

DP/21-1

経済財政分析ディスカッション・ペーパー

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—

川村 健史・久保 達郎・淀谷 恵実

Economic Research Bureau

CABINET OFFICE

内閣府政策統括官（経済財政分析担当）付

本稿は、政策統括官（経済財政分析担当）のスタッフ及び外部研究者による研究成果を取りまとめたもので、学界、研究機関等、関連する方々から幅広くコメントを頂くことを意図している。ただし、本稿の内容や意見は、執筆者個人に属するものである。

内容

1. はじめに	1
2. 使用データについて.....	2
3. 分析手法と結果	5
3-1. 分析手法	5
3-2. 分析結果	7
3-3. 他予測との比較.....	10
4. まとめ	12
参考文献	13
付表. トラック通行台数データの記述統計.....	14
付図. 予測手法別にみた予測結果.....	15

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—

川村 健史[†] 久保 達郎[‡] 淀谷 恵実[§]

【要旨】

我が国の生産活動の状況を把握できる代表的な指標に、鉱工業生産指数（IIP）がある。同指数は、月単位の生産活動水準を、基準年を100として指数化したもので、生産活動月の翌月末に公表される。また、主要企業を対象にした、生産活動月の翌月および翌々月の生産計画を基に、鉱工業生産予測指数として2か月先までの予測値も同時に公表される。

本稿は、鉱工業生産指数について、ビッグデータを用いて、予測指数よりも速報性がありかつ、予測指数単体よりもパフォーマンスがよい指数の算出を試みるものである。より具体的には、企業の生産活動と連動性があると考えられる商用車（トラック）カーナビデータ（通行台数データ）等を用い、複数の機械学習により、生産活動月の鉱工業生産指数の週次予測を試みた。

その結果、IIPと高い相関を持つ週次予測が可能である点を示すことができた。IIPは、生産月の翌月末に公表されるため、トラックカーナビデータ（通行台数データ）を用いて週次予測を行うことで、我が国の鉱工業生産の動向を、公式統計よりも2か月弱早く把握・ナウキャストできる可能性がある。

さらに、IIP実績値や予測指数を用いたVARモデルや、経済産業省によるSNSデータ等を用いたモデルによる予測よりも、予測精度の高いモデルを構築できた。もともと、本稿で用いたトラックカーナビデータ（通行台数データ）は、ナビタイムアプリを導入した車両データのみを対象とするほか、データ取得地点についても、全ての工業地域を網羅できていないなど、今後の予測精度向上に余地を残すものである点には留意が必要である。

* 本稿の作成において、株式会社サイバーエージェント AILab リサーチ・サイエンティスト森脇大輔氏、国際通貨基金エコノミスト小寺信也氏、内閣府の籠宮信雄氏、村山裕氏、堤雅彦氏、石井達也氏から有益なコメントを頂いた。ここに記して感謝を申し上げる。ただし、本稿に残された誤りはいうまでもなく筆者の責に帰すものである。また、本論文で示された見解は筆者の個人的なものであり、必ずしも内閣府の見解を示すものではない。

[†] 内閣府政策調査員

[‡] 内閣府政策調査員

[§] 内閣府上席政策調査員

1. はじめに

経済活動の現状を早期に把握したいというニーズは大きい。生産活動の場合、通常は鉱工業生産指数（以下、IIP (Indices of Industrial Production)）の動きをみる。IIPは、月単位で把握した生産水準を指数化したもので、生産活動月の翌月末に公表される。また、鉱工業生産予測指数として、主要企業を調査対象に、生産活動月の翌月および翌々月の生産計画を基にした2か月先までの予測値も同時に公表される。予測指数によって大まかな方向感を得ることは可能だが、あくまで計画値であるため、生産の動向把握には1か月のラグを伴うのが現状である。

こうしたラグを埋め、IIPの早期把握を試みる先行研究例も存在する。例えば、国土交通省（2001）は、製造企業は、特積¹トラックおよび国内航空貨物等で原料・半製品を輸送することから、IIPと特積トラック・国内航空貨物の間には相関関係が認められ、これら2つの指標は、IIPに3か月先行するという。なお、特積トラックデータおよび国内航空貨物データはともに活動月の2か月後に公表されるため、3か月の先行性を踏まえると、これらデータを用いた予測は1か月分である（例えば、1月のデータ公表が3月下旬、IIPに3か月先行するため、1月データにより4月分の予測が可能）。

他例として、経済産業省・野村証券株式会社・金融工学研究センター（2017）は、TwitterやブログなどのSNSツイートのうち、IIPと相関の高い景気・仕事関連の約50のキーワードをもとにAIが抽出したツイートの件数に加え、鉱工業生産予測指数や為替レート等をインプットデータとし、機械学習の手法を用いて生産月の週次予測を行っている²。また、王・須合・高橋・松村（2021）は、労働投入量と生産活動の相関が強い業種（輸送機械、生産用機械、電気・情報通信機械）について、工場として特定されたメッシュ内の滞在人口（携帯電話の位置情報データを基に取得）を集計した指数によりIIPナウキャストが有効であることを示している。

本稿では、国土交通省（2001）で示された特積トラックデータとIIPの相関に着目し、週次の動向把握が可能な商用車（トラック）のカーナビデータ等を用いてIIPの週次予測を試みる。なお、予測手法については、経済産業省・野村証券株式会社・金融工学研究センター（2017）に倣い、カーナビデータとIIPのセットを学習データとする機械学習の手法を利用した。具体的には、線形回帰のほか、正則化最小二乗法といった機械学習の手法を用いた試算を行い、精度の比較を行っている。

