークモデルでも利用している。

ベンチマークモデルのCMIDASモデルは、①3活 (前月比)、②鉱工業生産指数

---

<sup>9</sup> MIDASモデルの推計にあたっては、ラグ変数の係数間に特定の構造 (アーモン・ラグなど) を仮定する場合と、特に係数間の関係を仮定せず、通常のOLSで回帰する場合 (Unrestricted MIDAS) の2通りの方法が存在する。ベンチマークモデルでは後者の手法を採用しており、後述する本稿でのモデル改良の際も、これに倣っている。

(以下 IIP と呼称、前月比)、③実質卸売業販売額 (前月比)、④ロイター短観 (第 1 主成分) の 4 変数を説明変数とし、この 4 変数の組み合わせから計 14 通りの MIDAS モデルを別個に推計し、それぞれの予測値を計算する<sup>10</sup>。そのうえで、14 個の予測値を単純平均し、CMIDAS モデルの予測値とする。

### 2-1-3. 予測平均 (Forecast Combination) の利用

一般的な時系列予測において、単一のモデルによる予測値よりも、異なる複数のモデルの予測値を組み合わせる方が、予測精度が改善しやすいことが、多くの先行研究で指摘されている (Winkler (1989)、Timmermann (2006))。予測精度が向上する理由として、①複数のモデルを用いる方が、予測対象となるデータの生成プロセスに生じる構造変化を捉えやすい (Diebold and Pauly (1987))、②予測モデルにおける定式化の誤りの影響を軽減しやすい (Stock and Watson (2004)) といった点が挙げられている。

こうした考え方に基づき、Chikamatsu et al. (2018) では、わが国を対象とした GDP ナウキャストイングについて、複数の Forecast Combination モデルについて予測誤差を比較し、上記の Bridge モデル、CMIDAS モデル、そしてエコノミストの GDP 予測値を単純平均したモデルの予測力が平均的に最も優れていることを示した。今回のベンチマークモデルも同様に、この 3 つのモデルの Forecast Combination を用いている<sup>11</sup>。もっとも、ベンチマークモデルのベースとなっている Chikamatsu et al. (2018) では、2018 年第 1 四半期までの計数をもとにナウキャストイングモデルの予測精度を評価しており、その後起こった新型感染症が拡大するもとの急激な経済変動の時期は、評価の対象に含まれていない。そこで、次節では、ベンチマークモデルの直近の時期までの予測精度の変遷を確認する。

---

<sup>10</sup> ベンチマークモデルでは、推計するパラメーター数に制約を設けているため、上記 4 変数を全て説明変数とした MIDAS モデルは使用していない。

<sup>11</sup> Chikamatsu et al. (2018) では、エコノミストの GDP 予測値について、Bloomberg 社が集計する予測値と、公益社団法人日本経済研究センターが公表する E S P フォーキャスト調査の予想平均値を両方検討しており、結果として後者を含めた Forecast Combination モデルの方がパフォーマンスが優れていることを示している。本稿でも、エコノミストの予測値として E S P フォーキャスト調査の予測値を用いる。

## 2-2. ベンチマークモデルの予測精度の変遷

本節では、ベンチマークモデルの予測精度が、直近までどのように推移してきたかを確認する。予測精度を評価する指標は複数存在するが、以下では、多くの先行研究で利用されるアウト・オブ・サンプル予測の平均平方二乗誤差（Root Mean Squared Error : RMSE）を用いる。

ナウキャストモデルの評価にあたっては、GDP の公表日から遡って、何か月前の時点での予測値を評価するかは重要な論点である。どの時点の予測精度を重視するかはナウキャストモデルの利用目的にも依存するが、本稿では、GDP 1 次速報値の公表直前時点でのデータセットを用いた予測値（「0 か月前予測」）、公表 1 か月前時点での予測値（「1 か月前予測」）、公表 2 か月前時点での予測値（「2 か月前予測」）をそれぞれ算出し、3 時点についての予測誤差（RMSE）の平均値を「統合予測誤差（統合 RMSE）」として参照することで、各予測時点を通しての平均的な予測精度を評価することとした<sup>12</sup>。

図表 1 は、2013 年第 1 四半期からその後の各時点までをサンプルとして計算した場合の、ベンチマークモデルによる予測値の RMSE を示したものである。比較として、エコノミスト予測値から計算される RMSE も掲載している。2020 年第 1 四半期までの時期について、ベンチマークモデルの統合 RMSE は、エコノミスト予測の RMSE を下回って、低位で安定していた。一方で、2020 年第 2 四半期以降、ベンチマークモデル、エコノミスト予測ともに予測精度は大きく悪化している。ベンチマークモデルについて予測時点ごとの予測誤差をみると、2020 年第 2 四半期以降、予測精度が大きく悪化しているのは 2 か月前予測であり、0、1 か月前予測は多少悪化していながらも、いまだエコノミスト予測に比べると優位にあることが分かる。

この点について、ベンチマークモデルを構成する 3 つの予測値（Bridge モデル、CMIDAS モデル、エコノミスト予測）ごとに RMSE を確認すると、2 か月前予測では、CMIDAS モデルの RMSE が 2020 年第 2 四半期以降大きく悪化している（図

---

<sup>12</sup> 予測精度の評価に利用しているデータは、Chikamatsu et al. (2018)や Angelini et al. (2011)などの先行研究と同様、GDP も説明変数も最新時点で得られたデータであり、過去の公表後に行われたリバイスなども全て反映したものである。また、METIPOS 小売販売額指標など、分析期間である 2013 年第 1 四半期以降に定期的な公表を開始した指標については、定期公表前についても、直近と同様の公表スケジュールでデータが利用可能であったと仮定している。このため、厳密には過去の予測時点で利用可能であった（リバイス前の）データセットではない。その意味で、当該データセットは「疑似リアルタイム（pseudo-real time）」のデータによる分析といえる。

表2)。CMIDAS モデルは、前述のように、月次の計数を説明変数として四半期 GDP を予測する手法であり、2 か月前予測の時点においては、多くの説明変数は四半期の1 か月目の計数しか利用できないため、1 か月目の計数のみでその四半期を予測することになる。2020年以降は、感染症の拡大や公衆衛生上の措置の動向によって毎月経済指標が大きく変動したことから、1 か月目の計数のみで予測を行う CMIDAS モデルの予測値は不安定となり、予測精度が大きく低下したと考えられる。また、Bridge モデルについても、足許にかけて2 か月前予測の予測精度は、CMIDAS モデルほど大きく悪化している訳ではないにせよ、恒常的に芳しくなく、ベンチマークモデル全体の予測精度を押し下げていると考えられる。

### 3. オルタナティブデータを用いた予測手法の改良

2 節で確認した通り、2020年第2 四半期以降におけるベンチマークモデルの予測精度の悪化は、主に、利用できるデータセットが限られている2 か月前予測で生じている。これは、従来型の月次の経済データに公表までのラグがあることが要因となっていると考えられ、より速報性の高いデータの利用が対処策となり得る。そこで本稿では、Bridge モデルの補外式の一部に、オルタナティブデータを用いることを試みる。

具体的には、ベンチマークモデルにおける Bridge モデルの補外式のうち、(3) 式で例示した3 活の補外式の説明変数に、オルタナティブデータとして①Google Trends カテゴリー検索指数、②METIPOS 小売販売額指標を加える<sup>13</sup>。今回、3 活に限定してオルタナティブデータによる補外を検討したのは、説明変数の中で、3 活は公表時期が最も遅く（対象月の末日から概ね42～51日後の公表）、他指標対比で補外値への依存度が高いほか、ベンチマークモデルにおける2020年以降の予測で、補外の誤差が最も大きいためである（図表3）。こうした事実から、未公表の3 活をより正確に予測できれば、GDP 予測値の精度向上に寄与すると考えられる。

#### 3-1. Google Trends カテゴリー検索指数

Google Trends は、Google の検索サイト上で「旅行」、「レストラン」といった特定の検索ワードが検索された回数を、時系列で提供するデータサイトである。デー

---

<sup>13</sup> 他の変数についても、3 活の補外と同様に、それぞれの補外式に従い補外推計されている（詳しくは補論を参照）。

タの系列によっては、経済活動の動きと高い相関がみられ、GDPをはじめとした様々な経済指標の予測に有用であることが知られている (Vosen and Schmidt (2011)、白木他 (2013)、Ferrara and Simoni (2019)、Woloszko (2020))。一方で、無数に存在する検索ワードのうち、3活の推計においてどのワードを用いることがふさわしいか、特定することは困難である。そこで本稿では、個別のワードの検索数ではなく、Google Trends に備わるもう1つのデータ取得方法である「カテゴリー検索」のデータを利用する。

カテゴリー検索数は、あるトピック (カテゴリー) に関連する検索ワードの検索数を、Google のアルゴリズムに基づき合算したデータである。例えば、カテゴリーの1つである「ホテル・宿泊」では、「ホテル」や「宿泊」というワードの検索回数に加えて、「東京都 ホテル」や「宿泊施設 おすすめ」といった、カテゴリーに関連する検索ワードの検索回数が含まれ得る。Google Trends では、全体で1,132個のカテゴリーが存在するが、本分析では、そのうち、以下の2つの条件を満たすものを利用する。

第1の条件は、短期的な経済変動と直接関連があると考えられるカテゴリーである。上記の1,132個のカテゴリーの中には「天文学」、「肥満」といった、短期的な経済変動とは直接関係しないと考えられるものも多い。そこで、1,132個のうち、特定の財・サービス需要に関わるカテゴリー (例えば「ワイン」、「ウエディング」など) や、広く景況感を映じていると考えられるカテゴリー («倒産」、「小売販売」など) といった、先験的に短期的な経済変動と関係性があると考えられる、252個のカテゴリーを選択した。

第2の条件として、Google Trends の検索数データの中に、データを分析者が取得 (ダウンロード) するタイミングによって数値が大きく変わる系列があり、これらの系列を除くことを考える。Medeiros and Pires (2021)によると、Google Trends の検索数データはサンプル抽出した結果に基づいており、当該ワードの検索数が相応に少ない場合、データをダウンロードする時点によって、データの値が大きく変わり得る。こうした問題は分析における結果の再現性にも関わるため、本稿では、特定の条件の下で同一のカテゴリー検索数データを、時間を空けて複数回サンプル取得し、そのサンプル間の標準偏差が一定以下であったカテゴリーのみを分析対象とす

ることとした<sup>14</sup>。第1の条件と第2の条件をともに満たすのは、217個のカテゴリーとなる。

検索数のデータ系列の中には、定義変更などに起因する段差が生じているものがあり、Woloszko (2020) を参考に段差調整を行った<sup>15</sup>。段差を調整した系列について、季節調整を施し、各カテゴリーにおける「検索指数」を作成した。その上で、各検索指数の長期的なトレンドを除去するために、指数の HP フィルターを用いたトレンドからの乖離率を分析に使用した<sup>16</sup>。

図表4では、このようにして作成した系列のうち、3つの系列について推移を例示する。「旅行ガイド・トラベログ」の推移をみると、2020年入り後、感染症拡大の影響から、大きく水準を切り下げており、公衆衛生上の措置などによる旅行需要減退を反映している姿が窺える。また、「自動車ローン」の推移をみると、2014年4月や2019年10月に行われた消費税率引き上げに伴う、自動車購入の駆け込みと反動を映じた動きが現れており、自動車販売との関連性が示唆される。「郵便・宅配」の推移を確認すると、2020年の感染症拡大時に大きく上昇するなど、いわゆる「巣ごもり需要」の増加を捉えている可能性がある。

### 3-2. METIPOS 小売販売額指標

METIPOS 小売販売額指標は、小売店の POS データを利用した速報性の高い指標であり、約1万店舗から集計した業態別の販売額データに基づいて作成される。こうした小売 POS データは、経済状況をリアルタイムで分析するツールとして、近年、特に感染症の拡大後、様々な研究に利用されている（例えば、Konishi et al. (2021) など）。もっとも、筆者の知る限り、こうした小売 POS データをわが国の GDP ナウキャストに利用した研究は存在しない。本稿では、METIPOS 小売販売額指標に含まれる、スーパーマーケット、ドラッグストア、コンビニエンスストア、ホームセンター、家電大型専門店の5業態について、週次の販売額指数を月次化し

---

<sup>14</sup> 具体的には、各カテゴリー検索指数について10分間の間隔を空けて5回サンプルを取得し、サンプル間の標準偏差が0.01を下回ったものを対象とした。

<sup>15</sup> Googleによって実施された2011年1月の「地理的範囲の変更」と、2016年1月の「システムの変更・改善」によって、データに段差が生じていると考えられる（Woloszko (2020)）。段差が生じた月の前年比を、段差が生じる前月の前年比と同一とみなして接続し、翌月以降は、段差調整前の前月比で延長するという方法により、これらの影響を排除した。

<sup>16</sup> HP フィルターにおける平滑化パラメーター（ $\lambda$ ）は14,400とした。

た上で季節調整済み前月比を作成し、推計に用いる。

### 3-3. 推計方法

従来のモデルで3活の補外に利用していた経済指標と、上記のオルタナティブデータの各系列を併せると、3活の補外式における説明変数は200個以上になる。一方で、推計のサンプル期間は最大でも9年間、月次データで100か月分程度と限られており、サンプル数が説明変数の数を下回ることから、通常のOLSでは推計できない。そこで、本稿では機械学習の一手法であるElastic Net法を用い、係数の推計と変数選択を同時に行うことで、この問題を回避する。

回帰式の推計を行う際に、望ましい変数が自動的に選択される、つまり該当する変数以外に係るパラメーターが0となる性質は「スパース (sparse) 性」と呼ばれる。スパース性を持つ推計手法のうち、代表的な手法はTibshirani (1996) が提案したLasso回帰と呼ばれる手法であるが、Lasso回帰は(サンプル数 $n$ ) < (説明変数の数 $p$ ) となる回帰式は推計できないほか、変数の数が増えると、多重共線性 (multicollinearity) によって推計値が不安定化するという問題がある。

こうした問題に対処できるのが、Zou and Hastie (2005) によって提案されたElastic Net法である。Elastic Net法は、スパース性を残しつつ、多重共線性の問題に対して頑健であるという点に強みがある<sup>17</sup>。また、サンプル数と説明変数の数に関して、Lasso回帰にあるような制約が存在しないため、本分析のようにサンプル期間が比較的短く、かつ説明変数が多い場合の推計に適している。

Elastic Net法において、説明変数の係数は次の(5)式のように推計される。

$$\hat{\beta} = \underset{\beta}{\operatorname{argmin}} \left( \frac{1}{2n} [\mathbf{Y} - \mathbf{X}\beta]^2 + \lambda \left[ \alpha \sum_{j=1}^p |\beta_j| + \left( \frac{1-\alpha}{2} \right) \sum_{j=1}^p \beta_j^2 \right] \right) \quad (5)$$

---

<sup>17</sup> 説明変数に多重共線性を持つ変数グループが含まれる場合、Lasso回帰では、グループ内のいずれか1つの変数の回帰係数のみが非ゼロとなり、グループのその他の変数の回帰係数はゼロと推計されてしまう傾向を有し、係数の値自体もサンプルの変化に対して脆弱である。一方、Elastic Net法では、グループ間の回帰係数はいずれもほぼ同様の値をとる性質(グループ効果)が存在することが知られている(Zou and Hastie (2005))。グループ効果は、変数間に多重共線性が存在する場合でも、それらの回帰係数が安定的に推計される(データの多少の差で、推計値が大きく変化することがない)という点で、望ましい性質といえる。

