



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と機械学習アプローチを用いた鉱工業生産ナウキャストモデリングの構築

古川角歩*

kakuho.furukawa@boj.or.jp

箕浦征郎**

yukio.minoura@boj.or.jp

久野遼平***

hisanor@g.ecc.u-tokyo.ac.jp

八木智之*

tomoyuki.yagi@boj.or.jp

No.22-J-14
2022年7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

** 調査統計局（現・金融機構局）

*** 東京大学

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と機械学習アプローチを用いた 鉱工業生産ナウキャストモデリングモデルの構築*

古川 角歩†・箕浦 征郎‡・久野 遼平§・八木 智之**

2022年7月

【要 旨】

近年、経済状況をリアルタイムに把握するために、従来の伝統的な統計データに加えて、「オルタナティブデータ」を活用する動きが広がっている。本稿では、わが国製造業の生産動向を示す鉱工業生産指数について、ナウキャストモデリングモデルの構築を試みる。構築したモデルは、次の特徴を持つ。第一に、速報性に優れたオルタナティブデータ（携帯電話の位置情報や電力需要に関するデータ）を利用しており、鉱工業生産指数公表の1～2か月前にナウキャストすることが可能である。第二に、機械学習の手法を用いて、経済情勢に応じて、「伝統的な経済統計による予測値（製造工業生産予測指数）」と「オルタナティブデータによる予測値」の混合比率を内生的に変化させてナウキャストすることで、予測精度の改善を図っている。推計結果をみると、オルタナティブデータに機械学習のアプローチを適用することで、新型コロナウイルス感染症拡大に伴う生産活動の大きな変動を含め、高い精度でナウキャストできることが分かった。

JEL 分類番号：C49、C55、E23、E27

キーワード：鉱工業生産、位置情報データ、電力データ、ナウキャスト、機械学習、新型コロナウイルス感染症

* 本稿の作成にあたっては、青木浩介氏、亀田制作氏、中島上智氏、陣内了氏、および日本銀行のスタッフから有益なコメントを頂戴した。記して感謝の意を表したい。ただし、残された誤りは筆者らに帰する。なお、本稿の内容や意見は、筆者ら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。

† 日本銀行調査統計局（kakuho.furukawa@boj.or.jp）

‡ 日本銀行調査統計局（現・金融機構局、yukio.minoura@boj.or.jp）

§ 東京大学（hisanor@g.ecc.u-tokyo.ac.jp）

** 日本銀行調査統計局（tomoyuki.yagi@boj.or.jp）

1. はじめに

近年、経済状況をリアルタイムに把握するために、「オルタナティブデータ」を活用する動きが国内外で広がっている^{1,2}。とくに新型コロナウイルス感染症の流行下では、景気変動のスピードや振幅が大きくなる場面がみられているが、伝統的な経済統計は、公表までに数週間から数か月のタイムラグが存在するため、速報性に優れたオルタナティブデータの利用が一段と進んでいる³。

例えば、米国では、ニューヨーク連銀が伝統的な経済統計（失業保険申請件数等）とオルタナティブデータ（電力使用量等）を組み合わせ、経済情勢の現状を週次でナウキャストしている（Lewis *et al.* (2020)）。わが国では、中澤（2022）がGDPについて、大久保ほか（2022）が個人消費について、それぞれオルタナティブデータを用いてナウキャストモデルを構築しており、いずれもナウキャストにあたって、オルタナティブデータの利用が有益であることを示している。また、ナウキャストモデルの構築にあたっては、従来から経済学で用いられてきた計量的手法（線形回帰分析等）だけでなく、機械学習モデルを用いた研究が増えていることも特徴点のひとつである⁴。例えば、Fornaro（2020）は、機械学習モデルを用いることで、生産活動に関するナウキャストの予測精度が向上することを示している。

本稿では、経済情勢をみるうえで重要な要素のひとつである製造業の生産動向について、オルタナティブデータと機械学習のアプローチを用いてナウキャストモデルの構築を試みる。わが国の生産動向に関する計数は、経済産業省が鉱工業生産指数（Indices of Industrial Production、IIP）として作成しているが、例えば2022年4月の実績値は翌月末の5月末に公表されており、そのタイムラグは約1か月となっている。本稿のモデルは、オルタナティブデータを用いることで、公式統計よりも1か月以上早く、生産活動の実態を捕捉することを目指す。

オルタナティブデータを用いて製造業の生産動向を分析している研究としては、水門・柳井（2020）や王ほか（2021）が挙げられる。これらの研究は、携帯

¹ 本稿では、亀田（2021）と同様に、伝統的な経済データ（月次や四半期のマクロ経済指標や上場企業の決算開示データ等）以外のデータを総称して、オルタナティブデータと呼んでいる。

² 例えば、BIS（2021）は、各国中央銀行におけるオルタナティブデータの利用状況を調査し、近年、その利用が急拡大していることを示している。

³ GDP統計（四半期）を一例にすると、米国やユーロ圏では当該四半期の翌月末、日本では翌々月中旬まで公表を待つ必要がある。

⁴ 「機械学習」の厳密な定義は論者によって異なり得るが、本稿では、ランダムフォレストや勾配ブースティング（詳細は後述）といった、従来から経済分析で用いられてきた手法とは異なるモデルを機械学習モデルと呼ぶこととする。

電話の位置情報データを使って、特定の工場敷地内における滞在人口を計測し、それと生産指数の間に高い相関があることを示している。また、水門ほか (2019) は、電力需要を用いることで鉱工業生産をナウキャストリングできると論じているほか、川村ほか (2021) はトラックのカーナビデータを用いた鉱工業生産指数のナウキャストリングを行っている。ただし、水門・柳井 (2020) や王ほか (2021) は、上記のとおりオルタナティブデータと生産指数の相関関係を示しているものの、ナウキャストリングモデルの構築には至っていない。また、水門ほか (2019) や川村ほか (2021) は、業種別の動向は分析していない。

本稿のナウキャストリングモデルでは、オルタナティブデータとして、王ほか (2021) や水門ほか (2019) に倣って、特定の工場敷地内における滞在人口データと電力需要に関するデータを用いる。また、伝統的な経済統計のひとつである製造工業生産予測指数の情報も活用することにする。伝統的な経済統計に加えて、オルタナティブデータを用いたモデルを構築することで、経済に大きなショックが加わり、伝統的な経済統計のみでは生産の動きを事前に捕捉しにくい局面でも、その動きを捉えられることが期待される。さらに、機械学習モデルを活用することで、モデル精度の向上を目指すことにする。

本稿の構成は次のとおりである。まず、第2節では、使用するデータについて説明する。第3節ではモデルの構築方法、第4節ではモデルの構築結果について、それぞれ説明する。第5節はまとめである。

2. 使用するデータ

2-1. オルタナティブデータ

本稿では、製造業の生産動向を考えるにあたって、労働投入量や資本投入量に着目する。後者の資本投入量は、資本ストックと資本の稼働率で説明することができる。これらのうち、資本ストックは企業戦略等によって比較的中長期的に変動する部分が大きく、短期的な生産変動は、労働投入量と資本の稼働率によってもたらされると考えられる。したがって、オルタナティブデータを用いてナウキャストリングを試みる際、労働投入量と稼働率の代理変数をみつけることができれば、短期的な生産変動の予測精度の向上につながると期待される。本稿では、労働投入量の代理変数として位置情報データを、稼働率の代理変数として電力データの活用を試みることにする。

（位置情報データの活用：「滞在人口指数」の作成）

位置情報データは、王ほか（2021）と同様に、株式会社 Agoop が提供する滞在人口データを利用する。当データは、日本全国を 100 メートル四方のメッシュに区切ったうえで、各メッシュにおける 1 時間ごとの滞在人口を推計したものであり、この推計値は、スマートフォン向けアプリケーションにおいて、同社がユーザーから許諾を得て取得した GPS 位置情報データに基づいている。王ほか（2021）は、工場が含まれるメッシュを特定し、当該メッシュにおける滞在人口を集計することで、各工場における生産活動の捕捉を試みている。本稿では、王ほか（2021）が作成したデータベースを用いて、製造業の生産活動を計測するための「滞在人口指数」を作成する⁵。具体的な算出方法は次のとおりである。

まず、工場 j における t 月 1 日から d 日時点までの滞在人口を以下のように基準化する。

$$PopulationIndex_{j,t,d} = \frac{Population_{j,t,d}}{Population_j} \times 100 \quad (1)$$

$Population_{j,t,d}$ は、工場 j に紐づけられたメッシュにおける、 t 月 1 日から d 日目時点までの間の、延べ滞在人口である^{6,7}。 $Population_j$ は、工場 j における 2017 年 1 月（データ始期）から 2019 年 12 月まで（感染症拡大前まで）の間のひと月あたりの平均延べ滞在人口である。なお、ある日の位置情報データは、数日後には利用可能となる。

次に、各工場における $PopulationIndex_{j,t,d}$ を、その工場で生産される財の付加価値額で加重平均することによって、業種 i の滞在人口指数を以下のように算出する⁸。

⁵ 王ほか（2021）では、製造業の工場の住所等のデータが含まれている平成 28 年経済センサス活動調査（経済産業省）の個票データを用いることで、工場に関連するメッシュを特定している。そのため、同調査が行われた時点以降に新設された工場における生産活動は捕捉することはできない点には留意が必要である。