本稿の構成は以下の通りである。2章で使用するデータについて詳述したうえで、3章は分析手法および結果、他予測値との比較を紹介する。4章はまとめである。

¹ 特積とは、特別積み合わせ貨物運送の略称。不特定多数の荷主企業の貨物を1台の車両にまとめて積載、全国規模で輸送する形態を指す。

² 野村証券 金融工学研究センター (http://qr.nomura.co.jp/quant/sns_ai/#jump4) にて公表。2021年5月末をもって更新終了。

2. 使用データについて

本稿では、株式会社ナビタイムジャパン（以下、ナビタイム）が提供する「携帯カーナビプロブデータ」を用いる。同データは、ナビタイムによる自動車向け携帯カーナビゲーションアプリ「トラックカーナビ」「カーナビタイム」「ドライブサポーター」等のユーザー車両を対象に、GPSにより取得された走行実績である。データの切り口により、走行距離、走行速度、滞在時間、（一定区間の）車両通行台数等の情報を得られるが、本稿では、後述のエリア内区間における週次および月次の車両通行台数を用いる³。また、アプリを利用する全車両の動向把握が可能だが、本稿では、IIPとの相関が高いと考えられる、商用車に限定したデータ（以下、トラック通行台数データ）を用いる⁴。

エリア（メッシュ）は、生産活動が活発に行われている場所を選定している。今回の実践では、関東全域および自動車・同部品関連企業、電子部品関連企業の工場が集積する岩手県、山形県、宮城県、石川県、山梨県、愛知県、静岡県、三重県、鳥取県、熊本県、大分県、長崎県のうち、工場や倉庫が複数立地、ないし、特定の主要製造企業の工場が立地している10km×10kmの160エリアである⁵。選定は、株式会社NTTタウンページの「タウンページ統計情報（2020年2月時点）」を用いて、工場および倉庫の住所データを取得し、東京大学空間情報科学研究センターが提供する「CSVアドレスマッチングサービス」を用いて、緯度経度データへ変換することで行った。

なお、一定エリア内区間のトラック通行台数データを用いるにあたり、アプリ利用登録者の増加（減少）によりトレンドが生じる影響を除くため、観測期間中のマクロのトラック台数は一定との仮定の下⁶、観測区間⁷あたり全トラック車両通行台数を観測区間あたりトラックカーナビユーザー数で除した、観測区間・1ユーザーあたり通過回数を使用している。また、一般道路と高速道路の2種類が利用可能であるが、一般道路、高速道路およびその合計について、観測区間・1ユーザーあたり通過回数の1か月間合計値と、同月のIIPの前年比および相関を比較すると、高速道路とIIPとの相関が最も高いため、本稿では高速道路通過データを用いている（図1）。

³ 他のデータを含めた追加的な分析は今後の課題である。

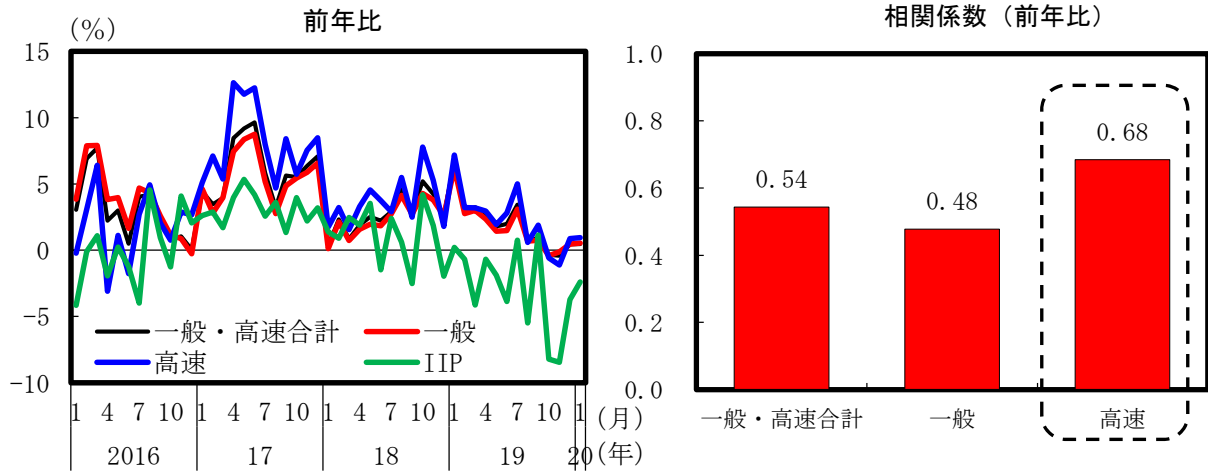
⁴ 具体的には、商用車向けカーナビゲーションアプリ「トラックカーナビ」およびその他カーナビゲーションアプリ使用者のうち、車種を商用車として登録しているデータ。本稿で用いたデータの詳細は、付表を参照のこと。

⁵ より具体的には、一般社団法人 日本自動車工業会「日本の自動車工場分布図」の都道府県別工場数等を参考に抽出。

⁶ この仮定は、例えば、景気後退局面において総トラック台数は減少しているが、1台当たりの稼働率が高まるような場合には、局面を適切に捉えられない可能性を排除出来ない点に留意が必要である。ただし、本推計期間は、概ね景気拡張局面であったことから、この問題は限定的と考えられる。