ただし、 $\mathbf{Y}$ は被説明変数のベクトル、 $\mathbf{X}$ は $p$ 個の説明変数の行列、 $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)'$ は説明変数の係数ベクトル、 $\lambda$ 、 $\alpha$ は正則化パラメーター ( $0 < \lambda$ 、 $0 < \alpha < 1$ )、 $n$ はサンプル数である。右辺の括弧内の第1項は回帰式の誤差二乗和であり、通常のOLSで用いる統計量と同じであるが、第2、3項が正則化項と呼ばれるElastic Net法に特有の項である。係数が0から遠ざかるとこれらの項が大きくなり、最小化問題においてあたかも罰則が科されたような形になることから、罰則付き回帰モデルとも呼ばれる。

3活の補外式は、次の(6)式を回帰式として、Elastic Net法により推計する。

$$ita_t = c + \sum_{i=1}^{217} \beta_i^{gt} gt_{i,t} + \sum_{j=1}^5 \beta_j^{mp} mp_{j,t} + \sum_{k=1}^4 \beta_k^x x_{k,t} + \epsilon_t \quad (6)$$

ここで、 $ita_t$ は3活(前月比)、 $gt_{i,t}$ はGoogle Trendsにおけるカテゴリ*i*の検索指数(トレンドからの乖離率の前月差)、 $mp_{j,t}$ はMETIPOS小売販売額指標の業態別販売額指数(前月比)、 $x_{k,t}$ はベンチマークモデルで補外式に利用されていた3つの指標(IIP<前月比>、景気ウォッチャー指数、実質卸売業販売額<前月比>)に加えて、新しい指標として新車乗用車登録台数(前月比)を追加した4指標である。新車乗用車登録台数については、ベンチマークモデルでは検討されていなかったものの、Bragoli(2017)、Hayashi and Tachi(2021)など、わが国のGDPナウキャストを行っている先行研究で利用されていることから、本稿では説明変数に加えることとした。この結果、説明変数の数は計226個となる。なお、説明変数は全て、平均が0、分散が1となるよう標準化した。

実際の推計にあたって、前述(5)式における正則化パラメーター( $\lambda$ 、 $\alpha$ )を設定する必要がある。本稿では、グリッドサーチ(grid search)によりパラメーターを設定する。すなわち、パラメーターの候補をそれぞれ複数用意して、2014年1月から2021年3月までの期間において、3活のアウト・オブ・サンプルの予測誤差が最小となるパラメーターの組み合わせを採用する<sup>18</sup>。

---

<sup>18</sup> 具体的には、 $\lambda$ 、 $\alpha$ ともに、0.1~0.9の間を0.1刻みで選択し、全ての組み合わせを試行して予測誤差が最も小さくなるパラメーターの組み合わせを選択している。こうして選択されたパラメーターは、 $\lambda=0.1$ 、 $\alpha=0.2$ である。

### 3-4. 推計結果

図表5では、上記の方法により推計された3活の補外式のうち、最もサンプル期間が長いもの（サンプル期間は2012年11月～2021年3月）の推計結果を掲載している<sup>19</sup>。226個の説明変数のうち、スパース推計によって除外された（係数が0となった）変数が141個あり、係数が0でなかった変数は85個となった。

回帰パラメーターが大きい、すなわち予測値における平均的な寄与が大きい変数をみると、上位から実質卸売業販売額、新車乗用車登録台数、IIPといった従来のデータ系列があり、その下に METIPOS 小売販売額指標の各指数が続いている。Google Trends の係数をみると、推計値が比較的大きい系列には、「旅行ガイド・トラベログ」や「自動車ローン」など、旅行サービスや自動車販売の動向を間接的に捉える指標が含まれている。一方で、符号がマイナスとなったパラメーターもあり、係数の絶対値が大きいものをみると、Google Trends の「オンラインビデオ」や「郵便・宅配」といった系列が並んでいる。これらは、感染症拡大下において、いわゆる「巣ごもり需要」が増加する中、検索数が大きく増加したカテゴリーであり、2020年以降、大きく水準を切り下げた3活と、負の相関がみられる系列となっている。

この推計式に基づき、2015年以降の3活のアウト・オブ・サンプル予測値（公表直前までに利用可能なデータを用いて予測した値）をみると、Elastic Net 推計による補外値は、ベンチマークモデルで利用されている補外値対比、RMSE が大きく低下しており、予測精度が改善していることが分かる（図表6）。特に、2019年9～10月に発生した、消費税率引き上げ前後の消費の駆け込み・反動減による動きや、2020年3月以降の感染症拡大下での急速な経済変動を、Elastic Net による予測値は精度良く予測しており、比較的大きい経済変動が起こった際に、予測値が実績を捕捉できているといえる。Elastic Net による予測値を、説明変数別に分解すると、オルタナティブデータ（Google Trends や METIPOS 小売販売額指標）の予測値に対する寄与が相応に大きいことが分かる。

以上のように、3活の予測精度は、オルタナティブデータの活用により大きく改

---

<sup>19</sup> METIPOS 小売販売額指標のサンプル期間が限られるため、3活の補外は2014年第1四半期から上記の（6）式で行うこととし、それ以前は（6）式の説明変数から Google Trends と METIPOS 小売販売額指標を除去し、通常の OLS で推計した補外式を用いることとした。

善するとの結果が得られた<sup>20</sup>。次節では、この新しい補外式を組み込んだ Bridge モデルを用いながら、最も予測精度が高いモデルの検討を行う。

## 4. 最良モデルの検討

本節では、ベンチマークモデルで利用した Bridge、CMIDAS といった基本的なモデルの枠組みは残しつつ、どの Forecast Combination を用いれば直近までの GDP の予測精度を最大化できるのか、多数の組み合わせを総当たりで試行し、予測誤差を比較することで検討する。

### 4-1. 最良モデルの選定プロセス

新しいナウキャストモデルを構築するにあたって、説明変数の候補となるデータは、基本的にベンチマークモデルに従う。ベンチマークモデルで利用されている変数のうち、本稿で引き続き利用するのは、①3活、②IIP、③実質輸出、④実質輸入、⑤景気ウォッチャー指数、⑥実質卸売業販売額の6指標である<sup>21</sup>。これに加え、第3節でも述べたように、先行研究においてわが国の GDP ナウキャストに多用されている⑦新車乗用車登録台数を加えて、計7指標の組み合わせから候補となるモデルを作成する。

ベンチマークモデルの構築に際しては、Bridge モデル、CMIDAS モデル、エコノミスト予測の3つの予測値を用いた Forecast Combination が検討されているが、本稿ではこれに加え、新たに Combined-Bridge (CBridge) モデルも検討する。これは、CMIDAS モデルと同様、複数の Bridge モデルの予測値を単純平均した予測値を利

---

<sup>20</sup> ここでの3活の補外式は、実績が1か月伸びる度に、係数の値を Elastic Net により毎回推計し直している。このため、説明変数ごとの係数の大きさは時間とともに、その時々各系列と3活との相関を映じて変化する。係数の値をある時点の値で固定し、その後の予測を行ったところ、係数を更新する場合と比べて、予測精度が低下する傾向にあることを確認している。

<sup>21</sup> Chikamatsu et al. (2018)やベンチマークモデルで利用していたロイター短観第1主成分については、2021年第1四半期まで推計期間を延長したうえでモデルの予測誤差への寄与を分析したところ、Chikamatsu et al. (2018)の結論と異なり、予測誤差への寄与は他の説明変数対比で小さくなった。第1主成分の計算にはスパース推計を用いており、ハイパーパラメーターなどの最適化による計算負荷が大きい。このため、本稿のように数十万通りのスペックを試行する際には、ロイター短観を入れると推計負荷が著しく増大するため、本稿ではこのロイター短観を説明変数の候補から除外した。

用することによって、定式化の誤りや構造変化に対して頑健性の高いモデルを構築しようとする試みである<sup>22</sup>。

ナウキャストモデルの構築は、以下の手順で進めていく（図表7）。

- ① <Bridge モデルの推計>上記の7指標を組み合わせた説明変数のセットを計127通り（ $2^7 - 1$ 通り）作成し、それぞれのセットについて Bridge モデルを推計する。127通りの Bridge モデルについて、それぞれ0～2か月前予測値を計算し、GDPの予測誤差（RMSE）を各予測値について算出する。それら予測誤差の単純平均（統合RMSE）を求め、127個のモデルのうち、統合RMSEが小さい上位10個のモデルを選出する。
- ② <CBridge モデルの推計>①で選出した10個の Bridge モデルを組み合わせたセットを1,023通り（ $2^{10} - 1$ 通り）作成し、各 CBridge モデルについて予測値を算出する。
- ③ <CMIDAS モデルの推計>①で作成した127通りの説明変数のセットについて、CMIDAS モデルを推計する。具体的には、各セットの変数から、考えられる全ての組み合わせについて MIDAS モデルを推計し、その予測値を単純平均することで、CMIDAS モデルの予測値を算出する<sup>23</sup>。
- ④ <Forecast Combination の推計>②で推計した CBridge モデル（1,023通り）から1つの予測値、③で推計した CMIDAS モデル（127通り）から1つの予測値、そしてエコノミスト予測値、の3つの予測値について単純平均を計算する。その組み合わせ総数は、129,921通り（ $1,023 \times 127$ 通り）となる。さらに、CBridge モデル予測値とエコノミスト予測値の2つだけの平均、CMIDAS モデル予測値とエコノミスト予測値の2つだけの平均も候補に加える。その結

---

<sup>22</sup> Forecast Combination によって予測値を組み合わせる際のウェイト付けの手法は複数あるが、本稿では最もシンプルな単純平均値を利用する。これは、「複雑なウェイト付け手法を使った予測値より、予測値の単純平均の方が総じてパフォーマンスが優れている」という経験則、いわゆる「Forecast Combination Puzzle」（Stock and Watson (2004)、Smith and Wallis (2009))を踏まえている。Chikamatsu et al. (2018)でも、複数のウェイト付け手法を検証しているが、最終的には単純平均値が最も予測精度が良いと結論付けている。

<sup>23</sup> 例えば、「3活、IIP、実質輸出」という説明変数のセットについて CMIDAS モデルを推計する場合、まず(i)3活のみ、(ii)IIPのみ、(iii)実質輸出のみ、(iv)3活・IIP、(v)3活・実質輸出、(vi)IIP・実質輸出、(vii)3活・IIP・実質輸出、という7つの説明変数の組み合わせについて、それぞれ MIDAS モデルを推計し、この7つの MIDAS モデルの予測値を単純平均して CMIDAS モデルの予測値とする。

果、予測値の候補は131,071通りとなり、この中から最も統合 RMSE が小さい予測値を算出した Forecast Combination モデルを「最良モデル」と呼ぶ。

上記の手順では、ベンチマークモデルに準拠し、最終的にエコノミスト予測値(E S Pフォーキャスト)をモデルの一部として利用している。一方で、時々的情勢に左右されず、機械的に予測値を算出できることがナウキャストモデルのメリットと考えるのであれば、むしろエコノミスト予測値をモデルに利用することが望ましくないという考え方もあり得る。このような考え方を踏まえて、上記④のプロセスを以下の④'に変更した、以下の推計値も検討する。

④' <Forecast Combination の推計 (除く E S P) >②で推計した CBridge モデル (1,023通り) から 1つ、③で推計した CMIDAS モデル (127通り) から 1つ、計 2つの予測値を単純平均する。その組み合わせ総数は、129,921通りである。さらに、CBridge モデルのみ、CMIDAS モデルのみの推計値も加えた計 131,071通りの中から、最も統合 RMSE が小さい予測値を算出した Forecast Combination モデルを「最良モデル (除く E S P)」と呼ぶ。

#### 4-2. モデル選定の結果

前節の手順を踏まえて、検討段階ごとに統合 RMSE が小さいモデルを列挙したのが、図表 8、9 である。

手順①の Bridge モデルの推計で統合 RMSE が小さい上位10個のモデルをみると、いずれも、オルタナティブデータを用いた補外推計の枠組みを導入した 3 活が説明変数として利用されている (図表 8 (2))。この段階で既に、上位10個のモデルの統合 RMSE はベンチマークモデルを下回っており、これには、2 か月前予測の予測誤差が低下したことが大きく寄与している。この10個のモデルの組み合わせにより算出した手順②の CBridge モデルも同様に、2 か月前予測を中心に予測精度が改善している (図表 8 (3))。一方で、手順③の CMIDAS モデルの上位10個のモデルをみると、統合 RMSE は、CBridge モデルに比べて悪化しており、ベンチマークモデル対比でも予測誤差が大きくなっている (図表 9 (1))。第 2 節で述べたように、ベンチマークモデルでの予測値の悪化は、CMIDAS モデルで顕著であったが、この傾向は説明変数の組み合わせを変えても同様の結果となる。

手順④の検討の結果、統合 RMSE が最小である「最良モデル」はエコノミスト予測値と Bridge モデル (説明変数は 3 活、実質輸出、実質輸入、景気ウォッチャー指

数、新車乗用車登録台数の5変数)を組み合わせたモデルとなった(図表9(2)、図表10)。また、「最良モデル(除くESP)」は5つのBridgeモデルを組み合わせたCBridgeモデルとなった(図表9(3)、図表10)。Forecast Combinationを構成するいずれの式においても、オルタナティブデータを用いた補外式を導入した3活が、説明変数として採用されている。また、いずれのForecast Combinationにおいても、CMIDASを利用しないモデルが最良との結果が得られており、ベンチマークモデルと異なるのが興味深い点である。

## 5. 最良モデルの予測精度

本節では、「最良モデル」と「最良モデル(除くESP)」について、その予測精度を確認する。図表11では、これら2つのモデルの0~2か月前予測を、実績値と比較している。はじめに2か月前予測値をみると、どちらのモデルでも予測値は概ね同様の推移となっており、感染症の影響で大きくGDPが動いた2020年第2~第3四半期の実績値を2か月前の時点で既にかなり精度高く予測できていることがわかる。1か月前予測、0か月前予測になると、2020年第2~第3四半期の実績値をより精度高く予測しているほか、2014年や2019年の消費税引き上げ前後の駆け込み・反動の動きといった、GDPの振幅が大きくなるような局面の動きも概ね捕捉できている。

次に、感染症拡大前後における予測誤差の変遷を、図表12で確認する。図では2013年第1四半期から各時点までのRMSEを示している。0か月前、1か月前予測においては、2つの最良モデルはベンチマークモデルとほぼ同程度のRMSEか、最良モデルの方が若干RMSEが大きい。一方、2か月前予測では、明確に最良モデルの方の予測誤差が小さくなっている。この傾向は特に2020年以降顕著であり、感染症拡大下で経済変動のボラティリティが高まる中、オルタナティブデータなどを活用した最良モデルが、早期に実績に近い値を予測できていることを示唆する。

最後に、いくつかの時期(四半期)について、期間中のデータのアップデートに伴う予測値の変遷を、各説明変数の予測値への寄与と併せて例示したものが図表13、14である。図表13は、2020年第3四半期における予測値の推移を示している。この四半期では、感染症の拡大に対する全国的な公衆衛生上の措置が解除され、GDP前期比が+5.3%と大幅なプラスとなった。そのGDP実績値に対して、最良モデル、最良モデル(除くESP)ともに、GDP公表2か月前の段階で、予測値は前