⁶ 王ほか（2021）は、滞在人口データを集計する際、鉱工業生産指数の前年比との「相関が最も高くなる時間帯」（1 時間単位）を抽出している（例えば、輸送機械工業については 17 時から 18 時の間の滞在人口を集計している）。もっとも、今回の分析で、王ほか（2021）が使用したデータを 2021 年 9 月まで延長して検証したところ、サンプル期間によって「相関が最も高くなる時間帯」が大きく異なることが分かった。このため本稿では、時間帯を特定せず、全時間帯（24 時間）の滞在人口を使うこととする。

⁷ 具体的には、 t 月 1 日 0 時から d 日 24 時までの 1 時間ごとの平均滞在人口を足し上げることで計算している。

⁸ 各工場で生産される財の付加価値額は、平成 28 年経済センサス活動調査（経済産業省）の個票データから取得している。

$$\text{滞在人口指数}_{i,t,d} = \sum_{j \in S_i} \frac{VA_j}{\text{TotalVA}_i} \cdot \text{PopulationIndex}_{j,t,d} \quad (2)$$

ここで S_i は業種 i に分類される工場の集合、 VA_j は工場 j で生産される財の付加価値額、 TotalVA_i は業種 i に分類される全ての工場で生産される財の付加価値額の合計を表す。

本稿では、2017年1月～2021年9月について、滞在人口指数を計算する。同指数と鉱工業生産指数の相関係数は0.81となり、同指数が生産活動をナウキャストイングするうえで有用であることが示唆される(図1(a))。同指数は、とくに新型コロナ感染症拡大の影響が大きかった2020年5月においても、生産の落ち込みを捉えることができている。他方で、2021年前半の生産回復局面において、滞在人口指数の前年比は、鉱工業生産指数の前年比と比べて、低めの伸びにとどまる。この背景としては、新型コロナ感染症拡大に伴う移動制約が長引くもとの、製造業においても在宅勤務が広がったため、生産が回復する中でも工場への出勤者数が抑制された可能性が考えられる⁹。

なお、業種別に滞在人口指数と鉱工業生産指数の相関係数を比較すると、輸送機械工業などでは高い値となっている一方、電子部品・デバイス工業では低い値となっている(図1(b)、表1)。王ほか(2021)が指摘するように、電子部品・デバイス工業は資本集約度が高いため、労働投入量の代理変数である滞在人口指数のみを用いて生産活動をナウキャストイングすることの難しさを示唆していると考えられる。

(電力データの活用：「電力指数」の作成)

電力データは、電力広域的運営推進機関が提供する電力需要実績データを利用する。当データは、地域別(全国10地域)および時間帯別(1時間毎)の電力需要の実績値であり、前日分までのデータが当機関のホームページにおいて無料で公表されている。

生産活動が活発化すれば、工場における電力需要も高まると考えられるため、電力データは、製造業の生産活動のナウキャストイングに有用であるとみられる。ただし、公表されている電力データは、電力利用者別の情報が開示されおらず、製造業だけでなく、一般家庭や非製造業(例えば、商業施設)等における

⁹ 毎月勤労統計を使って労働投入量(=総実労働時間×雇用者数。在宅勤務による労働時間も集計対象)を計算すると、この局面でも、鉱工業生産指数と概ね同様の動きとなっている(図2)。工場に出勤する必要性が低い業務(例えば、製造ラインではなく、管理部門等)については在宅勤務へとシフトしていた可能性が窺われる。

電力需要も含まれていることや、気象条件に応じた冷暖房需要等の影響を受けていることには留意が必要である（図 3）。製造業の生産活動に起因する電力需要のみを抽出することは容易ではないが、本稿では、次のとおり「気象要因を除いた電力需要」である「電力指数」を算出し、製造業の生産活動のナウキャストイングに利用する¹⁰。

$$\text{電力指数}_{t,d} = \sum_{1 \leq j \leq d} \sum_i \exp[\log(\text{Elec}_{i,t,j}) - \text{Weather}_{i,t,j}] \quad (3)$$

ここで、 $\text{Elec}_{i,t,j}$ は、地域 i （全国 10 地域）における t 月 j 日の電力需要実績（日次）である。 $\text{Weather}_{i,t,j}$ は気象要因に起因する電力需要の推計値であり、地域別に気温と降水量の 1 次項と 2 次項、および両者の交差項を電力需要実績（対数）に回帰することで計算している¹¹。前述のとおり、電力データには業種別の情報が開示されていないため、ここで作成する電力指数は全業種に共通の指数となる。

本稿では、滞在人口指数と同様、2017 年 1 月～2021 年 9 月について、電力指数を計算する。同指数と鉱工業生産指数の相関係数は 0.73 と高い値になっており、滞在人口指数と鉱工業生産指数の相関係数（0.81）よりは劣るものの、同指数が生産活動をナウキャストイングするうえで有用であることが示唆される（図 4）。電力指数は、とくに、滞在人口指数で上手く捉えることができなかった 2021 年前半の生産回復局面において、鉱工業生産指数の動きを比較的上手く捉えることができています。前述のとおり、この局面では、工場の出勤者数がなお抑制されていたとみられるが、生産に用いられる電力量をみることで、生産活動の把握につながる可能性が窺える。このことから、滞在人口指数と電力指数が製造業の生産活動を異なる側面から捉えており、両者を併用してナウキャストイングモデルを構築することで、精度向上につながる可能性が示唆される。

なお、業種別に電力指数と鉱工業生産指数の相関係数を比較すると、鉄鋼・非鉄金属工業や輸送機械工業といった業種で高くなっている（表 2）。

¹⁰ ここでは、製造業の電力消費量は、主に生産要因によって変動し、気象要因を取り除いた電力指数は生産動向を捉えていると仮定している。一般家庭や非製造業の電力消費量は、短期的には、主に気象要因によって変動すると考えているが、当然ながら、これらを完全に識別することは難しく、本稿で作成した電力指数にも、製造業以外の需要動向が含まれていることには留意が必要である。

¹¹ 気象要因については、気温と湿度、降雨量のデータを用いて複数パターンの試算を行い、計算される電力指数と鉱工業生産指数の相関が最も高い組み合わせを比較考量した結果、上記の組み合わせを採用した。

2-2. 伝統的な経済統計（製造工業生産予測指数）

本稿では、上述のオルタナティブデータに加えて、経済産業省が公表している、製造工業生産予測指数も使用する。この統計は、主要企業に対して、毎月初に当該月および翌月の生産計画を調査した結果を指数化したもの（以下、それぞれ当月予測指数、翌月予測指数とする）であり、各月末に公表されている。そのため、例えば4月の生産見通し（企業の生産計画）が3月末（3月初時点での生産計画）と4月末（4月初時点での生産計画）に公表されることとなり、先行きと足もとの製造業の生産活動の状況を把握するうえで貴重なデータである。ただし、製造工業生産予測指数は、調査対象の違い等もあって、経済産業省（2020）が指摘するように、鉱工業生産指数の実績値に比べて、①高めの値になりやすい傾向や②振れが大きくなりやすい傾向がある¹²。本稿では、こうしたバイアスを修正したうえで、ナウキャストイングに利用することにする¹³。以下の分析では、とくに断りのない限り、予測指数と呼称しているものは、全てバイアスを修正した値を示す。

鉱工業生産指数とバイアス修正後の製造工業生産予測指数の相関係数をみると、翌月予測指数、当月予測指数ともに高い値（それぞれ、0.91、0.97）となっており、企業の生産計画によって生産実績を高い精度で予測できることが確認できる¹⁴（表3）。ただし、製造工業生産予測指数では、調査時点以降に災害や感染症などによって経済に大きなショックが加わった際には、当然ながら、生産活動の変動を捕捉できないとみられる。実際、新型コロナウイルス感染症拡大の影響が大きかった2020年5月には、当指数では生産の大幅な落ち込みを捉えることができていない（図5（a））。

本稿で利用する3つのデータについて、本節での議論をまとめると、伝統的な経済統計である製造工業生産予測指数は、鉱工業生産指数との相関係数が高く、製造業の生産動向を高い精度で予測できているとみられる。ただし、感染症拡大時など、当指数の調査時点以降に経済に大きなショックが加わった際——例えば、4月の生産について、当月予測指数の調査時点（月初）から月末までの

¹² 調査対象は、鉱工業生産指数の基礎統計である生産動態統計の約14,000社、412品目に対し、製造工業生産予測指数が約800社、186品目となっている。

¹³ 具体的には、予測指数の特徴（①高めの値になりやすい傾向と②振れが大きくなりやすい傾向）を踏まえて、次のように対応する。まず、①への対応として、予測指数（前年比）を「予測指数－『予測指数と鉱工業生産指数の乖離幅<過去平均>』」として修正する。次に、②への対応として、

「①で得られた予測指数」×「鉱工業生産指数の標準偏差／予測指数の標準偏差」
として修正する。なお、過去平均や標準偏差は、推計期間中の実績値を利用する。

¹⁴ なお、業種別に鉱工業生産指数と製造工業生産予測指数の相関係数をみると、輸送機械で高い一方、電子部品・デバイスでは低いなど、業種によるばらつきが存在する（図5（b））。

間に、ショックが加わった際^{15,16} —— には、生産活動の変動を捕捉できず、予測精度が悪化するとみられる。こうした場合は、日次ベースで把握可能なオルタナティブデータ（滞在人口指数や電力指数）を用いれば、予測指数で捕捉できない情報を得ることができるため、生産動向のより正確な把握につながると考えられる。次節では、こうした各データの特徴を踏まえて、ナウキャストモデルの構築を目指す。

3. ナウキャストモデルの構築方法

3-1. 予測対象と予測時点

本稿では、わが国の生産活動全体を示す鉱工業生産に加えて、主要9業種（鉄鋼・非鉄金属、金属製品、生産用機械、汎用・業務用機械、電子部品・デバイス、電気・情報通信機械、輸送機械、化学、パルプ・紙・紙加工品）の生産を対象に、それぞれナウキャストモデルを構築することにする（計10個）。