⁷ 観測区間は、交差点等の道路網表現上の結節点と次の結節点との区間をいう。本項では、IIPとの相関が高い高速道路データを用いており、高速道路上では、インターチェンジやジャンクション、サービスエリア/パーキングエリアなどの分岐部等が結節点となる。本稿で用いたデータは、選択したエリア内の計11,287区間を対象としている。

図1 1ユーザーあたり通過回数（選定した全エリア）



IIP 予測⁸にあたっては、説明変数として、トラック通行台数データ（1ユーザーあたり通過回数、高速、観測区間毎のデータ、以下同じ）⁹のほか、鉱工業予測指数、特積トラックデータ、国内航空貨物、災害ダミーを用いて検討を行った。説明変数のうち、トラック通行台数データについては日曜日から土曜日までの週次データとした。また、鉱工業生産予測指数は、1週目～3週目については2か月前見込値を用い、月末は1か月前見込値を用いた¹⁰。特積トラックデータおよび国内航空貨物については、国土交通省（2001）に倣い、生産月の3か月前値を用いた。また、災害ダミーは、政府の激甚災害指定日¹¹を含む月を「1」、それ以外の月を「0」とする。なお、目的変数および説明変数は、いずれも前年比を用いている（図2）。

また、予測期間は2018年1月～2020年1月までとしている。同予測期間に対する機械学習の期間は、2018年1月予測については、2016年1月～2017年11月までをインプットデータとし、2018年2月予測以降は、インプットデータを都度1か月分追加（学習期間が1か月ずつ増加）している。

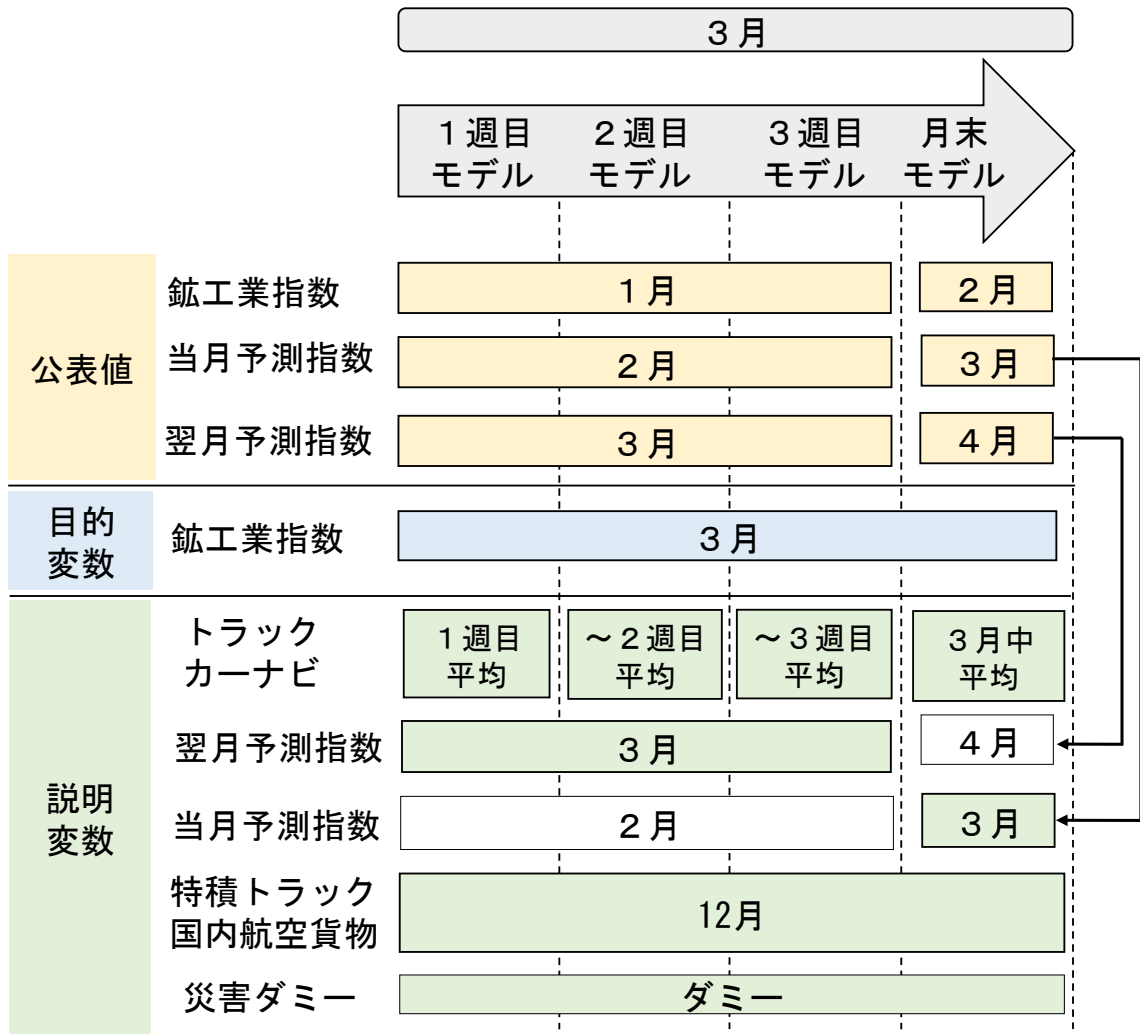
⁸ 本稿は、過去の実績値を用いて IIP 推計を行っているため、IIP 確報値を用いている（確報公表時点で速報値は上書き公表されるため）が、実際の運用としては、IIP 速報値の予測に用いることを想定している。なお、IIP の速・確報値には、小数点第 1 位を超えるような大きな差はない。

