

# ナウキャストモデリングモデルによる実質GDPの早期把握

経済調査部 久後 翔太郎

## 要 約

近年、Hayashi and Tachi (2022) や浦沢 (2021) によるGDPナウキャストモデリングモデルの予測値の公表が始まるなど、実質GDPを早期に把握する手段として、ナウキャストモデリングモデルが注目されている。本稿では、こうした運用実績の高い手法や機械学習によって得た複数の予測系列から精度の高いものを抽出し、それらにウェイト付けを行う手法によってGDPナウキャストモデリングモデルを構築した。更に、一部のマクロ経済統計については、オルタナティブデータ・業界統計などの速報性の高いデータによって得た推計値をモデルに取り込むことで、より早期に経済活動の変動を捉えることを試みた。

こうして構築されたモデルによる実質GDP予測の精度は市場予測の精度を上回り、同モデルは実質GDPの早期把握に有効な手段であることが示唆された。ただし、コロナショック以降はGDPナウキャストモデリングモデルによる予測値と実質GDP成長率の実績値の乖離が大きくなる傾向が見られるなど課題も残る。

## 目 次

はじめに

1章 GDPナウキャストモデリングモデルの構築

2章 パフォーマンスの検証と課題の精査

おわりに

## はじめに

景気を早期に把握することは、財政・金融政策を担う政策当局者にとってはもちろん、市場関係者、企業経営者など幅広い主体にとって重要である。景気を表す最も代表的な統計である実質GDPは、一国全体の経済活動を網羅的に反映しているという他の統計にはない特徴を有している一方で、速報性に欠けるという欠点がある。そこで、より速報性がある、または更新頻度の高い統計を用いて実質GDPを早期に把握する取り組みが進められてきた。こうした取り組みは“ナウキャスト”と呼ばれる。日本においても Hayashi and Tachi (2022) や浦沢 (2021) のナウキャストモデルによる実質GDP成長率の予測値が公表されており、景気の早期把握の手段としてナウキャストの注目度合いは高まっている。

本稿では、GDPナウキャストモデルを独自に構築し、その予測精度を市場予測と比較することで、同モデルの有効性を検証した。さらに、経済予測の分野でとりわけ注目度が高まっている以下の2つの要素を取り込むことで、GDPナウキャストモデルの精度の向上を図った。

1つは、オルタナティブデータの取り込みである。近年、JCB消費NOW<sup>1</sup>やSRI一橋大学消費者購買指数<sup>2</sup>など高頻度データへのアクセスが容易となり、GDPナウキャストの分野においても中澤 (2022) や浦沢 (2022) でオルタナティブデータを活用したモデルが構築されている。本稿でもこれらの先行研究を参考に、オル

タナティブデータをGDPナウキャストモデルに取り込むことで予測精度の向上を試みる。

もう1つは、機械学習の活用だ。機械学習による経済予測は発展が著しい分野の一つであり、GDPナウキャストモデルにおいても機械学習を活用した研究が蓄積されている。本稿では、伝統的な計量経済学のモデルに加え、機械学習を用いた手法を取り入れることで、1つのモデルに依存することなく、幅広いモデルから最適な予測値を抽出する。

本稿の手法によるGDPナウキャストモデルは、市場予測と比較しても予測精度が高く、景気の早期把握に有効である可能性が示唆された。また、週次のデータを用いてモデルの予測値が修正される過程を確認すると、概ねGDPが発表される時点の1.5～2カ月前には予測値が安定する傾向が見られた。ただし、緊急事態宣言の解除など、ある程度予見された経済活動の急変動が発生した際には、当該四半期の期初におけるモデル予測の精度は低くなることには留意が必要だ。

以下では、1章で本稿のGDPナウキャストモデルについて概説し、2章でその予測精度の評価及び課題の精査を行う。

1) クレジットカードの利用情報を基に作成される消費指数であり、半月ごとにデータが提供されている。

2) 日本全国約6,000店舗のPOSデータを基に算出される週次の支出指数。

# 1章 GDPナウキャストモデルの構築

本稿でのGDPナウキャストモデルの構築は図表1のプロセスに従った。

はじめに、オルタナティブデータや業界統計といった速報性の高いデータを使って、一部のマクロ経済統計の補外推計を行う。これにより、公表されている期間よりも1~2カ月程度先までの推計値を取得することが可能となる。