前節で説明したオルタナティブデータは、日次でデータを入手可能であるため、日次でナウキャストモデルを構築することができる。本稿では、各月の1週目（7日目）時点、2週目（14日目）時点、3週目（21日目）時点、そして月末時点における情報をそれぞれ用いて、当月の生産指数をナウキャストモデルを構築することにする（表4）。前述のとおり、例えば2022年4月の生産実績は5月末に公表されるので、本稿のナウキャストモデルでは、それよりも1~2か月程度早く生産動向を把握することができる。

3-2. 説明変数

推計式の被説明変数は各生産指数、説明変数は①滞在人口指数、②電力指数、③予測指数であり、いずれも前年比の値を利用する。③の予測指数は、モデルを作る時点で利用可能な最新の値 —— 1~3週目時点におけるモデルでは翌月予測指数、月末時点におけるモデルでは当月予測指数 —— を利用する。また、それぞれの説明変数について、1か月のラグを加えたものも検討する。説明変数として、具体的には、（1）オルタナティブデータのみを使うもの、（2）オルタナティブデータに加えて予測指数を利用するもの、（3）オルタナティブデータと

¹⁵ 製造工業生産予測指数では、各月の月初日時点における、当月および翌月の生産計画を調査している。調査票の提出締切日は毎月10日となっている。

¹⁶ このほか、ショック自体は調査時点より前に生じていたとしても、外部環境の変化が激しく、生産計画の修正が追い付いていない場合は、製造工業生産予測指数の予測精度は低下すると考えられる。

予測指数を利用し、かつラグ項も加えるもの、という複数のパターンを考える（表 5）。オルタナティブデータを利用する際、ふたつの指数のうち片方のみを用いるパターン等も考慮しており、計 9 パターンを試行する。

3-3. 推計するモデル

先行研究をみると、伝統的な計量モデル（OLS 等）から、近年の発展が著しい機械学習モデルまで、様々な種類のモデルを用いた経済指標のナウキャストイングや将来予測が試みられているが、常に予測精度が高くなるような汎用的（one-size-fits-all）なモデルは存在しない。これは、単純な手法を用いるとデータの動きを上手く捉えることができなくなることがある一方で、複雑過ぎる手法を用いると、予測モデルが既存のデータに対して過剰に適合してしまい、アウトオブサンプルの予測精度が単純な手法対比でむしろ悪化してしまいやすくなるためである（Christian and Griffiths (2017)）。この現象は過学習と呼ばれ、とくにサンプル数が少ないときに発生する可能性が高いとされている。したがって、ナウキャストイングモデルを構築する際には、サンプル数や使用するデータの特徴等を踏まえながら、過学習に陥らないように「適度な複雑さ」を持ったモデルを選択することが重要であると考えられる。この観点から、本分析では、以下の 3 種類のモデルを試行する。

（線形回帰モデル）

線形回帰モデルは、説明変数と被説明変数の関係が線形であることを仮定したシンプルなものであり、過学習が起きづらいというメリットがあると考えられる。他方で、（線形回帰の定義により、当然ではあるが）説明変数間の相互作用といったものはそもそも想定されていない。また、説明変数の数が増えすぎると、線形回帰モデルにおいても過学習が発生し、推計精度が悪化しやすくなる可能性が指摘されている（Stock and Watson (2006)）。

（機械学習による回帰モデル）

本稿では、説明変数間の相互作用や非線形性等を分析できる機械学習モデルとして、ランダムフォレストと勾配ブースティングの 2 パターンをそれぞれ推計する¹⁷。両モデルは、被説明変数と説明変数の間の関係に先験的な仮定を置くことなく推計することができ、先行研究でもよく使われるモデルである¹⁸。両モ

¹⁷ ランダムフォレストや勾配ブースティングの他のメリットとしては、説明変数が多いときでも推計結果が安定する傾向があるという点が存在する。もっとも、本分析で使用する説明変数はあまり多くないため、本分析においてはこの点によるメリットは大きくないと考えられる。

¹⁸ 多くの先行研究では、ランダムフォレストや勾配ブースティングを用いることで、経済指数の予測精度を改善できるとしている（Fornaro (2020), Batarseh *et al.* (2020), Chapman and

デルの技術的な整理は、例えば *Hastie et al. (2009)* に詳しいが、いずれも多数の決定木を構築してそのアンサンブルを用いて予測するモデルである。ランダムフォレストでは、「全体のデータから復元抽出したサンプルに基づいて決定木を構築する」というステップを繰り返す。勾配ブースティングでは、各ステップにおいて、「前回までのステップで構築した決定木を踏まえて、最終的な予測精度が高くなるように次の決定木を構築する」というステップを踏むことになる（決定木を順番に利用してモデルを構築する）。

一般的には、線形回帰モデルよりも機械学習モデルの方がより複雑なモデルとなっている。説明変数間の相互作用や非線形性の影響が強い場合には、より複雑なモデルを用いることで予測精度が改善できると考えられる。他方で、今回のオルタナティブデータのようにサンプル数が限られているときには、前述のとおり、モデルが過学習に陥る可能性が高くなることには留意が必要である。

（「混合モデル」）

第 2 節で議論したとおり、自然災害の発生や感染症拡大など、経済に予期せぬ大きなショックが加わった局面以外（以下、「平常時」と記載する）では、伝統的な経済統計である予測指数のみを用いて、生産活動を相応の精度で把握可能であると考えられる。この場合、オルタナティブデータを用いることで得られるメリット —— 予測指数に含まれていない情報を加味することが可能 —— よりも、デメリット —— 追加情報を加味し、説明変数が増えることで、過学習に陥りやすくなる恐れ —— の方が大きくなる可能性がある。

ここでは、こうしたメリットとデメリットを踏まえて、異なるアプローチを「混合」して予測値を算出する独自の手法として、「混合モデル」を提案する。機械学習の分析において、複数のアプローチを併用して新たな予測値を得る手法は「ブレンドイング」と呼ばれており、予測精度を高めるために有用であるとされている（*Timmermann (2006)*、*Bolhuis and Rayner (2020)*）。

具体的には、以下の式で予測値を計算する。

$$p \times pred^{alt} + (1 - p) \times \text{予測指数} \quad (4)$$

ここで、 $pred^{alt}$ はオルタナティブデータを用いた線形回帰モデルによる予測値である。 p は、経済状況によって変化する可変パラメータであり、0 から 1 の間の値を取る。この値は、その時々 $pred^{alt}$ と予測指数の動きに応じて、機械学

Desai (2021))). ただし、本分析では、使用するデータのサンプル数がこれらの先行研究と比べて少ないため、機械学習モデルを用いるメリットは先行研究ほど大きくない可能性がある点には留意が必要である。

習モデル（ランダムフォレストおよび勾配ブースティングの 2 パターン）を用いて算出される。前述のとおり、 $pred^{alt}$ の変動が相対的に小さい平常時であれば予測指数そのものの予測精度が相応に高くなるとみられるため、(4) 式の予測精度を向上するために、 p は小さな値になると考えられる。一方、経済に大きなショックが生じて $pred^{alt}$ が相対的に大きく変動する際はオルタナティブデータの情報価値が増すとみられるため、 p は大きな値になると考えられる^{19,20}。

以上で紹介したモデル構築方針をまとめると、本稿では、10 の予測対象（鉱工業生産と 9 業種）と 4 つの予測時点（週次の 3 時点と月末）について、それぞれ 45 のナウキャストモデル（説明変数：9 パターン、モデル：5 パターン）を構築し、比較考量する^{21,22,23}。

4. ナウキャストモデルの構築結果

4-1. 予測精度の評価方法

本稿では、2018 年 1 月～2021 年 9 月のデータを用いて、前節で検討したモデルをそれぞれ構築する。そして、2020 年 1 月～2021 年 9 月について、アウトオブサンプルの予測精度が最も高いナウキャストモデルを「最良モデル」として選択することとする。

予測精度を評価するための指標は複数存在するが、本分析では代表的な指標である平均平方二乗誤差（Root Mean Squared Error、RMSE）を用いる²⁴。具体的には、例えば、鉱工業生産指数について、まず、2019 年 12 月までの実績データを用いてモデルを構築して 2020 年 1 月分のナウキャストを行い、次に、1 月までの実績を用いて 2 月分のナウキャストを行う。この作業を 2021 年 9 月分のナウキャストまで繰り返し、RMSE が最小のモデルを最

¹⁹ 混合モデルの詳細な推計方法は補論 1 を参照。

²⁰ 五島ほか（2019）も、オルタナティブデータ（高頻度データ）は、経済変動が大きい場面で、既存の統計対比で優位性を持つと指摘している。

²¹ モデルの種類は、線形回帰モデル、ランダムフォレストと勾配ブースティングによる回帰モデル、ランダムフォレストと勾配ブースティングを用いた混合モデル、の 5 パターンとなる。

²² 食料品・たばこ工業や繊維工業など一部の業種については、予測指数が公表されていないためナウキャストモデルを構築することができない。

²³ 説明変数（滞在人口指数と電力指数）と被説明変数（鉱工業生産指数）の関係性をみると、先行遅行関係は認められず、同時点の相関係数が最も高い。このため、モデル構築にあたって、説明変数は、被説明変数と同時点のものを利用する。

²⁴ なお、別の代表的な指標である平均絶対誤差（Mean Absolute Error、MAE）を用いて予測精度を評価しても、本稿と概ね同様の結果を得ることができる。