⁹ 本稿で用いたトラック通行台数データに関する記述統計は、付図 1 を参照。

¹⁰ 生産月の翌月末に公表される IIP と同時に、生産月の翌月分（1か月前見込値）および翌々月分（2か月前見込値）の予測指数が公表されるため。n 月 1 週目～3 週目 IIP（予測）= F（n 月 1 週目～3 週目トラック通行データ、n 月予測調査（2か月前予測））、n 月末 IIP（予測）= F（n 月トラック通行データ、n 月予測調査（1か月前予測））。

¹¹ <http://www.bousai.go.jp/taisaku/gekijinhukko/list.html>。

図2 使用するデータの時点イメージ（事例：生産月が3月の場合）と記述統計



(注) 鉱工業指数の週次予測には、上記説明変数のうち、緑色のデータを使用している。

3. 分析手法と結果

3-1. 分析手法

トラック通行台数データを用いた IIP の前年比予測は、生産月における週次および月次で行った¹²。具体的な予測手法は、従来からある最小二乗法による線形回帰（一般的な重回帰分析）、正則化最小二乗法として Ridge、Lasso、Elastic net である。

正則化最小二乗法とは、線形回帰に正則化項を用いて、説明変数の係数（重み）を小さくするペナルティをつけることで、過学習を防ぐ特徴をもつ¹³。Ridge は、学習した重みの二乗の合計（L2 正則化項）を用いることで係数の値を縮小する。Lasso は学習した重みの合計（L1 正則化項）を用いて係数を縮小することに加え、スパース性（回帰係数の多くを 0 と推定する性質）¹⁴を持つため、0 と推定された回帰係数に対応する変数を重要でないと考えることで変数選択も同時に行われる。Elastic net は L1 正則化項、L2 正則化項ともに用いた Ridge と Lasso の折衷案であり、Lasso の説明変数の数の制約などに対応したものである。なお、正則化項の強さを決定するパラメータ λ は、統計解析ソフト「R」を用いて、クロスバリデーション¹⁵により予測誤差が最小となるように決定した。

¹² IIP 前年比予測（確報値ベース）の予測に用いたトラック通行台数データは、脚注 7 に記載した観測区間毎のデータ。

¹³ 「重み」とは、学習用に用いる訓練データで得られた説明変数の係数（Weight）を指す。モデルの係数（重み）の絶対値が大きくなると、訓練データのモデルへの適合度が過度に高くなり、テストデータのモデルの当てはまりが悪くなる（過学習）ため、過学習を避けるために正則化（Ridge、Lasso、Elastic net の各式を最小化する w (weight) を求める）を行う。

¹⁴ 係数が 2 つの場合、ペナルティ領域が L1 正則化項はひし形となり、誤差項が最小となる最適解が軸上となるため、特定の係数が 0 となる。

¹⁵ クロスバリデーション（交差検証）とは、機械学習を行う際に最適なアルゴリズムやパラメータを見極める評価手法。予測モデルに用いるデータを、学習データとテストデータ（評価用データ）に複数パターン分割・検証し、精度の平均を取る。Fold 数は 7 とした。 λ の値（2020/1 月）はそれぞれ、Ridge（1 週目：28.5、2 週目：41.3、3 週目：291.3、月末：727.2）、Lasso（1 週目：0.3、2 週目：0.3、3 週目：0.3、月末：0.1）、Elastic net（1 週目：0.3、2 週目：0.4、3 週目：0.3、月末：0.3）。

$$Ridge = \sum_{i=1}^n (y^i - \hat{y}^i)^2 + \lambda \sum_{j=1}^m w_j^2$$

(L 2 正則化項)

$$Lasso = \sum_{i=1}^n (y^i - \hat{y}^i)^2 + \lambda \sum_{j=1}^m |w_j|$$

(L 1 正則化項)

$$Elastic\ net = \sum_{i=1}^n (y^i - \hat{y}^i)^2 + \lambda_1 \sum_{j=1}^m w_j^2 + \lambda_2 \sum_{j=1}^m |w_j|$$

y : 実測値

\hat{y} : モデルによる予測値

λ : 正則化の強さを決定するパラメーター

w : 係数

また、今回の比較対象には、ベンチマークとしての伝統的な時系列モデルの一つである多変量自己回帰 (VAR) モデルによる予測値と、経済産業省が公表している SNS データモデルによる予測値を用いた。VAR モデルは、自己相関の高い時系列データに適しており、以下の式により表される。

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \varepsilon_t, \varepsilon_t \sim W.N.(\Sigma)$$

ϕ : 自己回帰係数行列

p : 次数

ε : 誤差項

3-2. 分析結果

前項で紹介した各分析手法を用いた予測結果について、IIP との相関係数および IIP との誤差（RMSE：二乗平均平方根誤差、MAPE：平均絶対誤差率）を示す¹⁶。これを見ると、MAPE については、ElasticNet と殆ど変わらないが、相関係数は、相対的に Lasso が最も高く、RMSE については Lasso が一番小さくなっており、Lasso が相対的に最も当てはまりが良い。また、予測指数単体よりも相関係数、RMSE、MAPE とともにパフォーマンスの良い結果となっている（図 3）。