期比+4%台後半と、実績値に近い水準であった。説明変数別の予測値の寄与をみると、従来の月次データとともに、METIPOS 小売販売額指標、Google Trends といったオルタナティブデータが予測値を実績値に収束させる方向に寄与しており、これらの値で補外された3活はその寄与が小さくなっている（つまり、概ね3活の推移を正確に補外できている）ことが分かる。同様に、図表14で2021年第2四半期の予測値の変遷をみても、オルタナティブデータの情報を取り込みながら、どちらの最良モデルでも、概ねGDP 実績値に近い予測値を算出していることが分かる。

## 6. おわりに

本稿では、月次・四半期指標のみを用いた既存のナウキャストモデルをベンチマークとして、オルタナティブデータ（Google Trends 検索指数、METIPOS 小売販売額指標）を組み込んだ新しい Bridge モデルを構築した。また、2021年第1四半期までのデータを踏まえて、上記の新しい Bridge モデルを含めた Forecast Combination モデルを総当たりで作成し、最も予測誤差が小さくなるナウキャストモデルを検証した。選択された最良モデルは、ベンチマークモデル対比で2か月前予測を中心に予測精度が改善し、より早期にかつより正確に、GDP をナウキャストすることが可能なモデルを構築することができた。

留意点として、ベンチマークモデルが感染症の拡大前までは高い予測パフォーマンスを示していたにもかかわらず、その後、感染症の拡大時期を経て、予測精度が悪化したように、本稿で提示した最良モデルについても、今後、経済活動が感染症の影響を脱し、新たな局面に入る中で、予測パフォーマンスが変化していく可能性も考えられる。GDP ナウキャストにおいては、1つのモデルに過度に依存していくのではなく、時々の経済構造に応じたモデルとなっているかを定期的に点検、改良していくことが重要と考えられる。

## 参考文献

- 浦沢聡士 (2021) 「GDP ナウキャストイング：成果と課題」、Kanagawa University Economic Society Discussion Paper、No.2021-01.
- 亀田制作 (2021) 「オルタナティブデータを用いた日銀リサーチの紹介」、日銀レビュー・シリーズ、21-J-16.
- 白木紀行、松村浩平、松本梓 (2013) 「景気判断における検索データの利用可能性」、日本銀行調査論文.
- Andreou, E., E. Ghysels, and A. Kourtellos (2013). “Should macroeconomic forecasters use daily financial data and how?” *Journal of Business & Economic Statistics*, 31(2), 240–251.
- Anesti, N., S. Hayes, A. Moreira, and J. Tasker (2017). “Peering into the present: the Bank's approach to GDP nowcasting,” Bank of England Quarterly Bulletin, Q2.
- Angelini, E., G. Camba-Mendez, D. Giannone, L. Reichlin, and G. Rünstler (2011). “Short-term forecasts of euro area GDP growth,” *The Econometrics Journal*, 1(14), C25–C44.
- Baffigi, A., R. Golinelli, and G. Parigi (2004). “Bridge models to forecast the euro area GDP,” *International Journal of Forecasting*, 20(3), 447–460.
- Bañbura, M., D. Giannone, M. Modugno, and L. Reichlin (2013). “Now-casting and the real-time data flow,” In: *Handbook of Economic Forecasting*. Elsevier, 195–237.
- Bok, B., D. Caratelli, D. Giannone, A. M. Sbordone, and A. Tambalotti (2018). “Macroeconomic nowcasting and forecasting with big data,” *Annual Review of Economics*, 10, 615–643.
- Bragoli, D. (2017). “Now-casting the Japanese economy.” *International Journal of Forecasting*, 33(2), 390–402.
- Chikamatsu, K., N. Hiramata, Y. Kido, and K. Otaka (2018). “Nowcasting Japanese GDPs,” Bank of Japan Working Paper Series, No. 18-E-18.
- Chikamatsu, K., N. Hiramata, Y. Kido, and K. Otaka (2021). “Mixed-frequency approaches to Nowcasting GDP: An Application to Japan,” *Japan and the World Economy*, vol.57: 101056.

- Diebold, F. X., and P. Pauly (1987). “Structural change and the combination of forecasts,” *Journal of Forecasting*, 6(1), 21–40.
- Ferrara, L., and A. Simoni (2019). “When are Google data useful to nowcast GDP? An approach via pre-selection and shrinkage,” Banque de France Working Paper April 2019, WP717.
- Foroni, C., and M. Marcellino (2014). “A comparison of mixed frequency approaches for nowcasting Euro area macroeconomic aggregates,” *International Journal of Forecasting*, 30(3), 554–568.
- Hara, N., and S. Yamane (2013). “New monthly estimation approach for nowcasting GDP growth: The case of Japan,” Bank of Japan Working Paper Series, No. 13-E-14.
- Hayashi, F., and Y. Tachi (2021). “Nowcasting Japan's GDP,” mimeo.
- Higgins, P. (2014). “GDPNow: A model for GDP 'Nowcasting',” FRB Atlanta Working Paper 2014-7, Federal Reserve Bank of Atlanta.
- Jardet, C., and B. Meunier (2020). “Nowcasting world GDP growth with high-frequency data,” Banque de France Working Paper, No. 788.
- Konishi, Y., T. Saito, T. Ishikawa, H. Kanai, and N. Igei (2021). “How did Japan cope with COVID-19? Big data and purchasing behavior,” *Asian Economic Papers*, 20(1), 146–167.
- Kuzin, V., M. Marcellino, and C. Schumacher (2013). “Pooling versus model selection for nowcasting GDP with many predictors: Empirical evidence for six industrialized countries,” *Journal of Applied Econometrics*, 28(3), 392–411.
- Mariano, R. S., and Y. Murasawa (2003). “A new coincident index of business cycles based on monthly and quarterly series,” *Journal of Applied Econometrics*, 18(4), 427–443.
- Medeiros, M. C., and H. F. Pires (2021). “The proper use of Google Trends in forecasting models,” arXiv preprint arXiv:2104.03065.
- Smith, J., and K. F. Wallis (2009). “A simple explanation of the forecast combination puzzle,” *Oxford Bulletin of Economics and Statistics*, 71(3), 331–355.
- Stock, J. H., and M. W. Watson (2004). “Combination forecasts of output growth in a seven-

- country data set,” *Journal of Forecasting*, 23(6), 405–430.
- Tibshirani, R. (1996). “Regression shrinkage and selection via the lasso,” *Journal of the Royal Statistical Society: Series B*, 58(1), 267–288.
- Timmermann, A. (2006). “Forecast combinations,” In: *Handbook of Economic Forecasting*, 1, 135–196.
- Vosen, S., and T. Schmidt (2011). “Forecasting private consumption: Survey-based indicators vs. Google trends,” *Journal of Forecasting*, 30(6), 565–578.
- Winkler, R. L. (1989). “Combining forecasts: A philosophical basis and some current issues,” *International Journal of Forecasting*, 5(4), 605–609.
- Woloszko, N. (2020). “Tracking activity in real time with Google Trends,” OECD Economic Department Working Papers, No. 1634.
- Zou, H. and T. Hastie (2005). “Regularization and variable selection via the elastic net,” *Journal of the Royal Statistical Society: Series B*, 67, 301–320.
- Zou, H., T. Hastie, and R. Tibshirani (2006). “Sparse principal component analysis,” *Journal of Computational and Graphical Statistics*, 15(2), 265–286.

## 補論. Bridge モデルにおける補外推計

本補論では、3節で述べた3活以外の、Bridge モデルにおける未公表計数の補外方法を詳述する。なお、モデル構築に利用した経済変数の概要は補論図表に掲載している。本稿のベースラインとなっているベンチマークモデルの補外方法は、Chikamatsu et al. (2018)に倣っている。最良モデルの選定においてもこのベンチマークモデルや Chikamatsu et al. (2018)の補外方法を概ね踏襲しているが、近年まで推計期間を延ばした際の有意性などを踏まえて、一部説明変数を変更している。

### 【IIP】

IIP ( $iip_t$ ) の未公表計数は、生産予測指数（前月比、 $iipf_t$ ）を補外値とする（A 1 式）<sup>24</sup>。

$$iip_t = iipf_t \quad (\text{A } 1)$$

### 【景気ウォッチャー】

景気ウォッチャー指数<家計動向関連の現状判断DI> ( $watcher_t$ ) は、IIP を説明変数として補外値を推計する（A 2 式）。

$$watcher_t = c + \beta_1 iip_t \quad (\text{A } 2)$$

### 【実質卸売業販売額】

実質卸売業販売額 ( $csc_t$ ) は、IIP、景気ウォッチャー指数を説明変数として補外値を推計する（A 3 式）。

$$csc_t = c + \beta_1 iip_t + \beta_2 watcher_t \quad (\text{A } 3)$$

### 【実質輸出入】

実質輸出 ( $ex_t$ ) は、IIP を説明変数として、また、実質輸入 ( $im_t$ ) は IIP と景気ウォッチャー指数を説明変数として、補外値を推計する（A 4、A 5 式）。

$$ex_t = c + \beta_1 iip_t \quad (\text{A } 4)$$

---

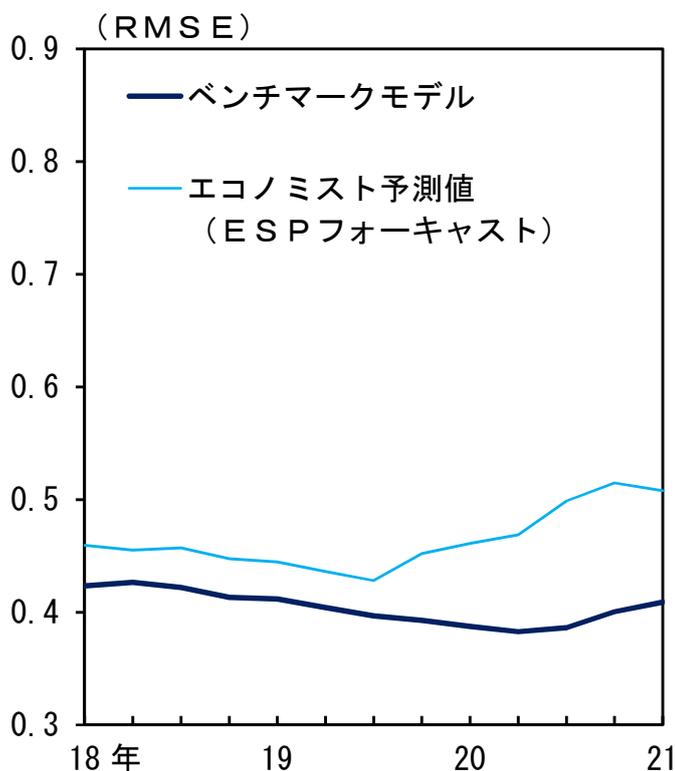
<sup>24</sup> 生産予測指数が利用できない期間については、IIP の値を代用している。

$$im_t = c + \beta_1 iip_t + \beta_2 watcher_t \quad (A5)$$

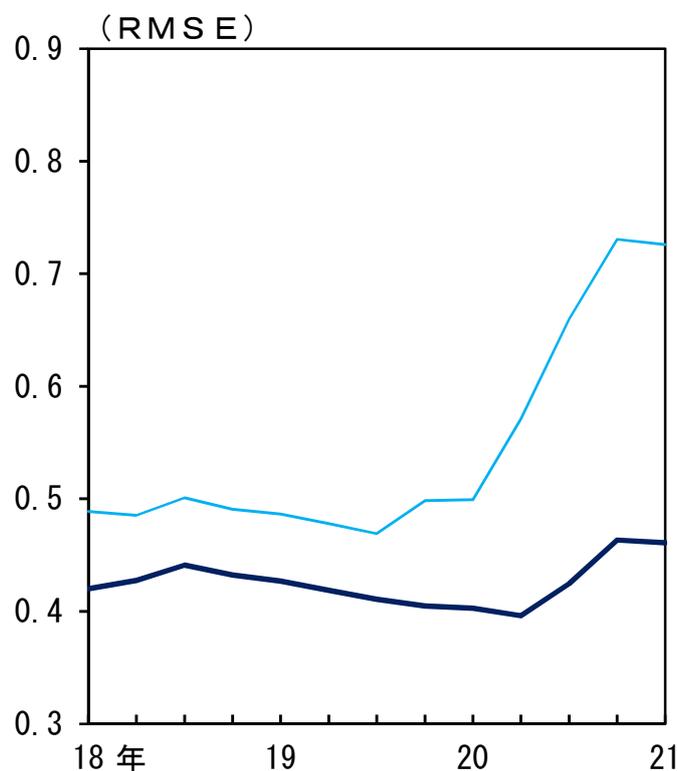
なお、四半期内の3か月目に当たるデータが全て利用できず、上記で示したような補外ができない場合には、四半期内の3か月目の計数は、四半期内の1か月目と2か月目の計数の平均値を補外値とする。このとき、1か月目と2か月目の実績値が利用できなければ、1か月目と2か月目の補外値を使用する。