良モデルとする。以下では、予測指数をベンチマークとし、計算された最良モデルの予測精度がベンチマーク対比で改善したか、という点を中心に検証する。

4-2. モデル構築結果²⁵

まず、鋳工業生産指数のナウキャストリングモデル構築結果を確認する。1週目（7日目）時点では、推計したモデルよりもベンチマークの方が、予測精度が優れている（図6）。この時点では、日次のオルタナティブデータの利用可能日数が限られていることもあり、モデルの精度向上にはつながらなかったとみられる。2週目以降の時点では、最良モデルの予測精度がベンチマークの精度を上回っている。月末時点では、機械学習を用いたもの（混合モデル）が最良モデルとして選択される。予測精度は、週を追うごとに改善しており、オルタナティブデータを用いることで、予測指数の調査でカバーできていない期間の生産活動に関する情報が付加され、予測精度の向上につながっていると考えられる。月末時点でのナウキャストリングモデルの推計結果をみると、今回構築した最良モデルは、とくに生産急変時にベンチマーク対比で有用である可能性が窺える。例えば、新型コロナウイルス感染症拡大の影響を受けて生産が大幅に落ち込んだ2020年5月には、ベンチマークでは生産の落ち込みを十分に予測することができていないが、最良モデルでは月末時点において高い精度で予測することができている。

次に、業種別のナウキャストリングモデルの推計結果をみると、まず月末時点では、どの主要業種でも最良モデルの予測精度がベンチマークを上回った（図7）。とくに、電子部品・デバイス工業など、ベンチマークの精度が相対的に高くない業種で、予測精度が大きく改善した。時点別にみると、電気・情報通信機械工業や電子部品・デバイス工業といった業種では比較的早い時点で最良モデルがベンチマークを上回る予測精度を達成している。

なお、月中の各時点において、ナウキャストリングモデルを推計した全10業種（鋳工業と主要9業種）の最良モデルのRMSEの平均値を計算し、ベンチマークと比較すると、1週目時点から最良モデルは平均的にベンチマークを上回る精度を達成しており、月末に近づくにつれてベンチマーク対比でRMSEの値が改善していくことが確認できる²⁶（図8）。

²⁵ 景気の情勢判断にあたって、政策当局では、季節調整済みの系列を用いて、前月比や前期比で考えることも多い。本稿で用いたオルタナティブデータは、サンプルの時系列が短く、季節調整を行うことが難しいため、本稿では前年比ベースでモデルを構築している。参考図1は、前年比ベースのナウキャストリング結果を前期比に換算した結果を示しているが、本節での議論と同様、最良モデルのRMSEは予測指数のRMSEを下回った。

²⁶ 本稿と同様に週次で鋳工業生産指数のナウキャストリングを試みた川村ほか（2021）でも、

4-3. モデル選択に関する考察

表 6 は、選択された最良モデルの一覧である。最も単純なモデルである線形回帰モデルが選択されるケースもあるが、多くの場合、混合モデルが選択されている。モデル選択の背景について、ここでは、①各モデルの RMSE の比較を通じて考察することにしたい²⁷ (図 9)。さらに、②オルタナティブデータを用いることのメリットについても、考察することにする。

まず、①各モデルの RMSE を比較すると、以下の点を指摘できる。第一に、線形回帰モデルは、各定式化において、ランダムフォレストや勾配ブースティングといった、機械学習による回帰モデルよりも RMSE が小さい。今回の分析ではサンプル数が限られていることもあり、これらの複雑なモデルを用いた結果、過学習が生じた可能性が高い。なお、この点は、今後、本稿で採用したオルタナティブデータの蓄積が進み、利用可能な時系列が延びることで、改善すると考えられる。

第二に、混合モデルは、各定式化において、線形回帰モデルおよび機械学習による回帰モデルよりも RMSE が小さい。前節で考察したとおり、オルタナティブデータを用いて経済指標をナウキャストイングする際には、線形回帰モデルでは定式化がシンプルすぎて生産活動を上手く捉えられない可能性がある。他方で、ランダムフォレストや勾配ブースティングによる回帰モデルを用いると、サンプル数が少ないなかで過学習に陥る可能性がある。本稿の推計結果は、このような状況において混合モデルが有用なアプローチであることを示唆している。

さらに、9 パターンの定式化を比較すると、各モデルにおいて、滞在人口指数と電力指数の双方を説明変数に含む「定式化 9」の RMSE が最も小さい。複数のオルタナティブデータを用いてモデルを構築することで、生産活動に関する様々な動きを捉え、ナウキャストイングの精度向上につながることを示唆される。

次に、②オルタナティブデータを利用することのメリットは、以下のような観点からも考察できる。図 10 は、月末時点の混合モデルについて、事後的に判明する製造業工業生産予測指数の実現率と、ナウキャストイングに用いるオルタナティブデータからの予測値のウェイトを示す (4) 式の p の値の関係を示し

月末に近づくにつれて同指数とモデル予測値の相関係数が高まっていくという結果を得ている。
²⁷ 機械学習アプローチは、モデルの中身が複雑であり、予測値をどのように算出しているのか、わかりにくく、解釈性の高いホワイトボックスモデル (線形回帰モデル等) との対比で、機械学習モデルはブラックボックスモデルと呼ばれることがある。ここでは、統計量を参考に、モデル選択の背景を議論することにする。

ている²⁸。両者の関係をみると、オルタナティブデータの変動から推計された p は、結果的に、製造業工業生産予測指数の予測精度が高い局面（100%近傍）では小さく、100%から離れると大きくなっている。つまり、混合モデルでは、外部環境が大きく変動し、企業が事前の生産計画を見直さざるを得ない局面で、オルタナティブデータの情報をより「重視」する（ p が大きくなる）ことで、予測精度の改善につなげていることになる²⁹。

5. まとめ

本稿では、鉱工業生産指数について、伝統的な経済統計（製造業工業生産予測指数）とオルタナティブデータ（滞在人口と電力）を組み合わせることで、また機械学習のアプローチを用いることで、ナウキャストモデルの構築を試みた。選択された最良モデルは、伝統的な経済統計対比で予測精度が改善しており、同モデルを用いることで、よりタイムリーに、そしてより正確に、鉱工業生産指数をナウキャストすることが可能になる。構築したモデルは、とくに、新型コロナウイルス感染症の流行下において、わが国の生産が急速に変動した場面において優れた予測精度を有している。

本稿の分析の留意点は次のとおりである。第一に、今回利用したオルタナティブデータは、速報性に優れているものの、そもそも生産活動を捕捉する目的で集計されたものではない。例えば、滞在人口指数は、生産を休止していても、大規模な設備点検・補修や、生産ラインの増設等によって直接生産活動と関係しない形で滞在人口が増加すれば、高めの水準で推移するかもしれない。このようなケースでは、生産と滞在人口指数との関係が変化し、本稿のナウキャストモデルの精度が低下する可能性がある。また、本稿の滞在人口指数は、平成28年の「経済センサス活動調査」の事業所データに依拠しているため、その後の工場新設や移設等の影響は考慮できていない点にも留意する必要がある。

第二に、本稿で用いたオルタナティブデータは時系列が短く、限られたサンプルでの分析となっている。今後、感染症の影響が和らぎ、経済情勢が新たな局面に移るなかで、本稿で構築した最良モデルのパフォーマンスが変化する可能性

²⁸ 実現率は、予測指数を鉱工業生産指数（実績値）で割った値。

²⁹ 言い換えれば、モデルで推計された p と事後的に判明する予測指数の実現率の間に図10のような関係がみられるということは、オルタナティブデータの変動状況から混合モデルを構築することで、事前に予測指数として示されている生産計画が修正される可能性を上手く予測できていることを示唆している。

もあり得る。また、本稿で利用しなかったオルタナティブデータを用いることで、モデルのパフォーマンスがさらに改善する可能性もある³⁰。

以上を踏まえると、ナウキャスト精度のさらなる向上に向けて、オルタナティブデータの蓄積を進めつつ、その特性に対する理解を深めることや、経済の構造変化等に応じて最適なモデルを探求することが求められる。

³⁰ この点、補論 2 では、ナウキャストモデルの拡張例として、自動車の交通量データを用いた分析を紹介する。

【参考文献】

- 王悠介・須合智広・高橋耕史・松村浩平 (2021)、「位置情報データによる経済活動のナウキャストイング」、日本銀行ワーキングペーパーシリーズ、No. 21-J-2
- 大久保友博・高橋耕史・稲次春彦・高橋優豊 (2022)、「『オルタナティブデータ消費指数』の開発：オルタナティブデータを用いた個人消費のナウキャストイング」、日本銀行ワーキングペーパーシリーズ、No. 22-J-9
- 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、No. 2021-J-16
- 川村健史・久保達郎・淀谷恵実 (2021)、「トラックカーナビデータを用いた鉱工業生産指数の予測 —— 機械学習を用いた試み ——」、内閣府経済財政分析ディスカッション・ペーパー
- 五島圭一・高橋大志・山田哲也 (2019)、「自然言語処理による景況感ニュース指数の構築とボラティリティ予測への応用」、『金融研究』、Vol. 38(3)、pp. 1-41
- 経済産業省 (2020)、「生産計画から生産動向が読み解ける？製造工業生産予測指数の活用法」、METI Journal Online、<https://journal.meti.go.jp/p/9255/>
- 水門善之・和泉潔・坂地泰紀・島田尚・松島裕康 (2019)、「高頻度電力需要データを用いた製造業活動のナウキャストイングモデルの構築」、人工知能学会第 35 回社会における AI 研究会、Vol. 35(1)、pp. 1-5
- 水門善之・柳井都古杜 (2020)、「携帯電話GPSデータに基づく自動車生産量のナウキャストイングと株式投資戦略」、『人工知能学会第 25 回金融情報学研究会』、pp. 9-12
- 中澤崇 (2022)、「オルタナティブデータを用いたGDPナウキャストイングモデルの構築」、日本銀行ワーキングペーパーシリーズ、No. 22-J-1
- Batarseh, F.A., M. Gopinath, and A. Monken (2020), "Artificial Intelligence Methods for Evaluating Global Trade Flows," International Finance Discussion Papers 1296, Washington: Board of Governors of the Federal Reserve System.
- BIS (2021), "Use of Big Data Sources and Applications at Central Banks," IFC Report No.13 Feb. 2021.