図 3 予測手法別にみた相関係数・RMSE・MAPE

相関係数

	1週目	2週目	3週目	月次
Lasso	0.936	0.944	0.949	0.959
Ridge	0.598	0.511	0.605	0.786
ElasticNet	0.939	0.938	0.919	0.956
LmG	-0.177	0.176	-0.157	0.073
予測指数（翌月）	0.903			—
予測指数（当月）	—			0.951

RMSE

	1週目	2週目	3週目	月次
Lasso	1.496	1.439	1.363	1.170
Ridge	3.333	3.504	3.112	2.610
ElasticNet	1.528	1.470	1.463	1.174
重回帰	23.146	28.675	15.351	22.682
予測指数（翌月）	3.175			—
予測指数（当月）	—			2.341

MAPE

	1週目	2週目	3週目	月次
Lasso	0.773	0.775	0.798	0.688
Ridge	1.307	1.305	1.210	1.147
ElasticNet	0.815	0.823	0.786	0.686
重回帰	11.390	12.585	5.487	6.389
予測指数（翌月）	2.717			—
予測指数（当月）	—			1.869

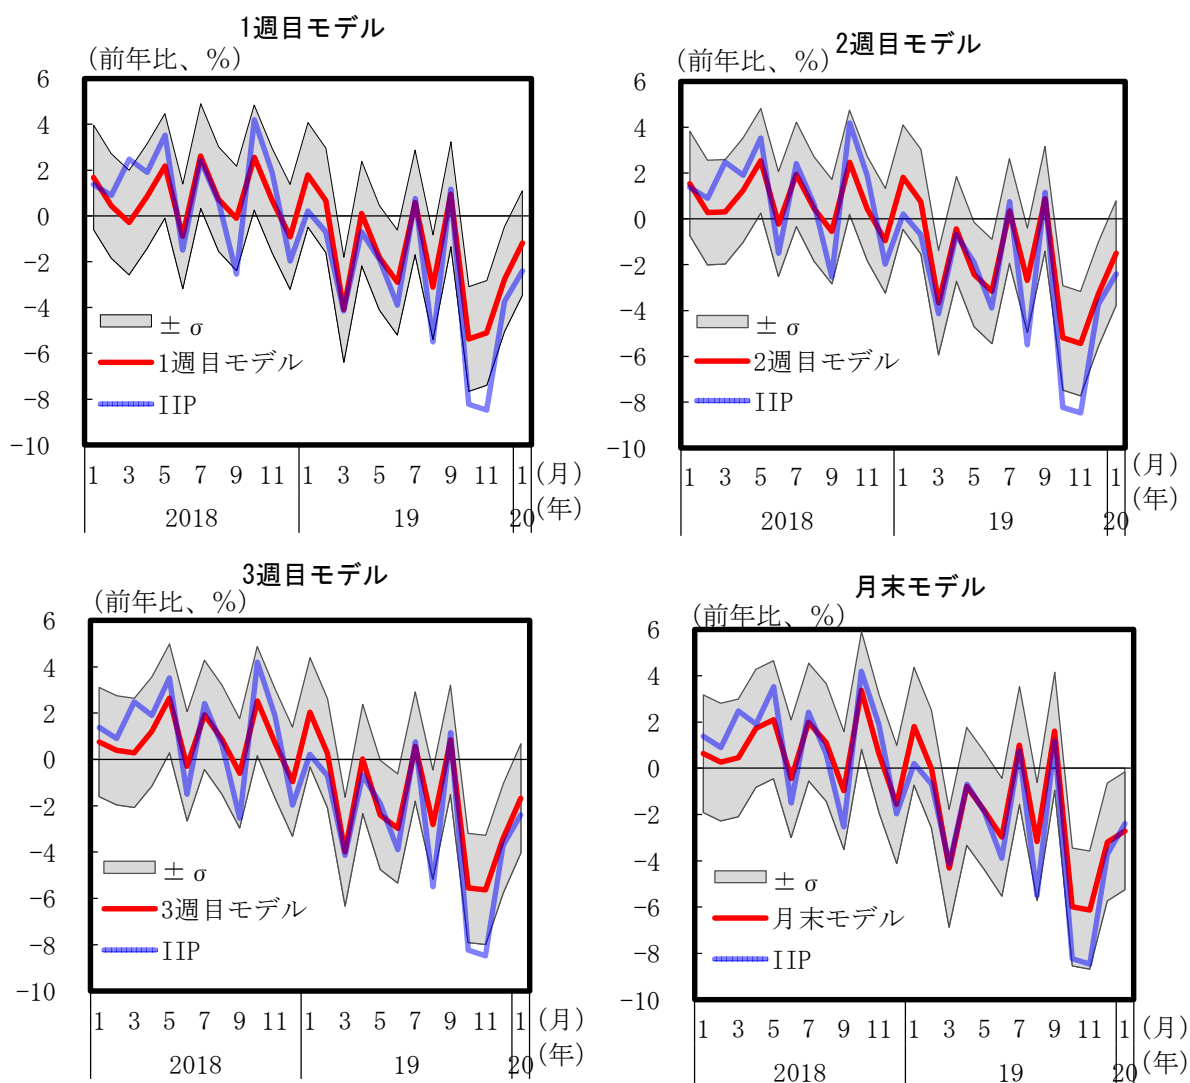
¹⁶ 予測期間は、2018年1月～2020年1月。予測開始時（2018年1月）のデータ学習期間は、2016年1月～2017年11月（2018年1月時点で公表されているIIP実績が2017年11月分までのため）。2018年2月以降の予測にあたっては、データ学習期間を1か月ずつ追加。