## 実質GDPの予測誤差

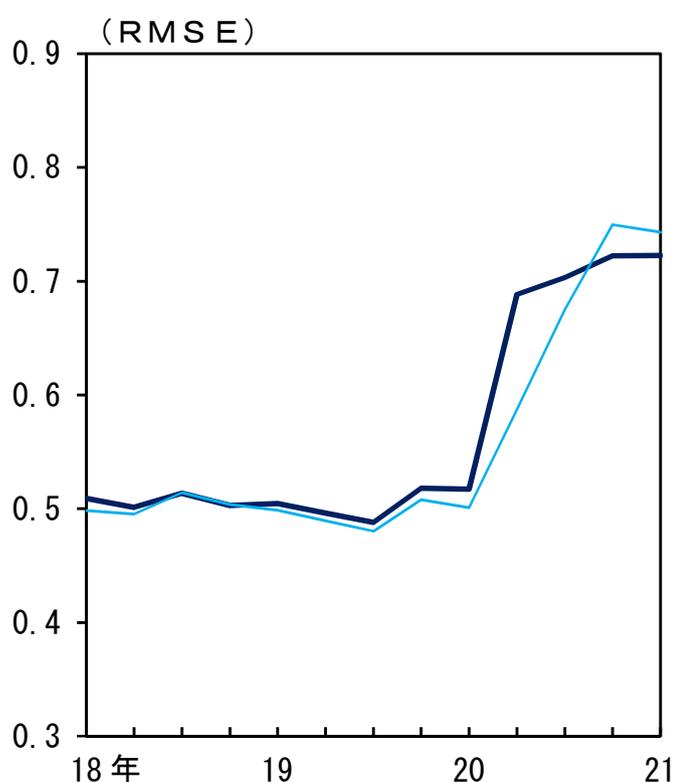
(1) 0か月前予測値のRMSE



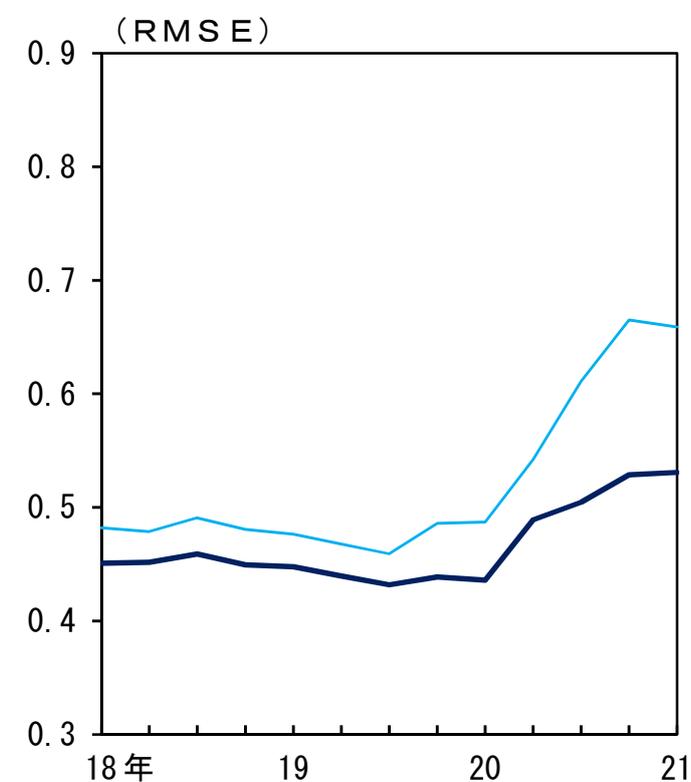
(2) 1か月前予測値のRMSE



(3) 2か月前予測値のRMSE



(4) 統合RMSE

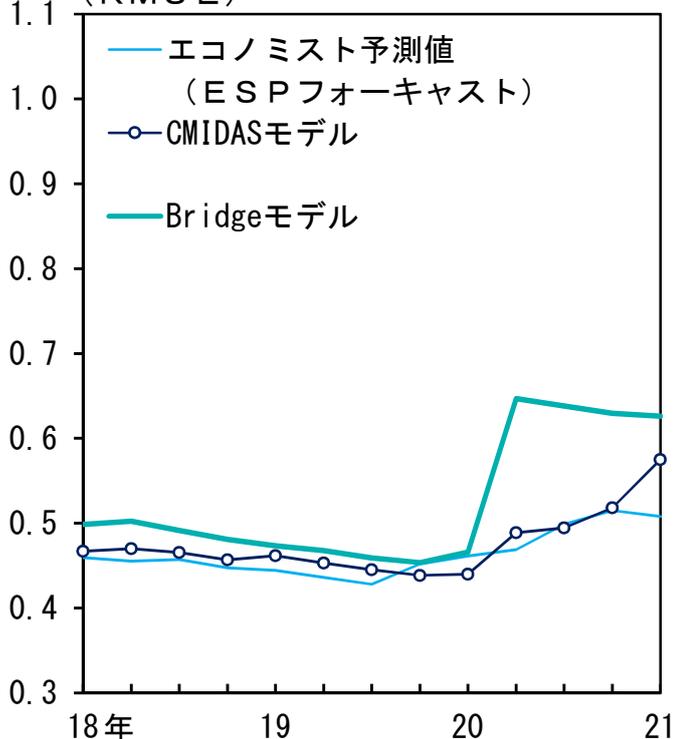


(注) RMSEの対象期間は、2013年第1四半期から各時点まで。

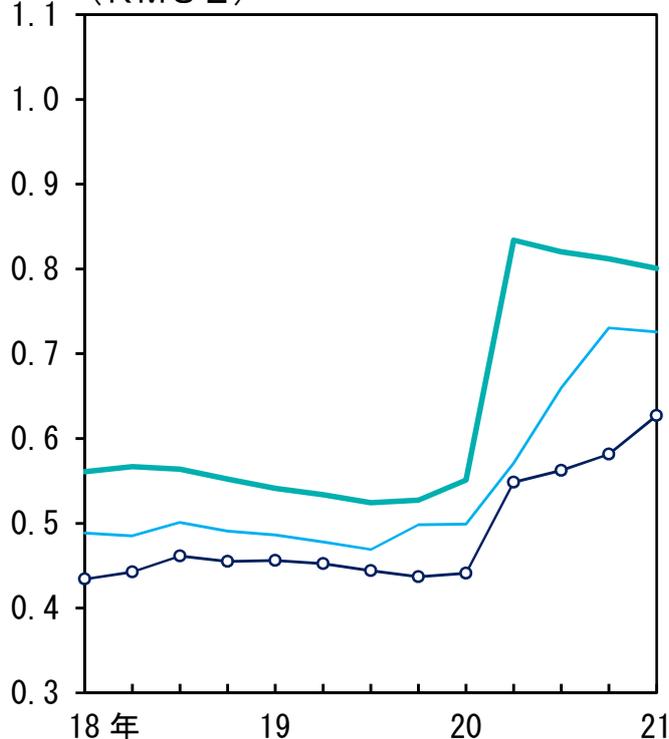
(出所) 内閣府、経済産業省、日本銀行、日本経済研究センター「ESPフォーキャスト調査」、Refinitiv社 Datastream

## 実質GDPの予測誤差（ベンチマークモデルの内訳）

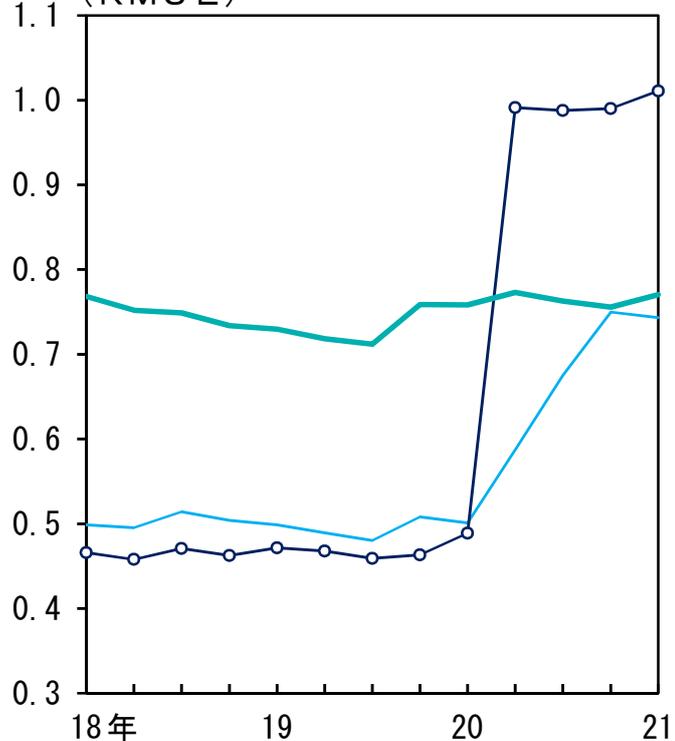
(1) 0か月前予測値のRMSE  
(RMSE)



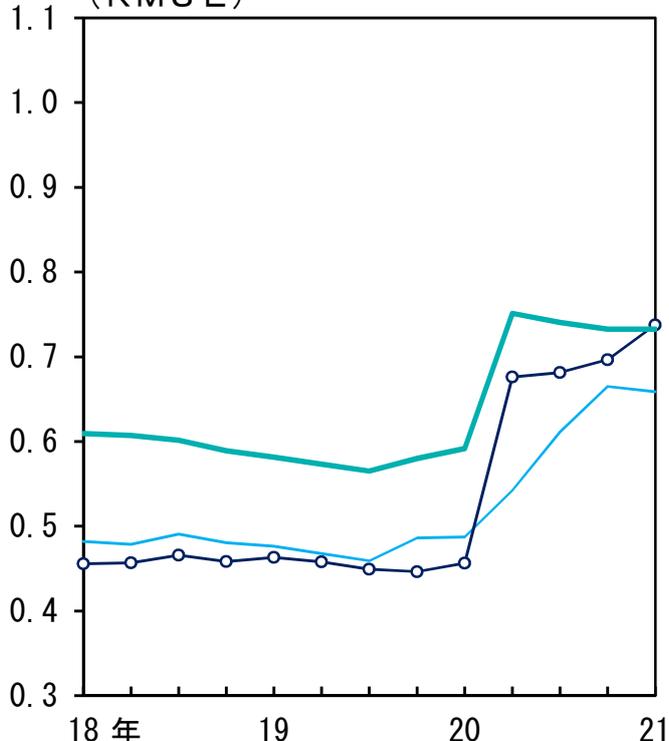
(2) 1か月前予測値のRMSE  
(RMSE)



(3) 2か月前予測値のRMSE  
(RMSE)



(4) 統合RMSE  
(RMSE)