- Bolhuis, M.A. and B. Rayner (2020), "Deus ex Machina? A Framework for Macro Forecasting with Machine Learning," IMF Working Paper Series, No. 20/45.
- Chapman, J.T.E. and A. Desai (2021), "Using Payments Data to Nowcast Macroeconomic Variables during the Onset of COVID-19," Bank of Canada Staff Working Paper, 2021-2.
- Christian, B. and T. Griffiths (2017), *Algorithms to Live by: The Computer Science of Human Decisions*, Henry Holt and Company.
- Fornaro, P. (2020), "Nowcasting Industrial Production Using Unconventional Data Sources," ETLA Working Papers, No. 80.
- Hastie, T., R. Tibshirani, and J.H. Friedman (2009), *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, 2nd Edition*, Springer.
- Lewis, D., K. Mertens, J.H. Stock, and M. Trivedi (2020), "High Frequency Data and a Weekly Economic Index during the Pandemic," Federal Reserve Bank of New York Staff Reports, No. 954.
- Stock, J.H., and M.W. Watson (2006), "Forecasting with Many Predictors," *Handbook of Economic Forecasting*, Vol. 1, pp. 515–554.
- Timmermann, A., (2006) "Forecast Combinations," in Elliott, G., C.W.J. Granger, and A. Timmermann, *Handbook of Economic Forecasting*, Elsevier.

(補論 1) 混合モデルの具体的な推計方法

本稿で使用した混合モデルの具体的な推計方法は次のとおり。推計は、月中のナウキャストタイミング時点（1 週目、2 週目、3 週目、月末）別および業種別に行う。

-
- ステップ 1： オルタナティブデータを説明変数として含む線形回帰モデルを推計し、生産指数の予測値 $pred^{alt}$ を計算する³¹。
- ステップ 2： $pred^{alt}$ とそれに対応する予測指数について、業種別の平均値と標準偏差を用いて標準化したものを、それぞれ z^{alt} 、 z^{trad} とする。
- ステップ 3： 線形回帰モデルの予測値の予測精度が予測指数を上回るときに 1、それ以外るときに 0 となる変数 y を計算する。
- ステップ 4： y を被説明変数、 z^{alt} と z^{trad} を説明変数とするモデルを、ランダムフォレストまたは勾配ブースティングで学習する。
- ステップ 5： 学習したモデルにもとづいて、 $y = 1$ となる確率 p を計算する。
- ステップ 6： 予測値を次式で計算する。

$$p \times pred^{alt} + (1 - p) \times \text{予測指数}$$

³¹ 本稿における分析では、線形回帰モデルの説明変数の組み合わせとして、表 5 と同じ 9 パターンを試行した。

(補論 2) ナウキャストモデルの将来的な拡張余地

本稿では、鉱工業生産指数のナウキャストモデル構築にあたって、オルタナティブデータである位置情報データと電力データを活用している。生産活動におけるインプットを示す代理変数としてこれらを利用しているが、今後、幅広い種類のオルタナティブデータの整備が進めば、モデルのさらなる精度向上につながるかもしれない。こうした観点から、本補論では、自動車の交通量データを用いた分析を行う。このデータは、現時点では速報性を有していないが、リアルタイムに開示されるようになれば、ナウキャストモデルに拡張できる可能性がある。

(「交通量指数」の算出)

本分析では、社会基盤情報流通推進協議会が提供する「断面交通量データ（位置情報付）提供 API」を使用し、全国の約 4 万の観測地点（一般道）を通過する車両台数（「断面交通量」と呼称）を集計する³²。当データは、リアルタイムで公表されているわけではなく —— 例えば、1 月分のデータは 3 月初に入手可能となる ——、現時点でナウキャストモデルに用いるのは難しいが、特定工場周辺の交通量を把握できれば、生産活動におけるインプットに関する情報（原材料や部品の搬入量）の代理変数となる可能性がある³³。

ここでは、断面交通量データを製造業の生産活動のナウキャストモデルに活用するために、以下のステップで「交通量指数」を算出する。まず、工場ごとに半径 500 メートル圏内に位置する観測地点を抽出する。その際、観測地点の半径 500 メートル以内に複数の工場が存在するケースもあるが、こうした観測地点については、特定の工場と紐づけることができないため、集計から除外した。次に、各工場について、抽出された観測地点における交通量を集計し、その工場へ出入りしたと考えられる交通量を計算する。最後に、滞在人口指数と同じ方法で、各工場に関する交通量を付加価値額で加重平均し、業種別の交通量指数を算出する。

$$\text{交通量指数}_{i,t} = \sum_{j \in S'_i} \frac{VA_j}{\text{TotalVA}'_i} \cdot \text{交通量}_{j,t} \quad (\text{A1})$$

³² 同データは、全国の都道府県警察が収集した一般道の断面交通量に関する情報を警察庁が取りまとめ、日本道路交通情報センターが提供している。社会基盤情報流通推進協議会が提供する API サービスを使用することで、断面交通量データを任意の時間・箇所から抽出し、断面交通量計測地点の位置情報を取得することができる。

³³ 同時に、出荷に関する情報を捉えている可能性もある。

ここで交通量 $_{j,t}$ は、工場 j における t 月の交通量をサンプル期間（2018 年 7 月～2021 年 9 月）の平均が 100 になるように標準化したものであり、 S'_i は業種 i に分類される工場のうち交通量を観測できる工場の集合、 VA_j は工場 j で生産される財の付加価値額、 $TotalVA'_i$ は S'_i に含まれる工場で生産される財の付加価値額の合計を表す。全国の工場のうち約 26%（付加価値ベース）について、近隣の交通量が観察することができる。

（交通量指数と鉱工業生産指数）

算出された交通量指数をみると、2019 年 7 月から 2021 年 9 月までの期間において、交通量指数と鉱工業生産指数との相関係数は 0.73 と高い値を示している（図 11 (a)）。業種別の生産指数との相関係数についても、輸送機械工業や電気・情報通信機械工業といった業種で高い相関がみられるほか、滞在人口指数との相関が低い（0.35）電子部品・デバイスについても、交通量指数との相関は 0.54 と高めの値となる（図 11 (b)、表 7）。

次に、交通量指数を用いることで実際に生産指数のナウキャストの精度を向上できるか、線形回帰モデルを用いて考察する³⁴。図 12 (a) は、説明変数として交通量指数のみ用いた場合（スペック 1）と、交通量指数に加えて、ほかのオルタナティブデータ（滞在人口指数と電力指数）と予測指数も用いた場合（スペック 2）の推計結果を示しており、多くの業種で交通量指数の係数は統計的に有意となっている。また、図 12 (b) で、説明変数としてオルタナティブデータと予測指数だけでなく、交通量指数も加えたスペック 2 と、オルタナティブデータと予測指数のみを用いたスペック 3（表 5 における定式化 6 に該当）の自由度調整済み決定係数を比較すると、いずれの業種についても、交通量指数を用いることで決定係数の値が幾分改善している。

以上の分析から、交通量に関するオルタナティブデータを使用することで、鉱工業生産指数のナウキャスト精度がさらに改善する可能性が示唆される。当データは前述のとおり、現時点においてリアルタイムで活用できるものではないが、今後、当データを含めて公共性の高いオルタナティブデータがリアルタイムに開示されるようになれば、経済予測への応用可能性も高まると期待される。

³⁴ 断面交通量データのサンプル期間が短く、アウトオブサンプルの予測精度を評価することが難しいため、ここでは、インサンプルにおける交通量指数の予測精度への影響について確認している。

表 1. 鉱工業生産指数と滞在人口指数の相関係数

業種	相関係数
鉱工業	0.81
輸送機械工業	0.76
金属製品工業	0.72
鉄鋼・非鉄金属工業	0.67
電気・情報通信機械工業	0.61
化学工業	0.60
汎用・業務用機械工業	0.51
生産用機械工業	0.46
パルプ・紙・紙加工品工業	0.39
電子部品・デバイス工業	0.35

(注) 業種別の鉱工業生産指数と滞在人口指数（月中平均）の前年比の相関係数（2018年1月～2021年9月）。
 (出所) 経済産業省、Agoop

表 2. 鉱工業生産指数と電力指数の相関係数

業種	相関係数
鉄鋼・非鉄金属工業	0.76
鉱工業	0.73
輸送機械工業	0.72
金属製品工業	0.71
電気・情報通信機械工業	0.68
パルプ・紙・紙加工品工業	0.68
生産用機械工業	0.57
汎用・業務用機械工業	0.57
電子部品・デバイス工業	0.53
化学工業	0.49

(注) 業種別の鉱工業生産指数と電力指数（月中平均）の前年比の相関係数（2018年1月～2021年9月）。
 (出所) 経済産業省、電力広域的運営推進機関、気象庁