ここでは予測精度が相対的に最も高かった手法（Lasso）の結果を紹介する。

トラック通行台数データ、特積みトラックデータ、国内航空貨物、鉱工業生産予測指数および災害ダミーを用いた予測値（前年比）について、IIPとの相関係数は0.9と非常に高い相関が確認できた。また、データ蓄積に伴い、週を追うごとに相関が高くなり、IIPとの誤差についても縮小傾向にある点を確認できる（前掲図3）。

また、IIP実績値と週次モデル別の予測値の推移をみると、何れの週のモデル（月末は月末モデル）についても、概ね $\pm\sigma$ に収まっている。特に、月末モデルは、全ての月で $\pm\sigma$ に収まっている（図4）。

図4 週次モデル別予測値の推移と予測誤差



なお、説明変数としてトラック通行台数のみを用いた場合、予測指数等他の変数を加えた本稿検討モデルよりも IIP 実績との相関は低く、予測誤差が大きい結果となる（前掲図 3、図 5）。前述したように、予測指数単体と比べると、トラック通行台数や予測指数等を用いた本稿モデルの方が、説明力が高いことを踏まえると、トラック通行台数は、予測指数の予測誤差を補正する効果があると考えられる。

図 5 予測手法別にみた相関係数・RMSE（トラック通行台数データのみ）

相関係数

	1週目	2週目	3週目	月次
Lasso	0.368	0.579	0.654	0.548
Ridge	0.540	0.498	0.599	0.787
ElasticNet	0.245	0.450	0.580	0.675
LmG	-0.242	0.169	-0.055	-0.037
予測指数（翌月）	0.903			—
予測指数（当月）	—			0.951

RMSE

	1週目	2週目	3週目	月次
Lasso	3.771	3.532	2.917	3.091
Ridge	3.437	3.532	3.141	2.615
ElasticNet	3.726	3.624	3.092	2.851
重回帰	28.917	23.063	30.377	209.357
予測指数（翌月）	3.175			—
予測指数（当月）	—			2.341

MAPE

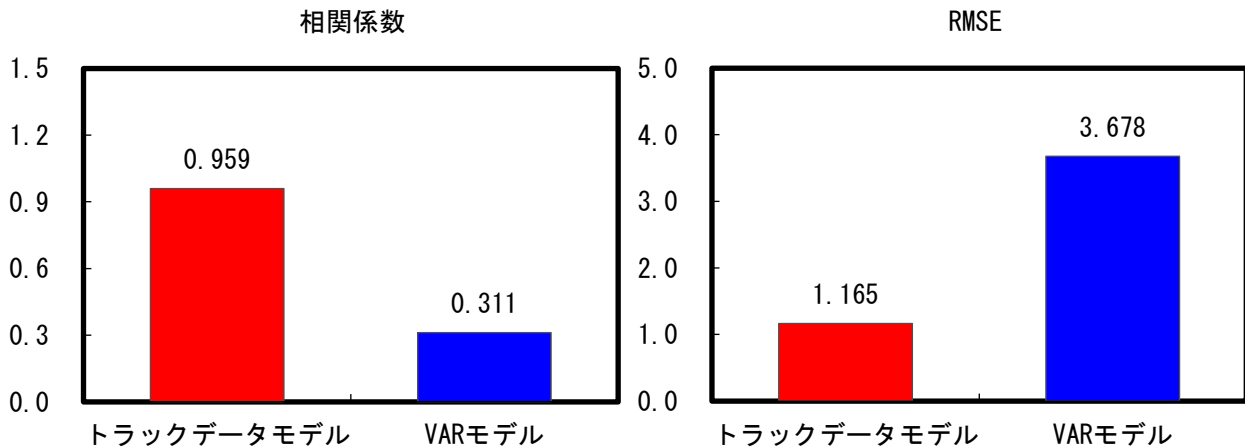
	1週目	2週目	3週目	月次
Lasso	1.348	1.258	1.075	1.138
Ridge	1.313	1.310	1.213	1.150
ElasticNet	1.275	1.359	1.113	1.193
重回帰	12.141	11.610	14.701	185.441
予測指数（翌月）	2.717			—
予測指数（当月）	—			1.869

3-3. 他予測との比較

本稿で試みたトラック通行台数データを用いた予測（以下、トラックデータモデル）について、①IIP・特積みトラックデータ・国内航空貨物・鉱工業生産予測指数・災害ダミーを用いた VAR（多変量自己回帰）モデル(最大ラグ数1)および、②経済産業省が公表している SNS データモデルと比較することで、その精度を検証する。

まず、トラックデータモデルと①IIP 等を用いた VAR モデルを比較する。VAR モデルによる予測値は、IIP との相関係数が 0.3 程度と、トラックデータモデルの相関係数よりも小さく、予測誤差 (RMSE) は VAR モデルの方がトラックデータモデルよりも大きい値となっている (図 6)。

図 6 トラックデータモデルと VAR モデルの比較 (2018 年 1 月～2020 年 1 月、月末モデル)