次に、図表2に掲載されているハードデータとソフトデータの変数について、あらかじめ設定した多数の組み合わせごとに、①ダイナミックファクター、②合成基準化変化率による共通変動成分、③個別系列、という3種類の入力データを用意する。なお、モデルに採用する変数の組み合わせの例が図表2の組み合わせ1から組み合わせ3である。

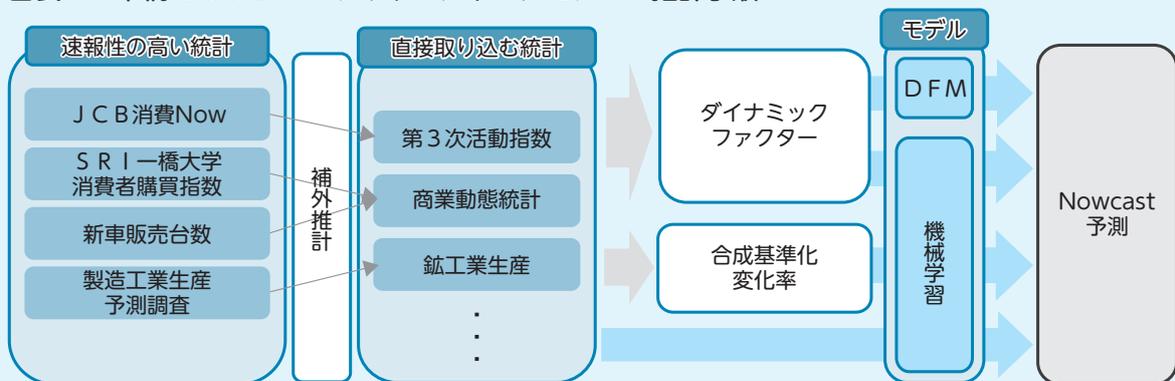
入力データをモデルに取り込むことで、モデルごとに予測系列を算出する。モデルはダイナミックファクターモデル(DFM)と機械学習モデルの2種類がある。ダイナミックファクターモデルでは、先に算出した入力データのう

ち、①ダイナミックファクターを用いて予測系列を算出する。このプロセスは通常のダイナミックファクターモデルによるGDPナウキャストの手法である。機械学習モデルでは、入力データの①から③を個別に取り込むことで、3通りの予測系列が算出される。

こうして得た多くの予測系列から精度の高いものを選び出す。さらに、選び出された系列に実質GDP成長率(前期比年率)との予測誤差(平均平方二乗誤差、RMSE: Root Mean Squared Error)を最小化するようウェイト付けして得た系列をGDPナウキャストモデルの予測系列とした。

なお、こうした評価には疑似的ナリアルタイムデータによるout-of-sample予測の結果を用いている。out-of-sample予測とは、予測対象(実質GDP成長率)が公表される前までに取得可能であったデータを用いて予測を行うことである。例えば、2022年第2四半期の実質GDPを予測する際には、同統計の1次速報が発表された2022年8月15日より前に取得可能であったデータのみを用いている。ただし、季節調整の変更など改定後の統計を使用しているため、厳密にはリ

図表1 本稿でのGDPナウキャストモデルの推計手順



(出所) 大和総研作成

アルタイム推計ではない。

## 1. 推計に用いるデータセットの概説

本稿のモデルに取り込む変数は図表2の通りである。ハードデータとソフトデータの双方から構成され、実質GDPの推計に用いられる基礎統計の情報を可能な限り少ない変数で取り込みつつ、速報性の高いソフトデータも用いることで、実質

GDPの動きを早期に把握することを目指している。

また、すべての変数を用いて予測値を算出するだけでなく、モデルに取り込む変数の組み合わせを設定した（図表2：「モデルに採用する変数の組み合わせ」）。推計に用いる変数の数を多くするほど各変数で共通する動きを抽出しやすくなる可能性がある半面、ノイズを多く取り込んでしまう