表 3. 鋳工業生産指数と製造工業生産予測指数の相関係数

(a) 翌月予測指数

業種	相関係数
鉄鋼・非鉄金属工業	0.93
生産用機械工業	0.92
輸送機械工業	0.91
鋳工業	0.91
汎用・業務用機械工業	0.87
化学工業	0.86
金属製品工業	0.85
電気・情報通信機械工業	0.84
パルプ・紙・紙加工品工業	0.71
電子部品・デバイス工業	0.68

(b) 当月予測指数

業種	相関係数
輸送機械工業	0.97
鋳工業	0.97
鉄鋼・非鉄金属工業	0.96
生産用機械工業	0.95
金属製品工業	0.94
電気・情報通信機械工業	0.91
パルプ・紙・紙加工品工業	0.91
化学工業	0.88
汎用・業務用機械工業	0.87
電子部品・デバイス工業	0.80

(注1) 業種別の鋳工業生産指数と製造工業生産予測指数の前年比の相関係数 (2018年1月~2021年9月)。

(注2) 製造工業生産予測指数はバイアス修正後の指数。

(出所) 経済産業省

表 4. 使用するデータとナウキャストモデルの時系列関係

		予測指数・生産指数関連 スケジュール (統計公表日等)	本稿モデルの ナウキャスト結果算出時期
$t-1$ 月	月初	予測指数：翌月 (t 月) 分回答時期 (調査票提出締切日：10日)	ナウキャスト結果算出 (1週目時点)
	月末	予測指数：翌月 (t 月) 分公表	
t 月	7日		
	月初	予測指数：当月 (t 月) 分回答時期 (調査票提出締切日：10日)	ナウキャスト結果算出 (2週目時点)
	14日		ナウキャスト結果算出 (3週目時点)
	21日		ナウキャスト結果算出 (月末時点)
	月末	予測指数：当月 (t 月) 分公表	
$t+1$ 月	月末	鋳工業生産指数： t 月分公表	

表 5. 本分析で使用する説明変数の組み合わせ

	(1)	(2)	(3)	定式化			(7)	(8)	(9)
				(4)	(5)	(6)			
滞在人口指数	✓		✓	✓		✓	✓		✓
電力指数		✓	✓		✓	✓		✓	✓
予測指数				✓	✓	✓	✓	✓	✓
滞在人口指数 (1 か月ラグ)							✓		✓
電力指数 (1 か月ラグ)								✓	✓
鉱工業生産指数 (1 か月ラグ)							✓	✓	✓

(注 1) 予測指数は、1 週目～3 週目時点では翌月予測指数、月末時点では当月予測指数を利用する。

(注 2) 鉱工業生産指数 (1 か月ラグ) は、1 週目～3 週目時点では前月分の指数が公表されていないため、前月分の当月予測指数の値を利用する。

表 6. 業種別・時点別最良モデル

業種	1週目	2週目	3週目	月末
鉱工業	RF 混合 (7)	GB 混合 (6)	線形回帰 (4)	GB 混合 (9)
鉄鋼・非鉄金属工業	GB 混合 (7)	GB 混合 (7)	GB 混合 (9)	GB 混合 (6)
金属製品工業	GB 混合 (7)	GB 混合 (6)	GB 回帰 (5)	GB 混合 (6)
生産用機械工業	線形回帰 (6)	RF 混合 (5)	RF 混合 (5)	GB 回帰 (8)
汎用・業務用機械工業	GB 混合 (4)	線形回帰 (4)	線形回帰 (4)	線形回帰 (4)
電子部品・デバイス工業	RF 回帰 (8)	RF 回帰 (8)	RF 回帰 (8)	線形回帰 (9)
電気・情報通信機械工業	線形回帰 (5)	線形回帰 (5)	RF 混合 (6)	GB 混合 (9)
輸送機械工業	GB 混合 (6)	RF 混合 (6)	RF 混合 (4)	RF 混合 (4)
化学工業	GB 回帰 (8)	GB 回帰 (8)	GB 回帰 (9)	GB 混合 (7)
パルプ・紙・紙加工品工業	RF 回帰 (8)	GB 回帰 (5)	GB 回帰 (5)	GB 混合 (6)

(注 1) 業種別、時点別に、RMSE の値が最も小さかったナウキャストモデルを記載している。

(注 2) 「線形回帰」は線形回帰モデルを、「RF 回帰」、「GB 回帰」はそれぞれランダムフォレストと勾配ブースティングによる回帰モデルを、「RF 混合」、「GB 混合」はそれぞれランダムフォレストと勾配ブースティングを用いた混合モデルを示す。括弧内の数字は表 5 における定式化の番号を示す。

(注 3) シャドウは、RMSE の値が予測指数よりも大きいモデルを示す。

表 7. 鉱工業生産指数と交通量指数の相関係数


業種	相関係数
輸送機械工業	0.81
鉱工業	0.73
電気・情報通信機械工業	0.69
汎用・業務用機械工業	0.68
電子部品・デバイス工業	0.54
金属製品工業	0.53
生産用機械工業	0.44
パルプ・紙・紙加工品工業	0.43
鉄鋼・非鉄金属工業	0.39
化学工業	0.17

(注) 業種別の鉱工業生産指数と交通量指数の前年比の相関係数 (2019年7月~2021年9月)。


(出所) 経済産業省、社会基盤情報流通推進協議会

図1. 鉱工業生産指数と滞在人口指数

(a) 鉱工業



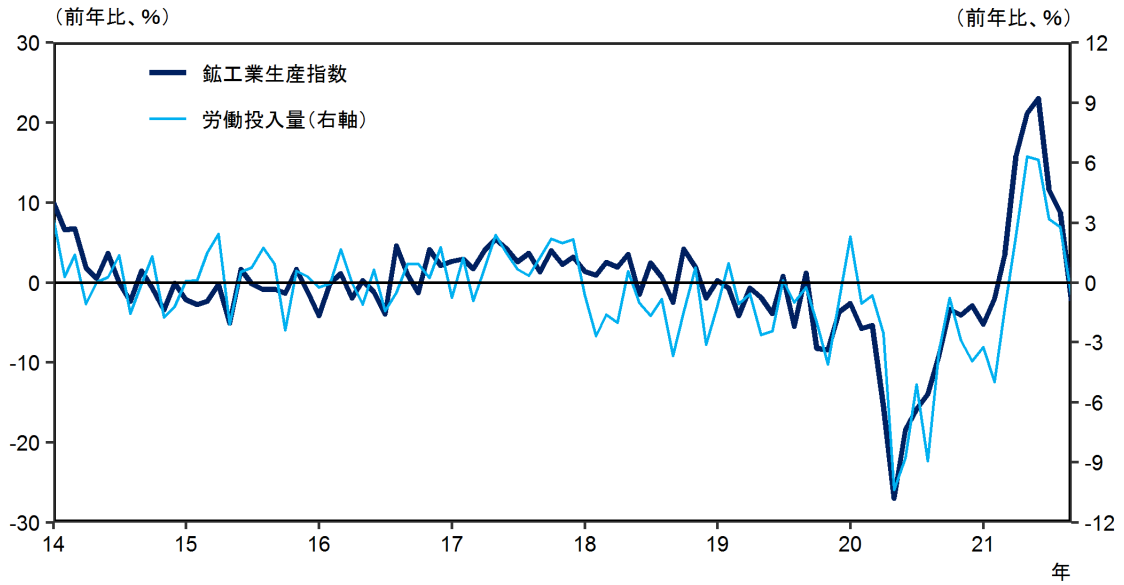
(b) 主要業種



(注) 滞在人口指数は、月中平均の値。

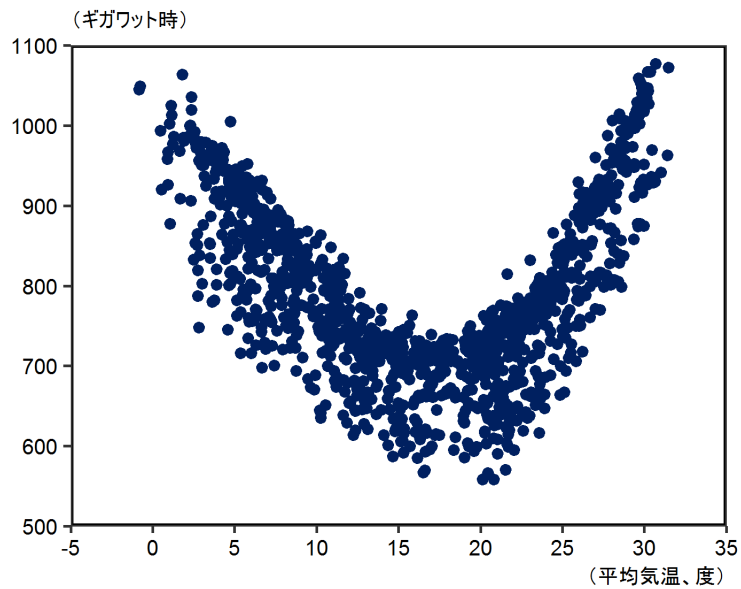
(出所) 経済産業省、Agoop

図2. 鉱工業生産指数と労働投入量




(注1) 労働投入量＝総実労働時間数（労働者一人あたり）×常用雇用者数。
 (注2) 鉱工業生産指数は鉱工業、労働投入量は製造業の値。
 (出所) 経済産業省、厚生労働省