また、両モデルの予測誤差が、統計的に有意な差であり、トラックデータモデルが VAR モデルよりも予想精度が高いといえるかを確認するため、Diebold-Mariano 検定¹⁷を行った。「VAR モデルによる予測と、トラックデータモデルによる予測の予測力が等しい」ことを帰無仮説とした Diebold-Mariano 検定を行ったところ、いずれのタイミングにおいても 1%水準で有意となり、両モデルの予測精度に統計的に有意な差があることが確認できた (図 7)。トラックデータモデルの RMSE が VAR モデルのそれよりも小さいことから、トラックデータモデルの方が予測精度は高いといえる¹⁸。

¹⁷ 二つの予測値の予測力を比較する際に用いられる検定。それぞれの予測誤差の差分を計算し、その期待値が 0 であるとき、二つの予測値の予測力が同じであると考え。今回、予測誤差には、二乗誤差を用いた。


¹⁸ R パッケージでは、DM 検定において、「二つの予測値の予測力が同じである」とする帰無仮説が棄却された場合 (二つのモデルの予測力に有意に差がある場合)、どちらの予測精度が高いかを予め設定する仕様となっている。本稿では、トラック通行台数データモデルの方が精度が高いという設定の上で DM 検定を実施し、棄却されたことから、DM 検定上でもトラック通行台数モデルの方が AR モデルよりも予測精度が高いことが示されている。

図7 トラックデータモデルと VAR モデルの Diebold-Mariano 検定 (2018 年 1 月～2020 年 1 月)



次に、トラックデータモデルと経済産業省が公表している②SNS データモデル¹⁹との比較を行う。SNS データモデルによる予測値は、IIP との相関係数が 0.8 程度と高いが、トラックデータモデルによる予測値と IIP との相関は 0.9 台とさらに高くなっている。また、予測誤差 (RMSE) については、SNS データモデルの方がトラックデータモデルよりも大きい値となっている (図 8)。


図8 トラックデータモデルと SNS データモデルの比較 (2018 年 1 月～2020 年 1 月、月末モデル)



¹⁹ 経済産業省が公表している鉱工業生産指数の季節指数を用いて、季節調整値を原数値に変換し、前年比を計算。

また、予測誤差について、VAR モデルと同様に、「SNS データモデルによる予測と、トラック通行台数データモデルによる予測の予測力が等しい」ことを帰無仮説とした Diebold-Mariano 検定を行ったところ、1、2 週目が 5% 有意、3 週目以降が 1% 有意となった（図 9）。このことから、両者の予測力には統計的に有意な差があることが認められ、トラックデータモデルの RMSE が SNS データモデルのそれよりも小さいことから、トラックデータモデルの予測は、SNS データモデルの予測よりも精度が高いといえる²⁰。

図 9 トラックデータモデルと SNS データモデルの Diebold-Mariano 検定（2018 年 1 月～2020 年 1 月）



4. まとめ

本稿では、トラック通行台数データを用いて、生産月における IIP の週次予測を試みた。その結果、IIP と高い相関を持つ週次予測が可能である点を示すことができた。IIP は、生産月の翌月末に公表されるため、トラック通行台数データを用いて週次予測を行うことで、我が国の鉱工業生産の動向を、公式統計よりも 2 か月弱早く把握・ナウキャストできる可能性がある。

さらに、IIP 実績値・予測指数等による VAR モデルや、経済産業省による SNS データ等を用いたモデルによる予測よりも、予測精度の高いモデルを構築できた。もっとも、本稿で用いたトラック通行台数データは、ナビタイムアプリを導入した車両データのみを対象とするほか、データ取得地点についても、全ての工業地域を網羅できていないなど、今後の予測精度向上に余地を残すものである点には留意が必要である。