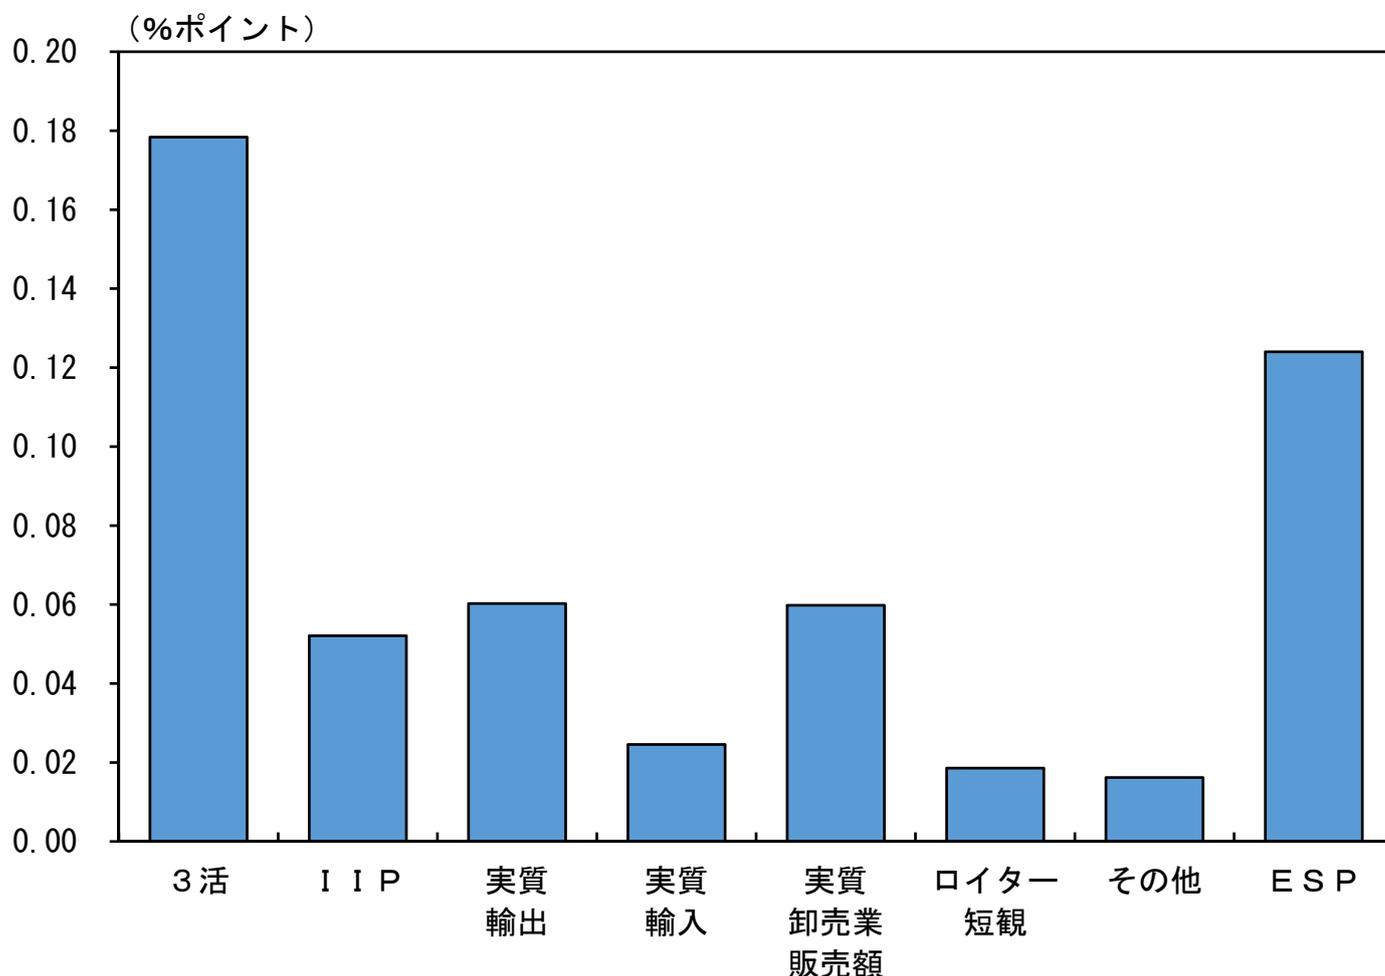


(注) RMSEの対象期間は、2013年第1四半期から各時点まで。

(出所) 内閣府、経済産業省、日本銀行、日本経済研究センター「ESPフォーキャスト調査」、Refinitiv社 Datastream

## ベンチマークモデルにおける各説明変数の寄与度

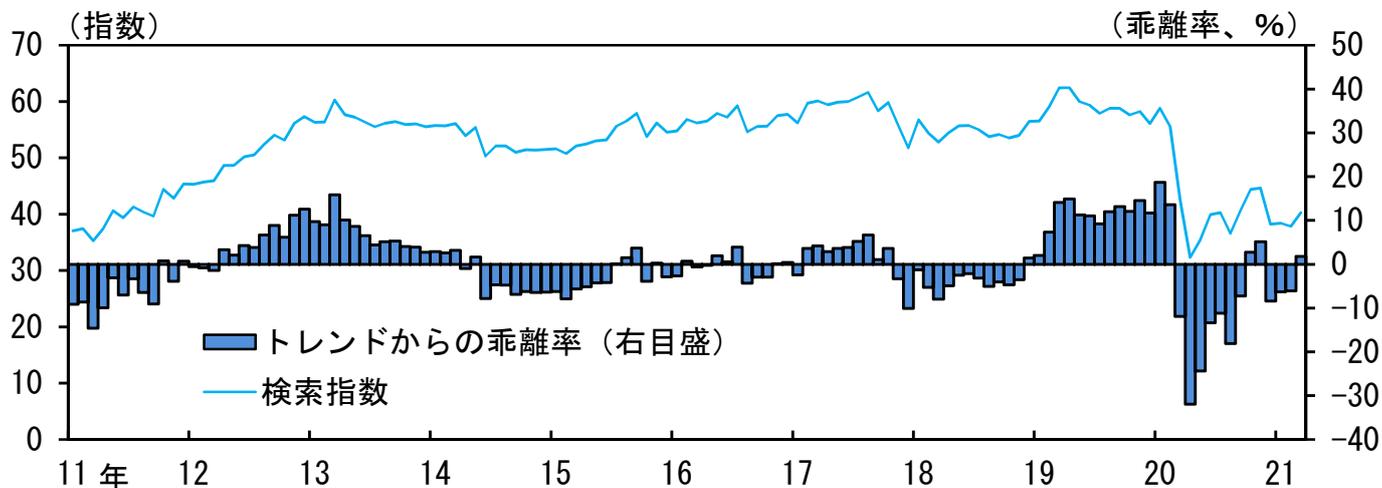
○ 各説明変数反映時の予測値変化幅（絶対値）の期間平均



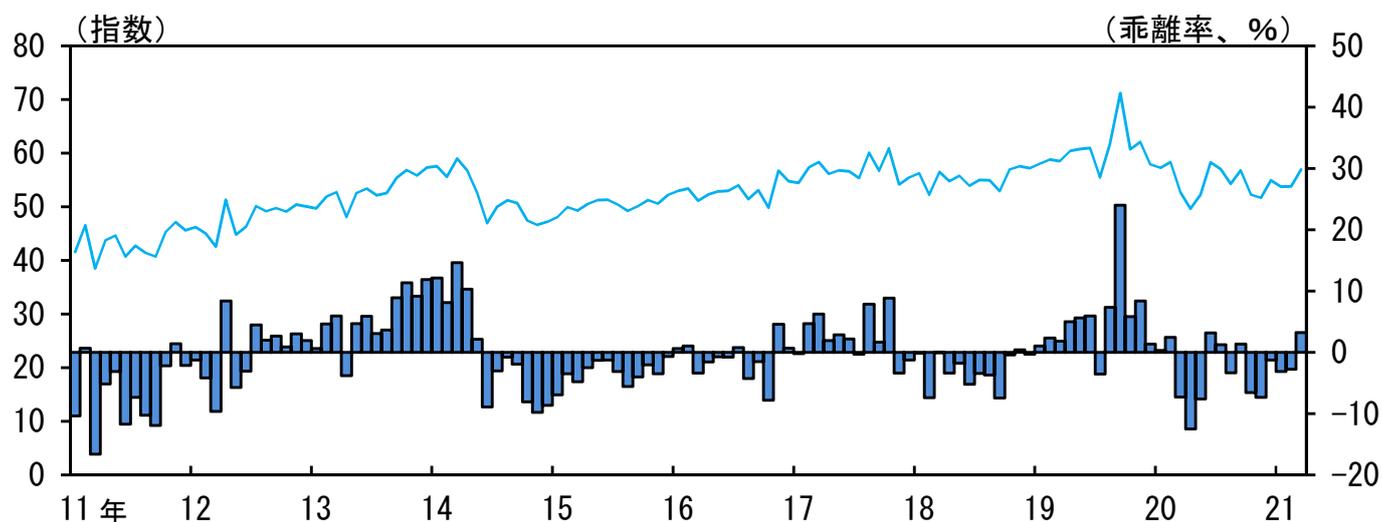
- (注) 1. 各説明変数が更新された際の、ベンチマークモデル予測値の変化幅の大きさ（絶対値）を計算し、それらを2020年第2四半期～2021年第1四半期において平均したもの。  
2. その他には定数項の変化などを含む。

## Google Trendsカテゴリ検索指数の例

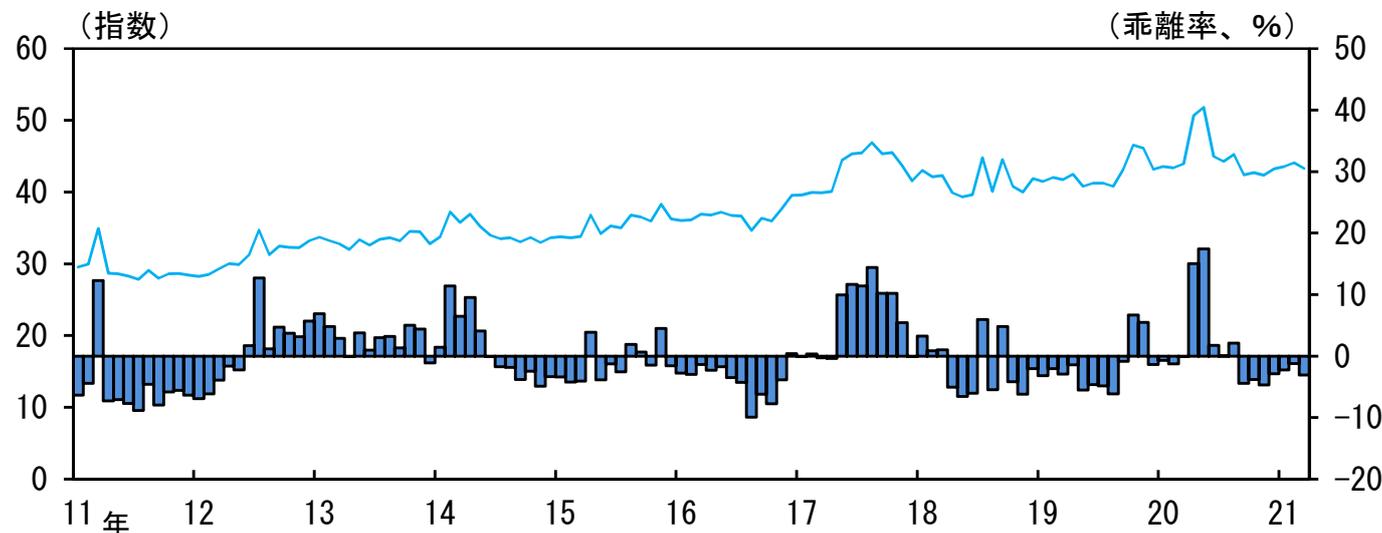
### (1) 「旅行ガイド・トラベログ」 (TravelGuides&Travelogues)



### (2) 「自動車ローン」 (AutoFinancing)



### (3) 「郵便・宅配」 (Mail&PackageDelivery)



(注) トレンドはHPフィルター (平滑化パラメーター $\lambda=14,400$ )。

(出所) Google

## Elastic Netによる3活の補外式(1)

順位	説明変数	係数	順位	説明変数	係数
1	実質卸売業販売額	0.117	59	OnlineGames	-
2	新車乗用車登録台数	0.047	60	TVCommercials	-
3	IIP	0.043	61	Signage	-
4	METIPOS (コンビニ)	0.041	62	Timeshares&VacationProperties	-
5	METIPOS (ホームセンター)	0.037	63	FilmFestivals	-
6	METIPOS (ドラッグストア)	0.035	64	MobileApps&Add-Ons	-
7	TravelGuides&Travelogues	0.023	65	RecordingIndustry	-
8	Plastics&Polymers	0.019	66	Film&TVIndustry	-
9	景気ウォッチャー指数	0.019	67	BusinessFinance	-
10	AutoFinancing	0.016	68	Boats&Watercraft	-
11	HomeFinancing	0.013	69	WebApps&OnlineTools	-
12	Optoelectronics&Fiber	0.013	70	PersonalAircraft	-
13	CarRental&TaxiServices	0.012	71	CommercialLending	-
14	InvestmentBanking	0.012	72	Consulting	-
15	Uniforms&Workwear	0.012	73	CarElectronics	-
16	PropertyInspections&Appraisals	0.010	74	AutomotiveIndustry	-
17	Headwear	0.009	75	Bicycles&Accessories	-
18	Distribution&Logistics	0.009	76	SwapMeets&OutdoorMarkets	-
19	CasualApparel	0.008	77	Campers&RVs	-
20	TouristDestinations	0.007	78	CommercialVehicles	-
21	HealthInsurance	0.006	79	Engine&Transmission	-
22	EventPlanning	0.006	80	AutoExterior	-
23	METIPOS (家電)	0.006	81	AutoInterior	-
24	VehicleFuels&Lubricants	0.005	82	CosmeticProcedures	-
25	Outsourcing	0.005	83	Wholesalers&Liquidators	-
26	TravelAgencies&Services	0.005	84	TobaccoProducts	-
27	Mobile&WirelessAccessories	0.005	85	VehicleSpecs, Reviews&Comparisons	-
28	Bed&Bath	0.005	86	Parking	-
29	Scooters&Mopeds	0.005	87	Microcars&CityCars	-
30	Printing&Publishing	0.004	88	Carpooling&Ridesharing	-
31	UrbanTransport	0.004	89	PublicStorage	-
32	ApparelServices	0.004	90	WaterSupply&Treatment	-
33	Hotels&Accommodations	0.004	91	Art&CraftSupplies	-
34	ClothingAccessories	0.003	92	Laundry	-
35	ElectronicComponents	0.003	93	Homemaking&InteriorDecor	-
36	LiveSportingEvents	0.003	94	Spas&BeautyServices	-
37	Commercial&InvestmentRealEstate	0.003	95	HairCare	-
38	AthleticApparel	0.003	96	Off-RoadVehicles	-
39	FuelEconomy&GasPrices	0.003	97	HomeImprovement	-
40	Electricity	0.002	98	Fashion&Style	-
41	Holidays&SeasonalEvents	0.002	99	AirTravel	-
42	RealEstateListings	0.002	100	Cruises&Charters	-
43	Test&Measurement	0.002	101	SoftwareUtilities	-
44	Coffee&Tea	0.002	102	WeightLoss	-
45	PropertyDevelopment	0.001	103	Pharmacy	-
46	Oil&Gas	0.001	104	Hospitals&TreatmentCenters	-
47	DiningGuides	0.001	105	Pharmaceuticals&Biotech	-
48	Eyewear	0.001	106	SportingGoods	-
49	InternetSoftware	0.001	107	HomeFurnishings	-
50	Resumes&Portfolios	0.001	108	IndustrialMaterials&Equipment	-
51	Investing	0.001	109	Freight&Trucking	-
52	MovieListings&TheaterShowtimes	0.001	110	Packaging	-
53	FormalWear	0.000	111	Moving&Relocation	-
54	KnowledgeManagement	0.000	112	Weddings	-
55	Luggage&TravelAccessories	-	113	OperatingSystems	-
56	SpecialtyTravel	-	114	DesktopComputers	-
57	ClassicVehicles	-	115	ComputerPeripherals	-
58	ISPs	-	116	E-CommerceServices	-

(注) 1. 推計期間は2012/11月～2021/3月。

2. 太字は現行指標など。説明変数は特記が無ければGoogle Trendsのカテゴリー名を示す。

3. 係数が—となっている説明変数は、スパース推定の結果、係数が0と推計されたもの。

(出所) 内閣府、経済産業省、日本銀行、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

## Elastic Netによる3活の補外式(2)

順位	説明変数	係数	順位	説明変数	係数
117	Import&Export	-	175	Currencies&ForeignExchange	-
118	Gadgets&PortableElectronics	-	176	VehicleBrands	-
119	Apartments&ResidentialRentals	-	177	RetailTrade	-
120	PhoneServiceProviders	-	178	AnimalProducts&Services	-
121	CommunicationsEquipment	-	179	Concerts&MusicFestivals	-
122	MobilePhones	-	180	GameSystems&Consoles	-
123	Beer	-	181	Freeware&Shareware	-
124	Wine	-	182	VentureCapital	-
125	Liquor	-	183	Poker&CasinoGames	-
126	Magazines	-	184	Kitchen&Dining	-
127	Bankruptcy	-	185	NuclearEnergy	-
128	Toys	-	186	FoodService	-
129	VehicleWheels&Tires	-	187	CareerResources&Planning	-
130	Photographic&DigitalArts	-	188	JobListings	-
131	Cycling	-	189	Costumes	-
132	HomeInsurance	-	190	Men'sClothing	-
133	AutoInsurance	-	191	Outerwear	-
134	ComputerDrives&Storage	-	192	Sleepwear	-
135	MultimediaSoftware	-	193	Women'sClothing	-
136	Business&ProductivitySoftware	-	194	RecreationalAviation	-
137	Cable&SatelliteProviders	-	195	METIPOS (スーパーマーケット)	-
138	ShoppingPortals&SearchEngines	-	196	CorporateEvents	-0.000
139	SmallBusiness	-	197	TV&VideoEquipment	-0.000
140	Pets	-	198	CleaningAgents	-0.001
141	Textiles&Nonwovens	-	199	Swimwear	-0.001
142	Webcams&VirtualTours	-	200	Undergarments	-0.001
143	Photo&VideoServices	-	201	HomeStorage&Shelving	-0.001
144	E-Books	-	202	Doctors' Offices	-0.002
145	Trucks&SUVs	-	203	Fire&SecurityServices	-0.002
146	TicketSales	-	204	Urban&RegionalPlanning	-0.002
147	BuildingMaterials&Supplies	-	205	WebPortals	-0.003
148	CivilEngineering	-	206	Metals&Mining	-0.004
149	ConstructionConsulting&Contracting	-	207	Housing&Development	-0.004
150	Renewable&AlternativeEnergy	-	208	Nursery&Playroom	-0.004
151	Aviation	-	209	PowerSupplies	-0.006
152	MaritimeTransport	-	210	BookRetailers	-0.006
153	RailTransport	-	211	DataSheets&ElectronicsReference	-0.006
154	Agrochemicals	-	212	DomesticServices	-0.006
155	Coatings&Adhesives	-	213	TVShows&Programs	-0.006
156	Dyes&Pigments	-	214	RiskManagement	-0.006
157	Outdoors	-	215	EntertainmentMedia	-0.009
158	LuxuryGoods	-	216	Candy&Sweets	-0.009
159	Footwear	-	217	ElectronicAccessories	-0.009
160	Welfare&Unemployment	-	218	ElectromechanicalDevices	-0.010
161	Bus&Rail	-	219	Children'sClothing	-0.010
162	ComputerComponents	-	220	PropertyManagement	-0.011
163	PhysicalAssetManagement	-	221	Laptops&Notebooks	-0.012
164	QualityControl&Tracking	-	222	FastFood	-0.013
165	Writing&EditingServices	-	223	WasteManagement	-0.019
166	ComputerServers	-	224	Mail&PackageDelivery	-0.022
167	HardwareModding&Tuning	-	225	HomeAppliances	-0.022
168	EnterpriseTechnology	-	226	OnlineVideo	-0.022
169	EducationalSoftware	-		定数項	-0.893
170	Custom&PerformanceVehicles	-			
171	Hybrid&AlternativeVehicles	-		ハイパーパラメーター	
172	CreditCards	-		$\lambda$	0.100
173	DebtManagement	-		$\alpha$	0.200
174	CollegeFinancing	-			