図表2 GDPナウキャストモデルの推計に用いる変数リスト

		共通ファクター				モデルに採用する変数の組み合わせ				備考
		グローバルファクター	製造業	非製造業	家計	組合せ1	組合せ2	組合せ3	...	
ハードデータ	鉱工業生産	✓	✓			✓	✓	✓	...	製造工業生産予測調査の補正値を延伸に利用
	資本財出荷	✓	✓			✓			...	
	鉱工業在庫	✓	✓			✓		✓	...	
	第3次活動指数	✓		✓		✓	✓	✓	...	JCB消費NOWを延伸に利用
	消費活動指数	✓			✓	✓	✓	✓	...	
	商業動態統計・小売販売	✓		✓	✓	✓	✓	✓	...	JCB消費NOW、新車販売台数、SR1一橋大学消費者購買指数を延伸に利用
	第3次活動指数 (広義対個人サービス)	✓			✓	✓	✓	✓	...	
	有効求人倍率	✓			✓	✓	✓	✓	...	
	労働投入量	✓			✓	✓		✓	...	
	輸出数量指数	✓	✓			✓			...	
	実質輸出	✓	✓			✓	✓	✓	...	
実質GDP	✓				✓	✓	✓	...		
ソフトデータ	日銀短観・業況判断DI 中小製造業	✓	✓			✓	✓	✓	...	
	日銀短観・業況判断DI 中小非製造業	✓		✓		✓	✓	✓	...	
	ロイター短観 製造業	✓	✓			✓	✓	✓	...	先行きDIを利用し3カ月先まで延伸
	ロイター短観 非製造業	✓		✓		✓	✓	✓	...	先行きDIを利用し3カ月先まで延伸
	景気ウォッチャー 製造業	✓	✓			✓		✓	...	
	景気ウォッチャー 非製造業	✓		✓		✓		✓	...	
全国小企業月次動向調査結果	✓	✓	✓		✓	✓	✓	...		

(出所)大和総研作成

リスクが高まる。実際、本モデルにおいても、多くの変数を用いた方が高い予測精度を得るとは限らなかった。そこで、変数の組み合わせを多く用意することで、精度の高い予測値を導出できる可能性を高めるよう意図している。

## (1) ハードデータ

ハードデータとしては、月次指標を中心に実質GDPの基礎統計などを採用した。これらの変数をGDPの三面性から整理すると、鉱工業生産や第3次活動指数はGDPの変動を生産面から捉える。また、消費（消費活動指数、商業動態統計、広義対個人サービス）や設備投資（資本財出荷）、輸出（輸出数量指数、実質輸出指数）といった需要面のGDPの動きも捕捉されることが期待される。分配面のGDPについては企業所得に関連するデータを月次で取得することは難しいが、家計所得の動きは労働投入量によって一部捉えられている。また、GDPの三面性には直接関係はないものの、多くの先行研究と同様に雇用に関する指標を取り入れた。ただし本モデルでは、景気の遅行指数である失業率ではなく、一致指数である有効求人倍率を採用している。

また、浦沢（2022）を参考に、一部のハードデータの未公表月については、オルタナティブデータや業界統計によって延伸した推計値を接続する。具体的には、第3次活動指数の未公表月はJCB消費NOWによって、商業動態統計はJCB消費NOW、SRI一橋大学消費者購買指数及び新車販売統計によって延伸した推計値で未公表月のデータを補う。また、オルタナティブデータではないものの、鉱工業生産指数については製造工業生産予測調査の補正值を用いて補外推計を施している。こうした処理により、公表されている期間

よりも1から2カ月先までの期間のデータをモデルに取り込むことができ、予測精度の向上を期待できる。加えて、月次データであっても補外推計部分については週次・隔週で更新され、より早期に景気動向を把握することが可能となる。