²⁰ 脚注 12 と同様の設定を行っている。

参考文献

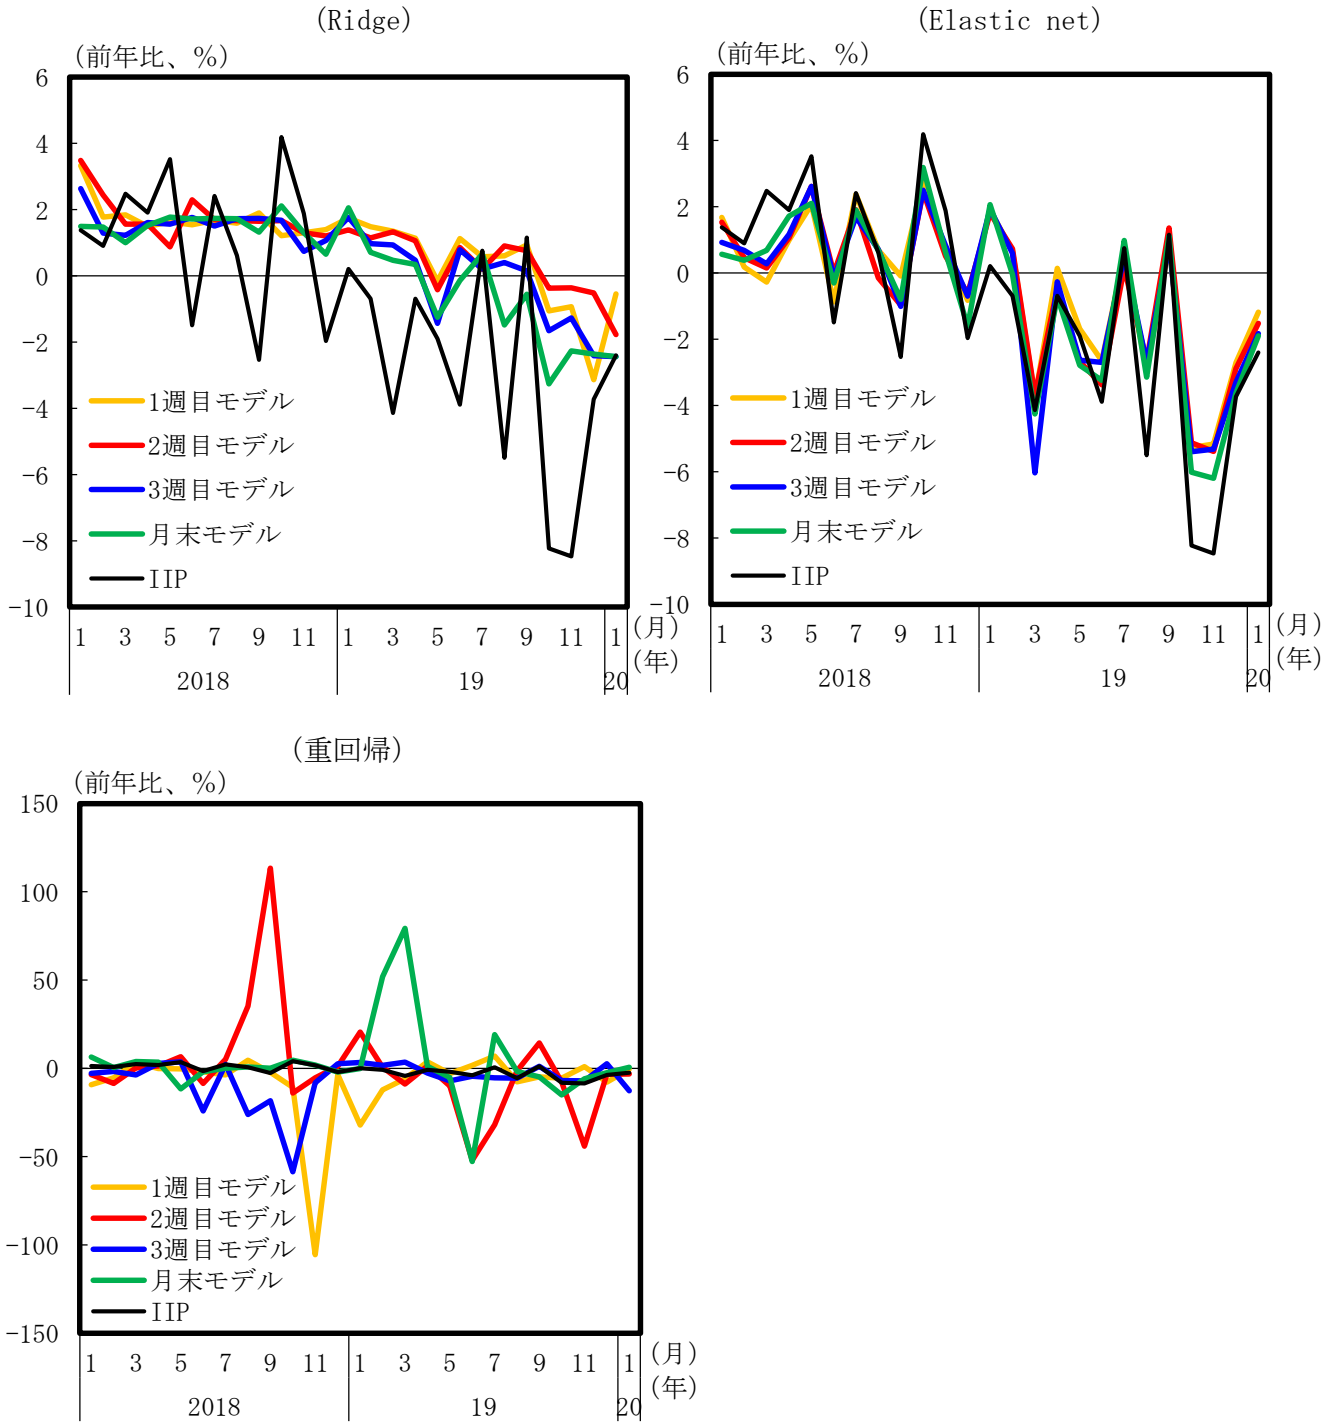
- 国土交通省（2001）「今月のトピックス～景気に対して先行的に動く交通関連統計～」国土交通月例経済 平成 13 年 7 月号
- 饗場行洋・山本裕樹（2018）「データサイエンスと新しい金融工学」財界観測 2018 年春号
- 野村証券株式会社金融工学研究センター（2017）「SNS×AI 鉱工業生産予測指数のご紹介」
- 王悠介・須合智広・高橋浩史・松村浩平（2021）「位置情報データによる経済活動のナウキャストイング」日本銀行ワーキングペーパーシリーズ 21-J-2

付表. トラック通行台数データの記述統計

	原数値	前年比
平均	1.86	3.90
標準誤差	0.02	0.49
中央値 (メジアン)	1.88	3.20
標準偏差	0.12	3.43
分散	0.02	11.75
尖度	-1.24	0.52
歪度	-0.15	0.63
範囲	0.43	15.75
最小	1.63	-3.11
最大	2.06	12.64
合計	113.23	191.33
データの個数	61	49

付図. 予測手法別にみた予測結果

本論中で検討した Lasso 以外の手法を用いた予測結果を示す。



以上