(注) 1. 推計期間は2012/11月～2021/3月。

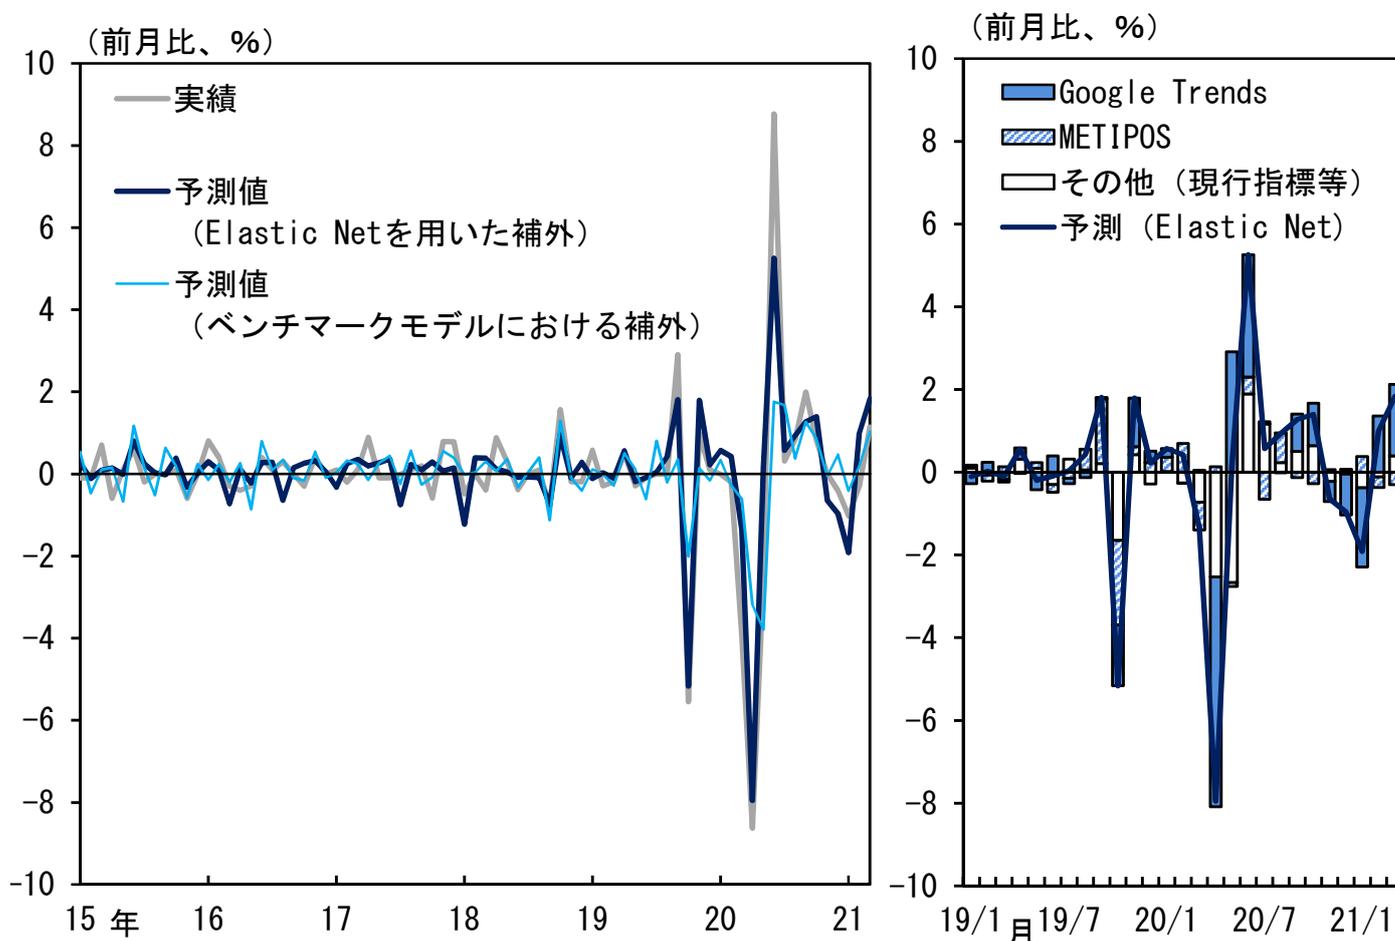
2. 太字は現行指標など。説明変数は特記が無ければGoogle Trendsのカテゴリー名を示す。

3. 係数が—となっている説明変数は、スパース推定の結果、係数が0と推計されたもの。

(出所) 内閣府、経済産業省、日本銀行、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

### 3活予測値の比較

#### (1) 3活予測値の比較、予測値における説明変数別の寄与度分解



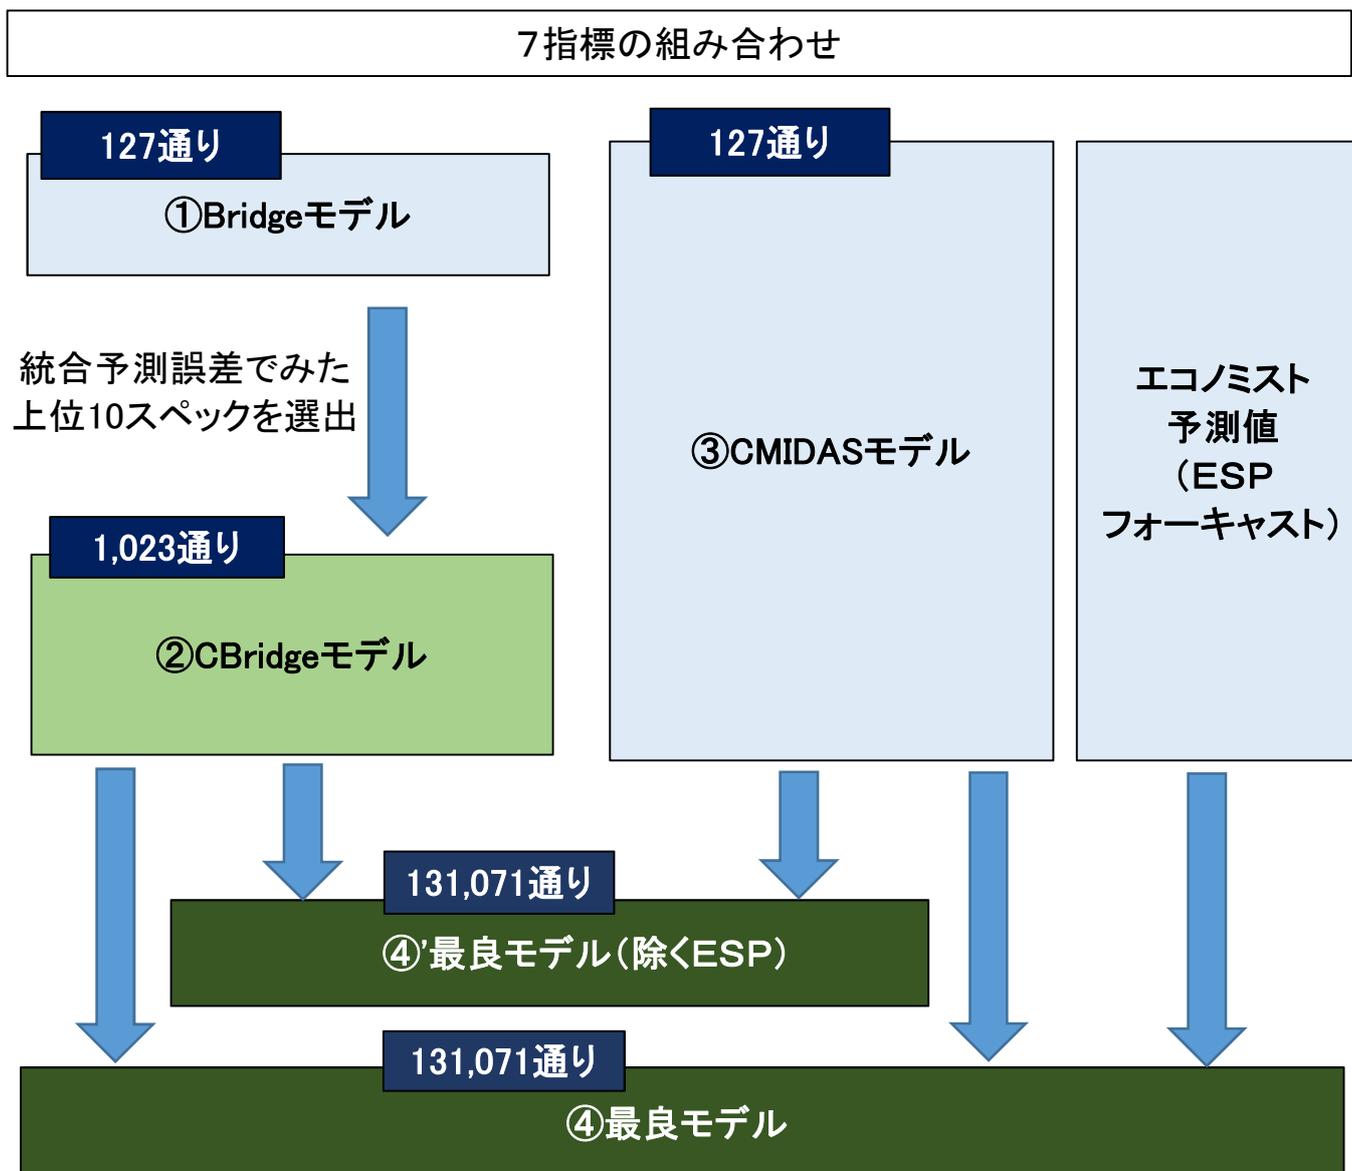
#### (2) 各補外の予測誤差 (RMSE)

	2015/1月～ 2021/3月		
		2015/1月～ 2019/12月	2020/1月～ 2021/3月
Elastic Netを 用いた補外	0.77	0.46	1.47
ベンチマークモデル における補外	1.30	0.72	2.52

(注) 予測値は3活の公表直前時点で利用可能なデータを用いて推計したもの。

(出所) 内閣府、経済産業省、日本銀行、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

## モデルの選定過程の概要



## モデルの選定の結果 (1)

### (1) ベンチマークモデル

	予測誤差 (RMSE)			
	統合	0か月前予測	1か月前予測	2か月前予測
ベンチマークモデル	0.531	0.409	0.461	0.723

### (2) Bridgeモデル (統合予測誤差が小さい方から10スペック)

順位	説明変数	予測誤差 (RMSE)			
		統合	0か月前予測	1か月前予測	2か月前予測
1	ITA EX Watcher CAR	0.494	0.444	0.506	0.534
2	ITA EX CAR	0.495	0.450	0.511	0.525
3	ITA EX Watcher	0.501	0.443	0.496	0.566
4	ITA EX	0.502	0.447	0.498	0.560
5	ITA EX IM CSC CAR	0.514	0.482	0.537	0.522
6	ITA EX IM CSC Watcher CAR	0.517	0.483	0.540	0.527
7	ITA EX CSC Watcher	0.517	0.454	0.519	0.579
8	ITA EX CSC	0.517	0.454	0.520	0.578
9	ITA EX IM Watcher CAR	0.519	0.486	0.526	0.546
10	ITA EX IM CSC	0.525	0.485	0.528	0.561

### (3) CBridgeモデル (統合予測誤差が小さい方から10スペック)

順位	組み合わせるBridgeモデル	予測誤差 (RMSE)			
		統合	0か月前予測	1か月前予測	2か月前予測
1	BR1 BR2 BR3 BR5 BR9	0.489	0.445	0.500	0.521
2	BR1 BR3 BR5 BR9	0.489	0.445	0.499	0.522
3	BR1 BR3 BR5	0.489	0.442	0.500	0.526
4	BR1 BR2 BR3 BR9	0.489	0.442	0.496	0.529
5	BR1 BR2 BR3 BR4 BR5 BR9	0.489	0.443	0.498	0.526
6	BR1 BR2 BR9	0.489	0.447	0.500	0.521
7	BR1 BR3 BR4 BR5 BR9	0.489	0.444	0.497	0.528
8	BR1 BR2 BR4 BR5 BR9	0.489	0.446	0.501	0.521
9	BR1 BR4 BR5	0.490	0.443	0.501	0.525
10	BR1 BR3 BR4 BR5	0.490	0.440	0.497	0.532

- (注) 1. RMSEの計算期間は、2013年第1四半期～2021年第1四半期。  
 2. (2)の説明変数は、ITA：3活、EX：実質輸出、IM：実質輸入、Watcher：景気ウォッチャー指数、CAR：新車乗用車登録台数、CSC：実質卸売業販売額。  
 3. (3)のBridgeモデルは、BR+(2)の順位で表されている。

## モデル選定の結果 (2)

### (1) CMIDASモデル (統合予測誤差が小さい方から10スペック)

順位	説明変数	予測誤差 (RMSE)			
		統合	0か月前予測	1か月前予測	2か月前予測
1	CSC IIP ITA EX Watcher CAR	0.643	0.530	0.575	0.825
2	CSC IIP ITA EX IM Watcher CAR	0.646	0.537	0.578	0.824
3	CSC IIP ITA EX Watcher	0.652	0.501	0.559	0.894
4	CSC IIP ITA EX IM Watcher	0.665	0.515	0.574	0.905
5	CSC IIP ITA Watcher	0.676	0.510	0.602	0.917
6	IIP ITA EX IM Watcher CAR	0.677	0.520	0.614	0.896
7	IIP ITA EX Watcher CAR	0.678	0.518	0.623	0.892
8	CSC IIP ITA Watcher CAR	0.685	0.550	0.634	0.872
9	IIP ITA EX Watcher	0.688	0.495	0.602	0.968
10	CSC IIP ITA EX CAR	0.689	0.558	0.577	0.931

### (2) 最良モデルの選定 (統合予測誤差が小さい方から5スペック)

順位	組み合わせるモデル・予測値	予測誤差 (RMSE)			
		統合	0か月前予測	1か月前予測	2か月前予測
1	COMBR1022 ESP	<b>0.484</b>	<b>0.406</b>	<b>0.509</b>	<b>0.537</b>
2	COMBR990 ESP	0.485	0.406	0.512	0.537
3	COMBR1008 ESP	0.485	0.404	0.510	0.541
4	COMBR1019 ESP	0.485	0.403	0.508	0.544
5	COMBR1012 ESP	0.488	0.406	0.513	0.544

### (3) 最良モデル (除くESP) の選定 (統合予測誤差が小さい方から5スペック)

順位	組み合わせるモデル	予測誤差 (RMSE)			
		統合	0か月前予測	1か月前予測	2か月前予測
1	COMBR1	<b>0.48876</b>	<b>0.445</b>	<b>0.500</b>	<b>0.521</b>
2	COMBR2	0.48883	0.445	0.499	0.522
3	COMBR3	0.489	0.442	0.500	0.526
4	COMBR4	0.489	0.442	0.496	0.529
5	COMBR5	0.489	0.443	0.498	0.526

- (注) 1. RMSEの計算期間は、2013年第1四半期～2021年第1四半期。  
 2. (2)の説明変数は、ITA：3活、EX：実質輸出、IM：実質輸入、IIP：鉱工業生産指数、Watcher：景気ウォッチャー指数、CAR：新車乗用車登録台数、CSC：実質卸売業販売額。  
 3. (2)、(3)のCOMBR(X)は、CBridgeモデルの統合予測誤差が小さい方からX位のモデルを示す。ESPはESPフォーキャスト予測値を示す。