図3. 気温と電力需要



(注) 東京電力エリア内における電力需要量と東京都内の平均気温の関係（2018年1月～2021年9月、日次データ）。
 (出所) 電力広域的運営推進機関、気象庁


図4. 鉱工業生産指数と電力指数




(注) 電力指数は、月中平均の値。
(出所) 経済産業省、電力広域的運営推進機関、気象庁

図5. 鉱工業生産指数と製造工業生産予測指数

(a) 鉱工業



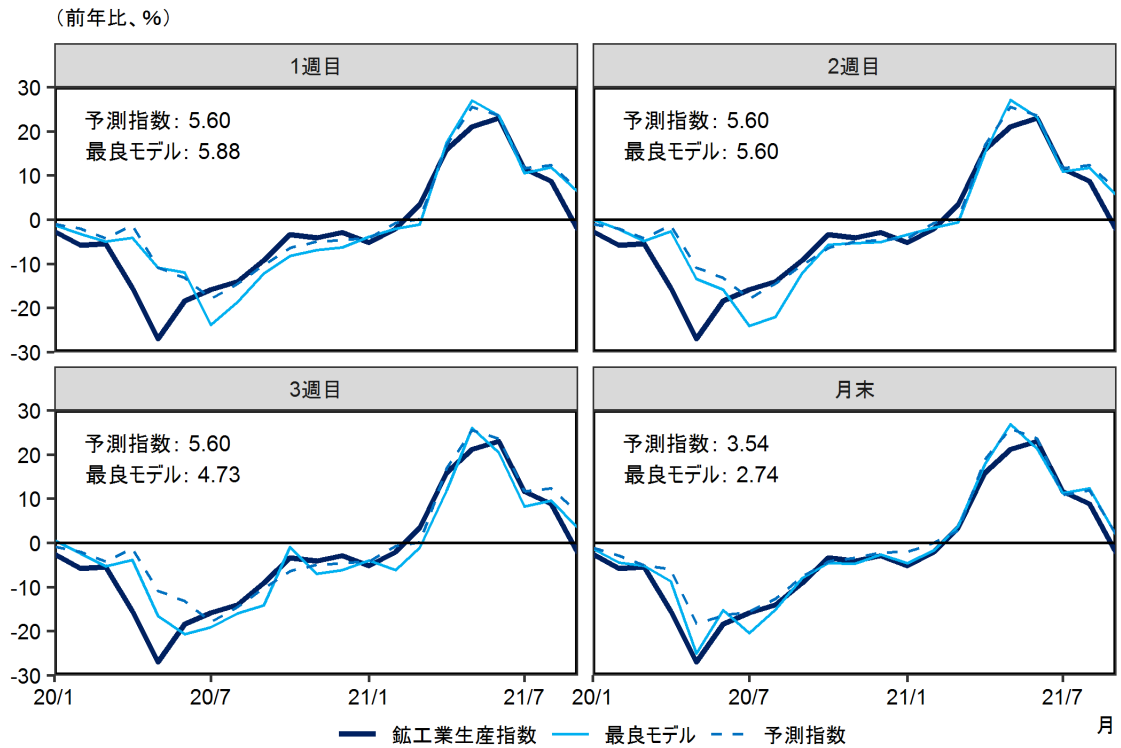
(b) 主要業種



(注) 予測指数はバイアス修正済みの値。

(出所) 経済産業省

図6. ナウキャストモデルの推計結果（鋳工業）




(注1) 予測指数は、1週目～3週目時点では翌月予測指数、月末時点では当月予測指数を表す。


(注2) 図中の数字は、RMSEの値。

図7. ナウキャストイングモデルの推計結果（主要業種）

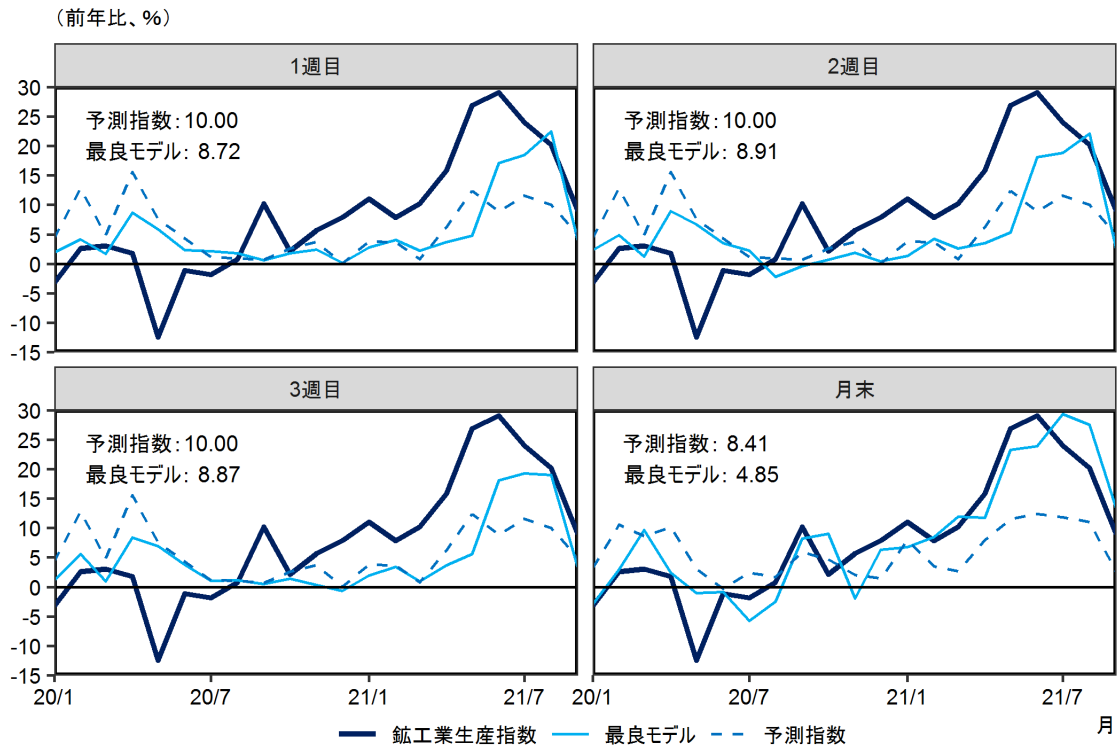
(a) 生産用機械工業



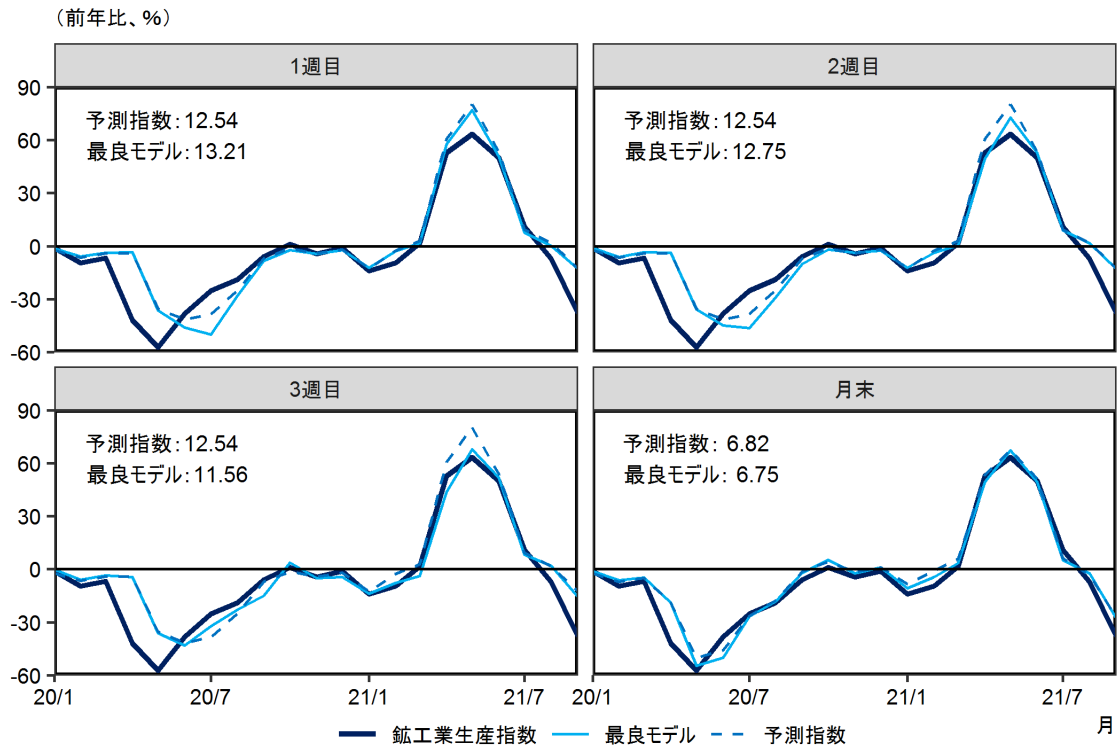
(b) 電気・情報通信機械工業



(c) 電子部品・デバイス工業

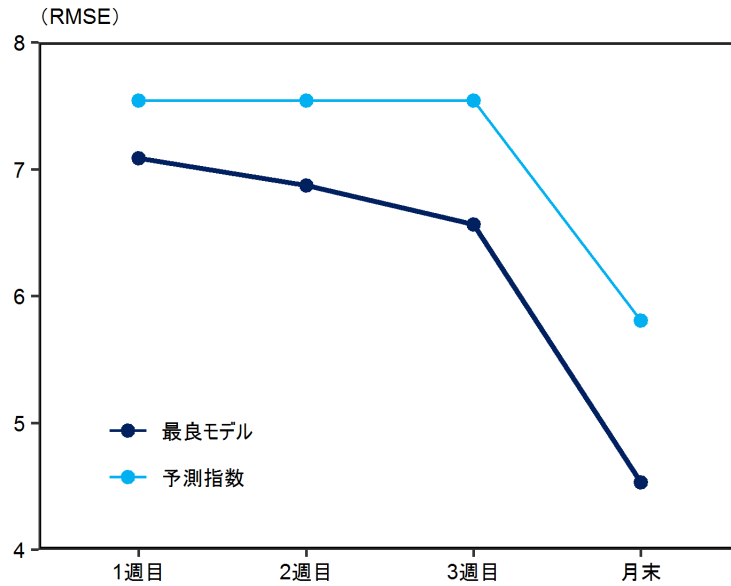


(d) 輸送機械工業



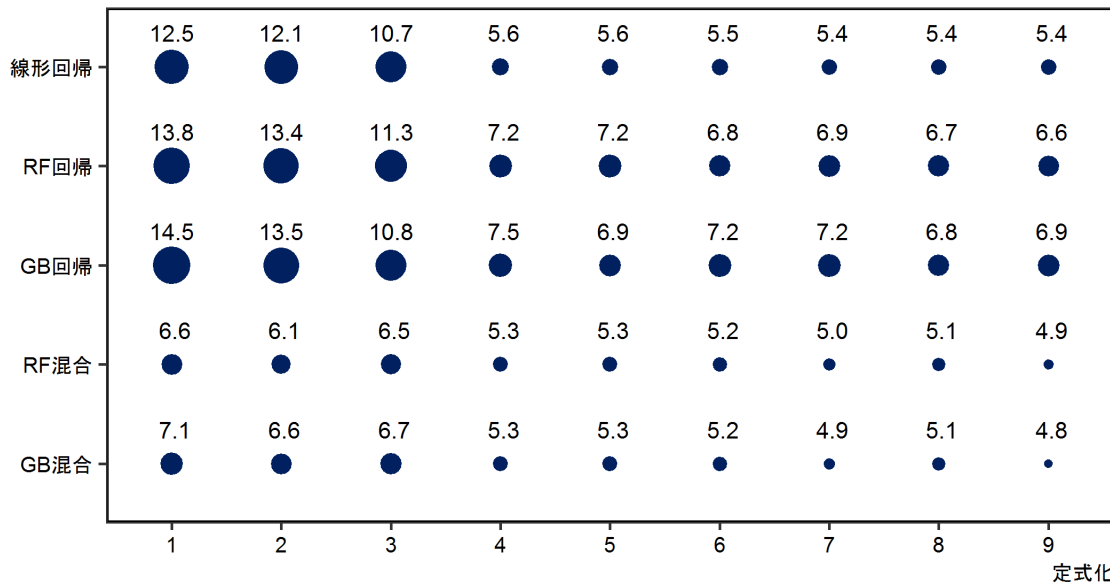
(注1) 予測指数は、1週目～3週目時点では翌月予測指数、月末時点では当月予測指数を表す。
 (注2) 図中の数字は、RMSEの値。

図8. ナウキャストモデルの推計結果（時点別・RMSE）




(注1) 予測指数は、1週目～3週目時点では翌月予測指数、月末時点では当月予測指数を表す。
 (注2) RMSEは、全業種の平均値。