## 選定されたモデルの概要

### 選定された最良モデル

○Bridgeモデル（単一式）予測値と、ESPフォーキャストの単純平均。

<構成式>①3活、実質輸出、実質輸入、景気ウォッチャー指数、新車乗用車登録台数  
②ESPフォーキャスト

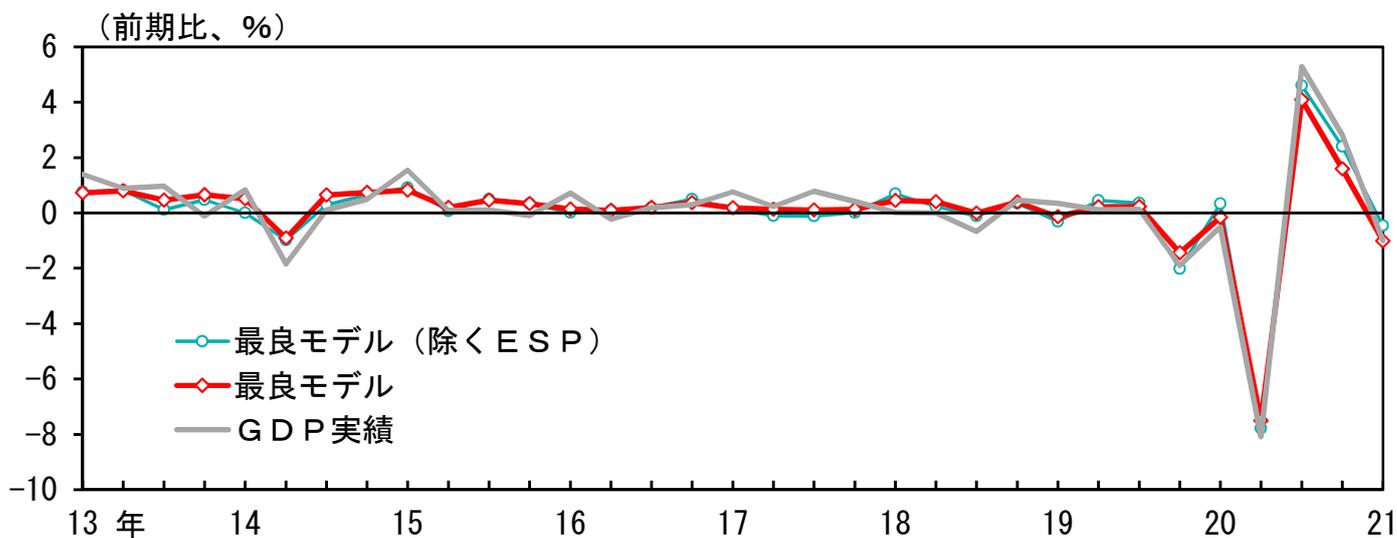
### 選定された最良モデル(除くESP)

○5つのBridgeモデル予測値を単純平均したCombined Bridgeモデル。

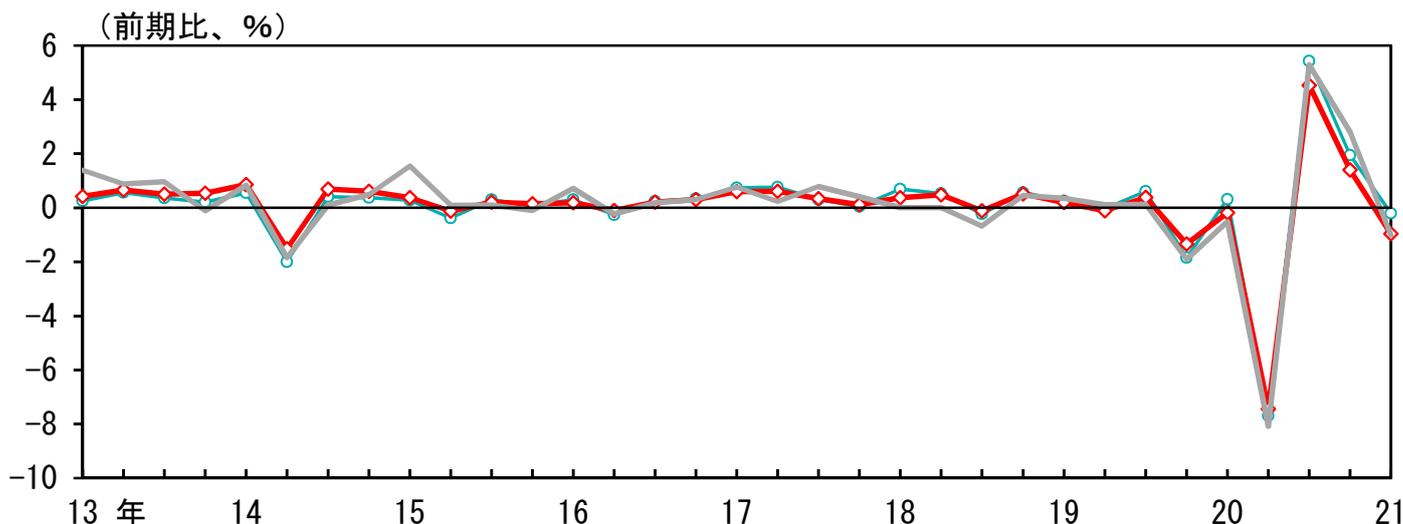
<構成式>①3活、実質輸出、景気ウォッチャー指数、新車乗用車登録台数  
②3活、実質輸出、新車乗用車登録台数  
③3活、実質輸出、景気ウォッチャー指数  
④3活、実質輸出、実質輸入、実質卸売業販売額、新車乗用車登録台数  
⑤3活、実質輸出、実質輸入、景気ウォッチャー指数、新車乗用車登録台数

## 最良モデル・最良モデル（除くESP）の予測値

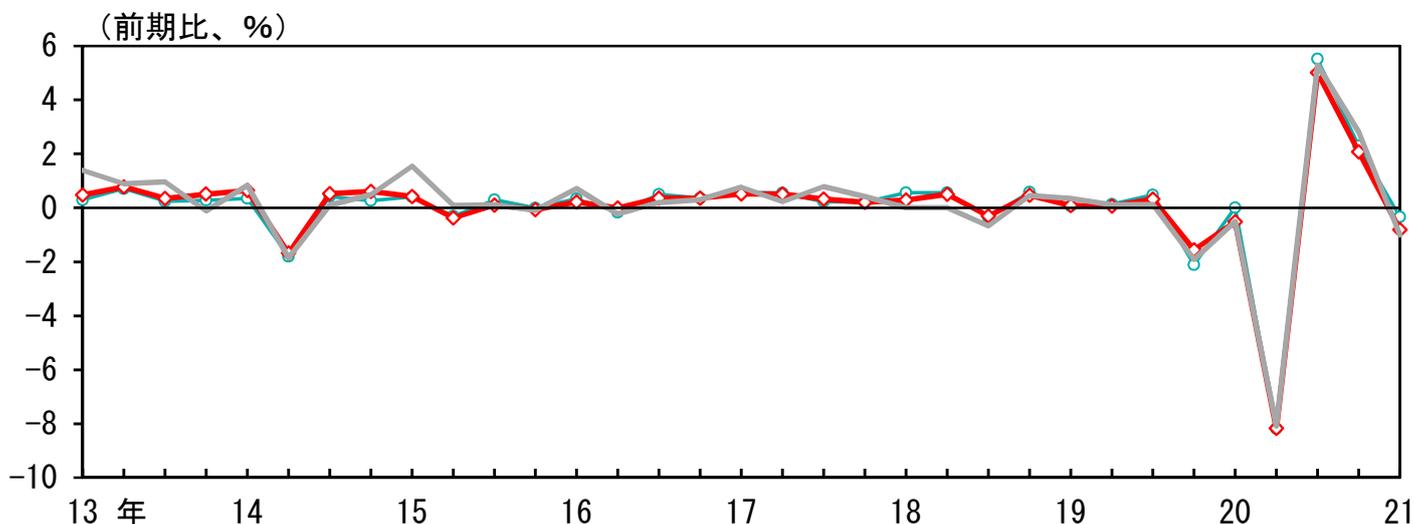
### (1) 2か月前予測値



### (2) 1か月前予測値



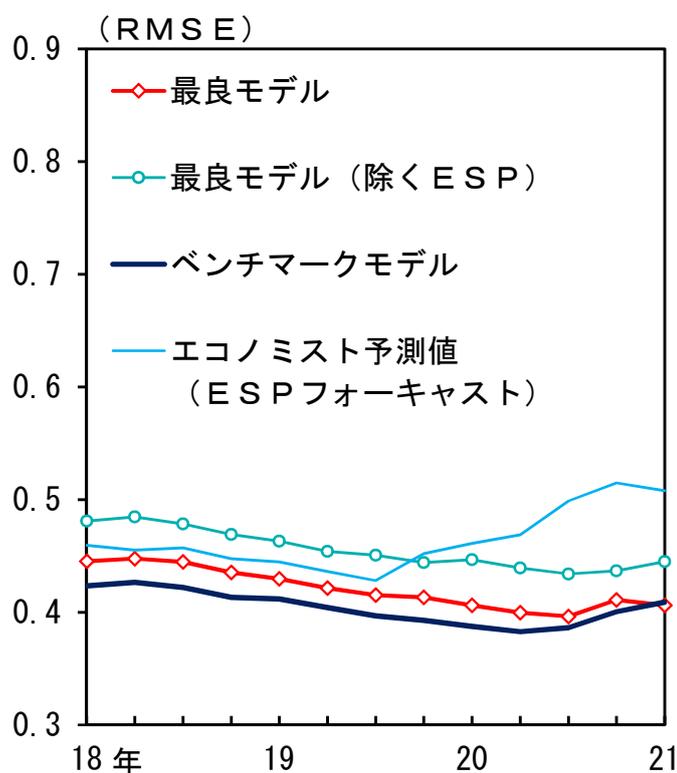
### (3) 0か月前予測値



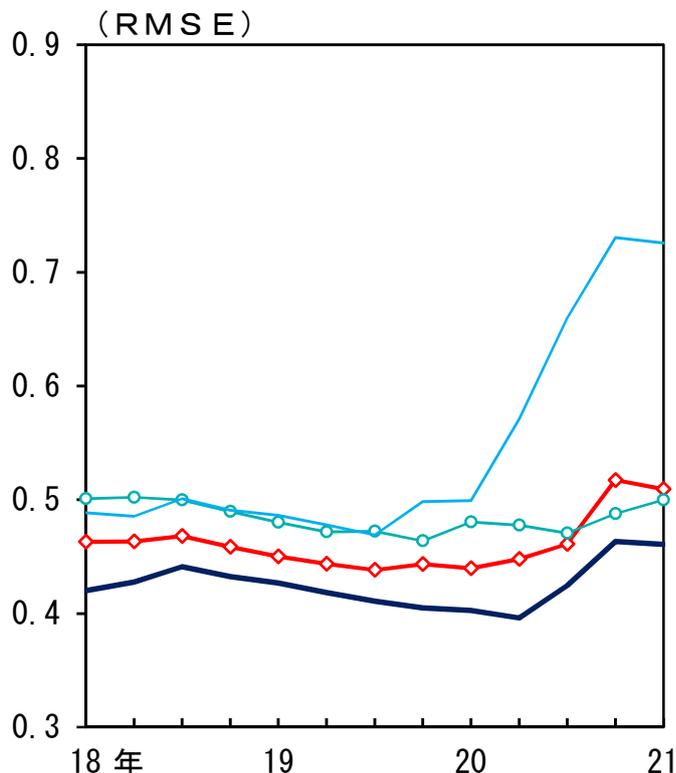
(出所) 内閣府、経済産業省、日本銀行、日本経済研究センター「ESPフォーキャスト調査」、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

## 実質GDPの予測誤差

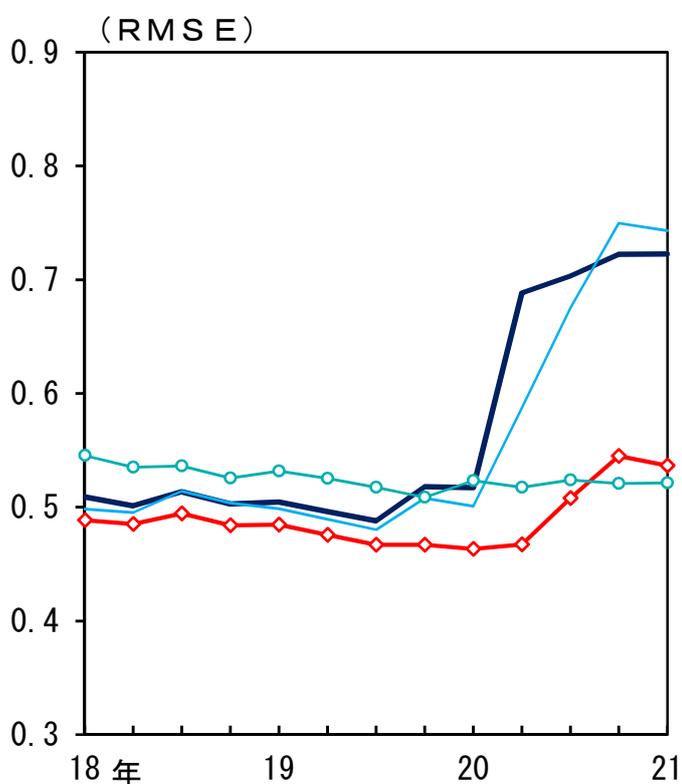
(1) 0か月前予測値のRMSE



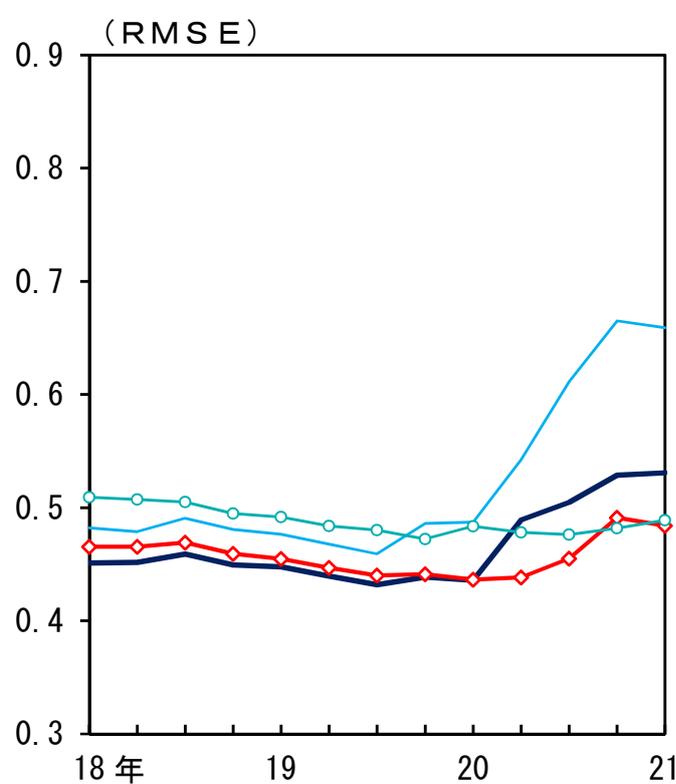
(2) 1か月前予測値のRMSE



(3) 2か月前予測値のRMSE



(4) 統合RMSE



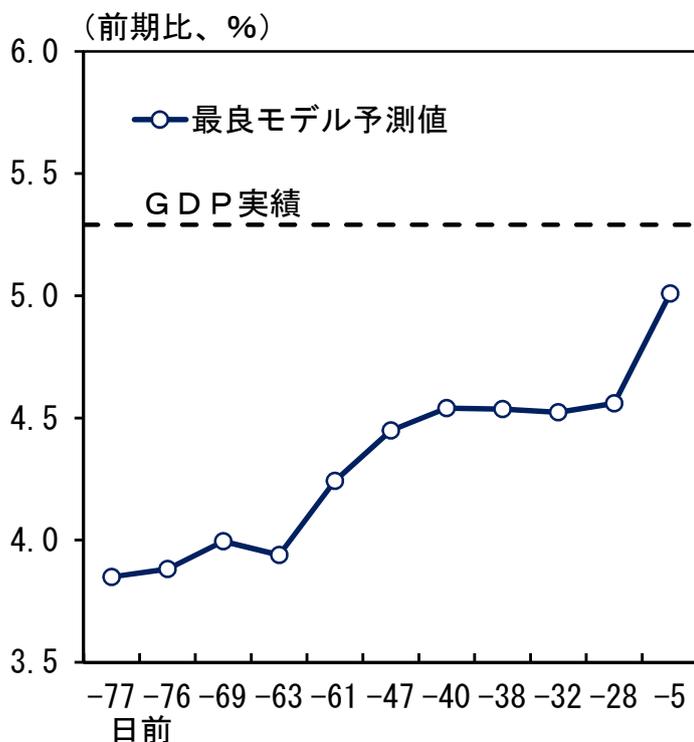
(注) RMSEの対象期間は、2013年第1四半期から各時点まで。

(出所) 内閣府、経済産業省、日本銀行、日本経済研究センター「ESPフォーキャスト調査」、Refinitiv社 Datastream、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

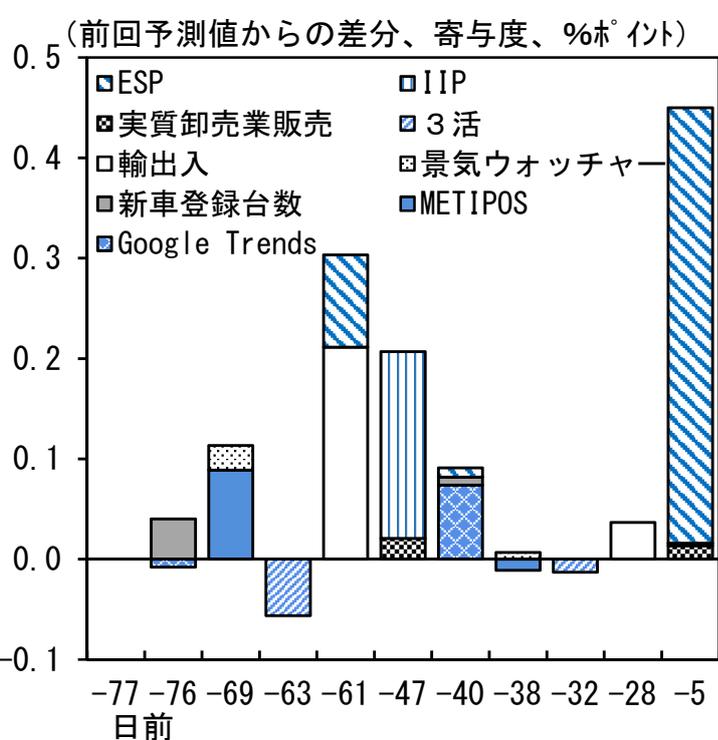
## 予測値の変遷 (2020年第3四半期の例)

### (1) 最良モデル

#### ① 予測値の推移

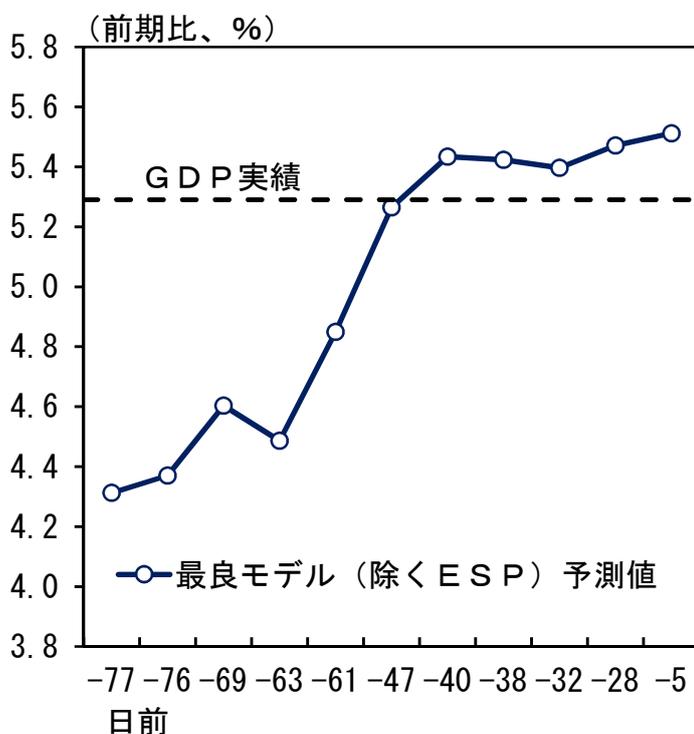


#### ② 予測値に対する説明変数別の寄与度

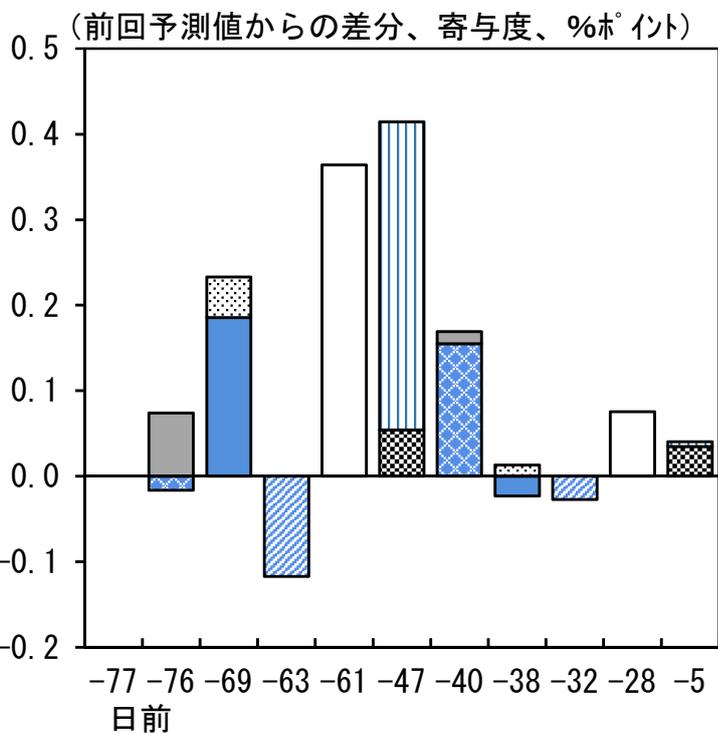


### (2) 最良モデル (除くESP)

#### ① 予測値の推移



#### ② 予測値に対する説明変数別の寄与度

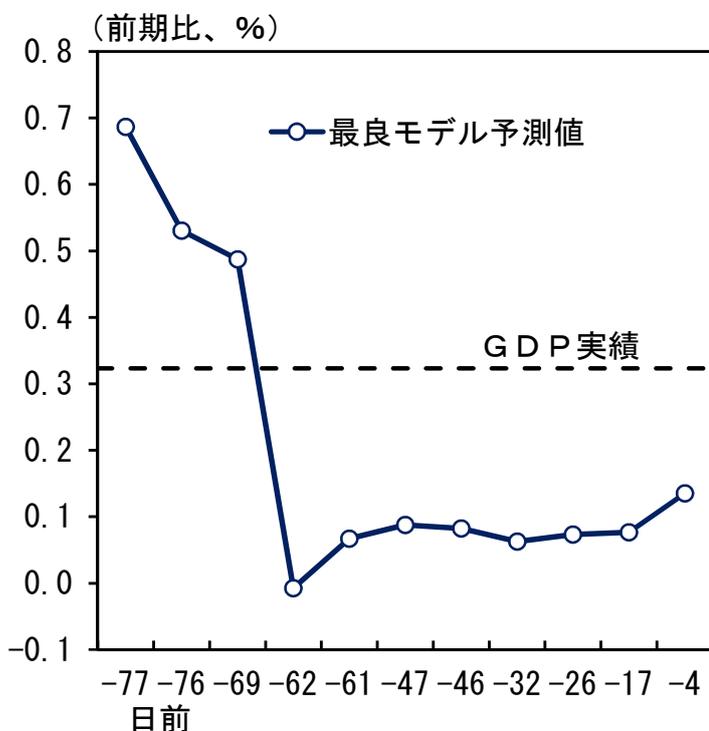


- (注) 1. 横軸は、1次QE公表日を0とした日数。  
2. 各指標の寄与度は、それぞれの指標を反映する前後での予測値の変化幅であり、予測式の係数変化分の影響を含む。  
3. Google Trends・METIPOSは、1か月分のデータが蓄積された段階で予測値に反映すると仮定。
- (出所) 内閣府、経済産業省、日本銀行、日本経済研究センター「ESPフォーキャスト調査」、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

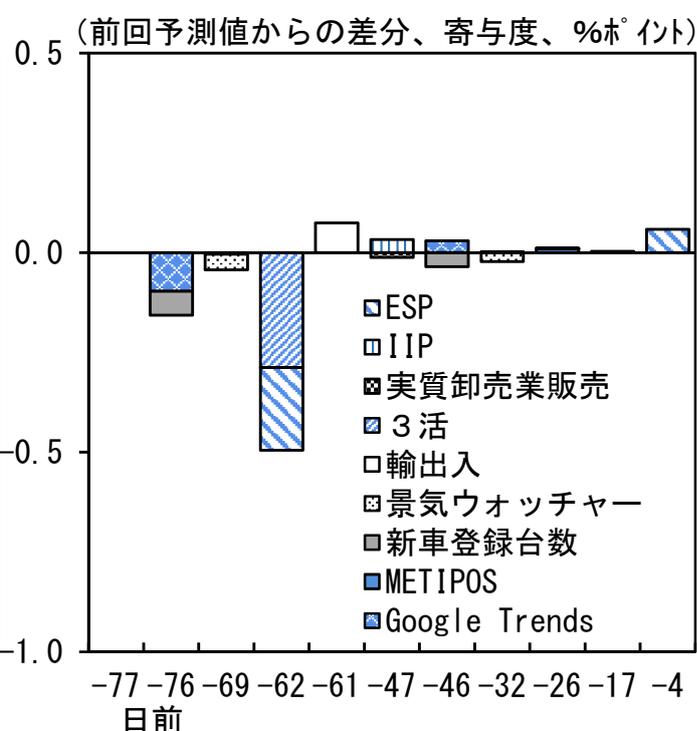
## 予測値の変遷 (2021年第2四半期の例)

### (1) 最良モデル

#### ① 予測値の推移

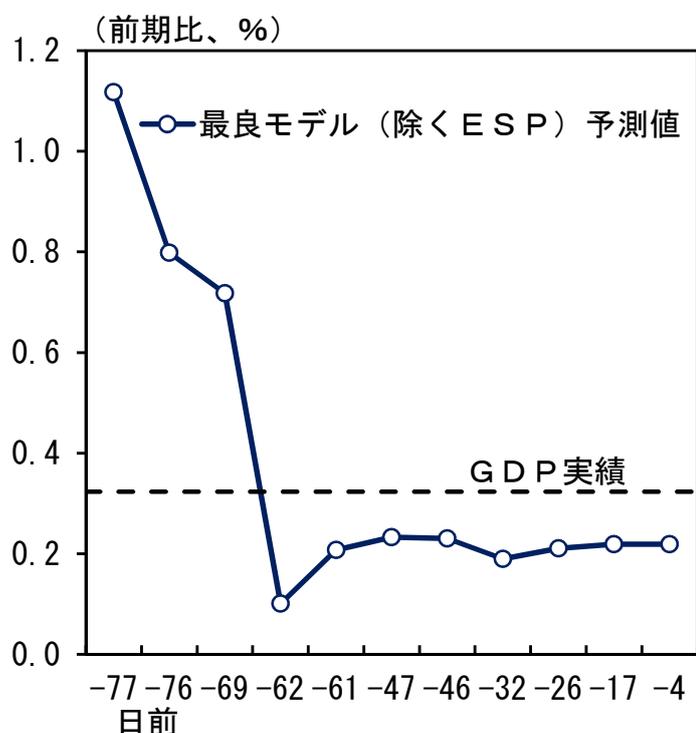


#### ② 予測値に対する説明変数別の寄与度

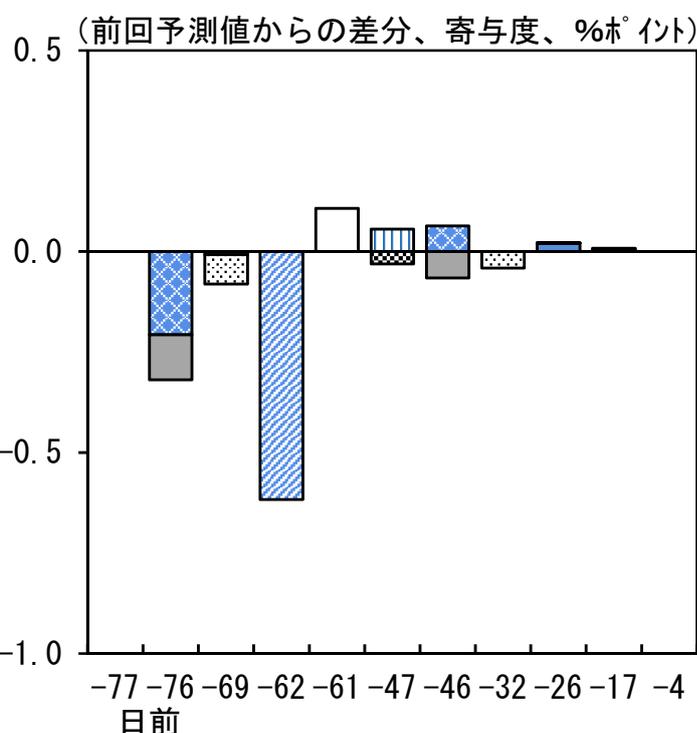


### (2) 最良モデル (除くESP)

#### ① 予測値の推移



#### ② 予測値に対する説明変数別の寄与度



- (注) 1. 横軸は、1次QE公表日を0とした日数。  
2. 各指標の寄与度は、それぞれの指標を反映する前後での予測値の変化幅であり、予測式の係数変化分の影響を含む。  
3. Google Trends・METIPOSは、1か月分のデータが蓄積された段階で予測値に反映すると仮定。
- (出所) 内閣府、経済産業省、日本銀行、日本経済研究センター「ESPフォーキャスト調査」、Google、日本自動車販売協会連合会、全国軽自動車協会連合会

## 利用データの概要

指標名	公表頻度	公表元	変換方法	公表ラグ (月)	公表ラグ (日)
第3次産業活動指数(3活)	月次	経済産業省	前月比	2	42~51
鉱工業生産(IIP)指数	月次	経済産業省	前月比	1	26~31
実質輸出	月次	日本銀行	前月比	1	16~23
実質輸入	月次	日本銀行	前月比	1	16~23
景気ウォッチャー (家計動向関連の現状判断指数)	月次	内閣府	水準	1	8~14
実質卸売業販売額 (デフレーターは企業物価指数)	月次	経済産業省 (デフレーター: 日本銀行)	前月比	1	25~31
製造工業生産予測指数 (補正值)	月次	経済産業省	前月比	0	-3~0
新車乗用車登録台数	月次	日本自動車販売協会 連合会、全国軽自動車協会連合会	前月比	0	1~6
Google Trends検索指数	日次 (月次に変換)	Google	前月比	0	1
METIPOS小売販売額指標	週次 (月次に変換)	経済産業省	前月比	0	5~9
ESPフォーキャスト調査 GDP予測値	月次	日本経済 研究センター	前期比	—	—
実質GDP(1次速報値)	四半期	内閣府	前期比	2	46~48

- (注) 1. 公表ラグは、データ対象期間(月次、四半期)の最終日からデータが公表されるまでの、おおよそのラグ期間を示す。  
2. いずれのデータも季節調整済(公表値に季節調整値がない場合は、X-12-ARIMAを用いて季節調整を実施している)。