図9. ナウキャストモデルの推計結果（モデル別・RMSE）



(注1) 「線形回帰」は線形回帰モデルを、「RF回帰」と「GB回帰」はそれぞれランダムフォレストと勾配ブースティングによる回帰モデルを、「RF混合」と「GB混合」はそれぞれランダムフォレストと勾配ブースティングを用いた混合モデルを示す。横軸の数字は表5における定式化の番号を示す。
 (注2) 図中の数字は、各モデル・定式化を用いた月末時点における予測値のRMSEの全業種平均値（バブルの大きさは、RMSEの大きさを示す）。


図 10. 予測指数の実現率と p




(注 1) 全業種、2つのモデル (ランダムフォレストと勾配ブースティング)、9つの定式化の推計結果。
(注 2) 一般化加法モデルによる近似曲線。

図 11. 鉱工業生産指数と交通量指数

(a) 鉱工業




(b) 主要業種




(出所) 経済産業省、社会基盤情報流通推進協議会

図 12. 鉱工業生産指数と交通量指数（OLS 推計結果）

(a) 交通量指数に係る係数と信頼区間



(b) 自由度調整済み決定係数

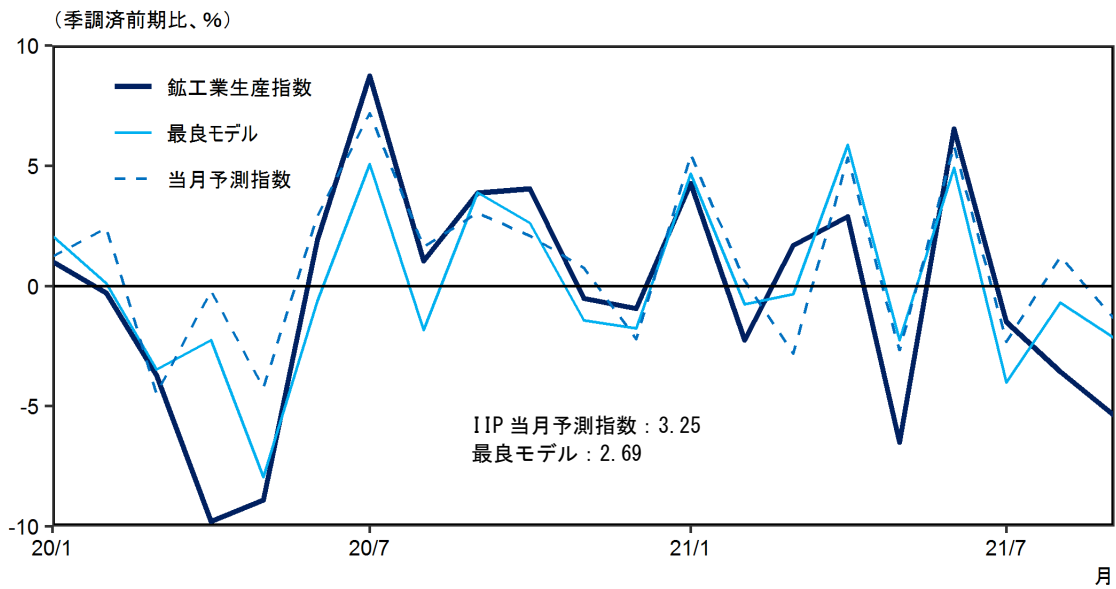


(注 1) スペック 1 は鉱工業生産指数を交通量指数のみで回帰したモデル、スペック 2 は鉱工業生産指数を滞在人口指数、電力指数、予測指数、交通量指数で回帰したモデル、スペック 3 は鉱工業生産指数を滞在人口指数、電力指数、予測指数で回帰したモデルを示す。

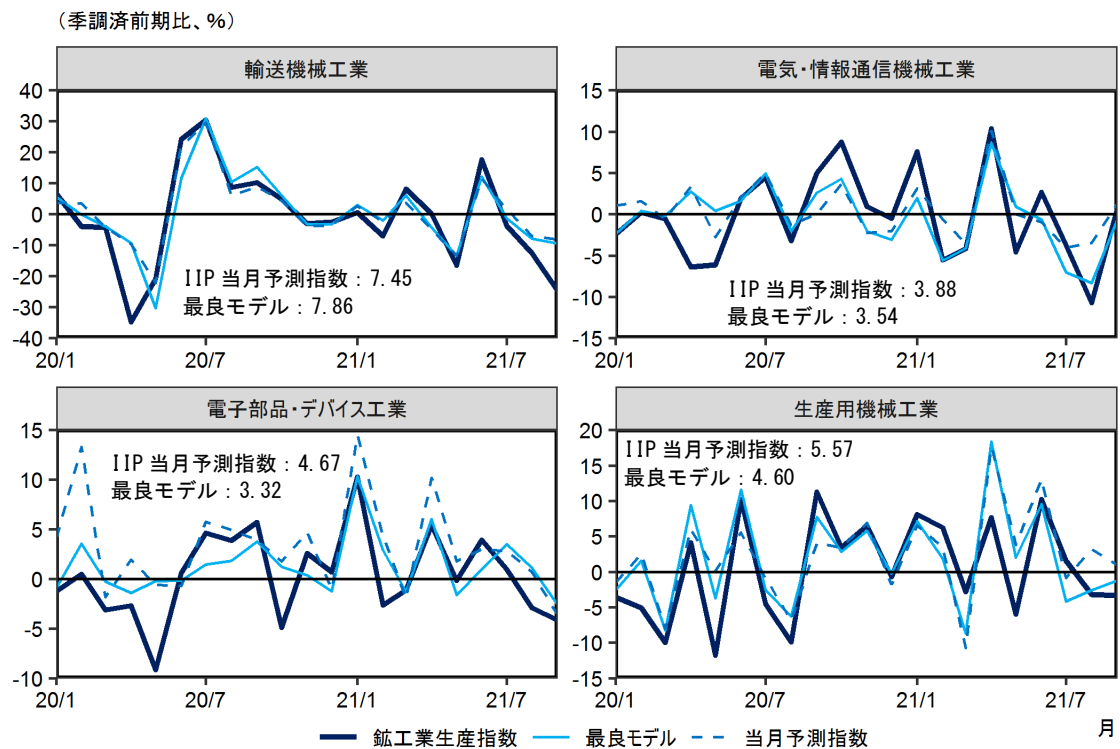
(注 2) エラーバンドは、95%信頼区間を示す。

参考図 1. ナウキャストモデルの推計結果（季節調整済み前期比ベース）

(a) 鉱工業



(b) 主要業種



(注) 図中の数字は RMSE の値。