## (2) ソフトデータ

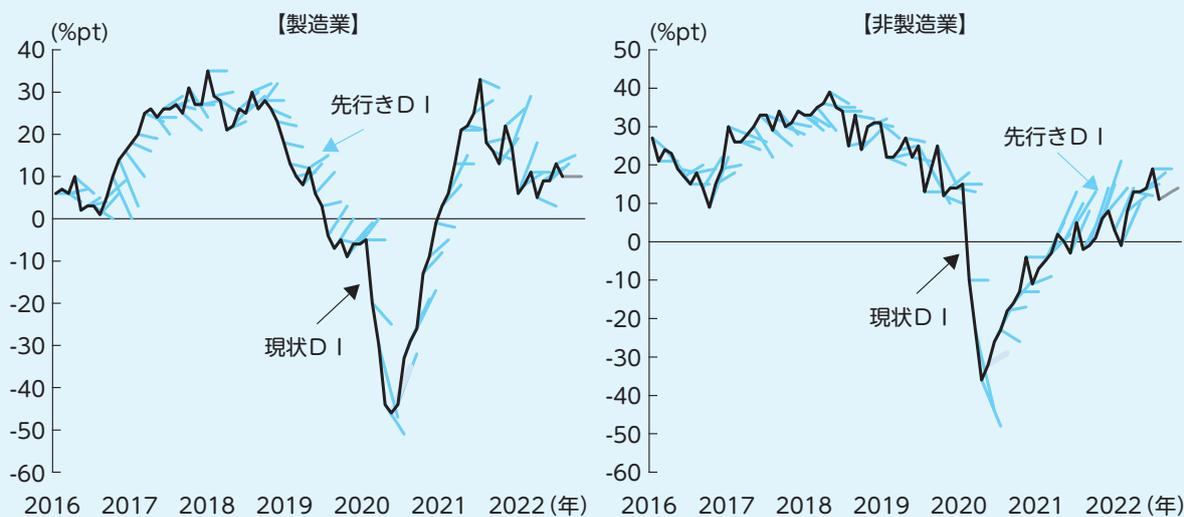
ソフトデータでは速報性の高い統計を多く採用することでモデルが景気の変動を早期に捉えることができるよう企図している。

本モデルの特徴の1つとして、中小企業の業況の捕捉には日銀短観を用いる一方、大企業についてはロイター短観を採用していることが挙げられる。ロイター短観はサーベイ対象が大企業に限られるものの、調査対象月の中頃には結果が公表されるため、非常に高い速報性を有する。加えて、ロイター短観の現状DIは、日銀短観における大企業製造業と非製造業の業況判断DIとの連動性が高いことが知られている。また、ロイター短観では日銀短観と同様に3カ月後の業況の見通し（先行きDI）が取得可能である。この情報を取り込むため、現状DIと先行きDIを線形補間した系列をモデルに取り込んだ。

こうした処理は、近年ではとりわけ新型コロナウイルス感染症対策の実施や解除に伴う実質GDPの変動を捉える上で有益であったとみられる。図表3でロイター短観の現状DIと先行きDIの推移を確認すると、コロナショック期やそこからの景気の回復局面において、とりわけ製造業で先行きDIによって景気の方角感を捉えることができてきている。

日銀短観にも同様に先行き判断DIがあるものの、四半期統計であるため公表頻度は低い。新型コロナウイルス感染症対策の実施に伴うGDP予

図表3 ロイター短観の現状DIと先行きDIの推移



(出所) Refinitivから大和総研作成

測の変化を即座に織り込むことができないため、日銀短観については現状判断DIのみを用いることとした。

## 2. モデル

### (1) ダイナミックファクターモデル(DFM)

ダイナミックファクターモデル(DFM)とは、変数から共通する動き(因子)を抽出し、その因子によって実質GDPの変動を予測する手法である。Hayashi and Tachi (2022)、浦沢(2021)といった日本で運用実績のあるGDPナウキャストモデルにおいて用いられている。海外に目を向けてもニューヨーク連銀が公表していた“New York Fed Staff Nowcast”においても同手法が用いられており、やはり運用面での実績のある手法であるため、本稿においてもモデルの1つとして採用した。

### (2) 機械学習モデル

先に概説した通り、機械学習モデルでは説明変

数として、①ダイナミックファクター、②合成基準化変化率による共通変動成分、③個別系列という3種類のデータセットを用意し、データセットごとに機械学習(SVM)により予測系列を算出した。

ダイナミックファクターを用いて機械学習でGDPナウキャストを行う手法は、Soybilgen and Yazgan (2021)で採用されている。米国のデータを用いて10種類のダイナミックファクターを抽出し、これらを説明変数としてアンサンブル学習によるGDPナウキャストモデルを構築している。米国ではこうした手法による予測精度がダイナミックファクターモデルによる予測精度を上回ったと指摘している。本稿とは異なる機械学習の手法が用いられているが、予測精度が向上する可能性はあるため、本稿のモデルにも機械学習モデルも採用した。

モデルに取り込む共通ファクターの導出方法として、ダイナミックファクターのほかに、「合成基準化変化率による共通変動成分」も採用した。

これは景気動向指数の作成に用いられている手法であり、採用する変数の変化率を基準化した上でその平均値によって全体の動きを捉えるものである。図表2における共通ファクター（グローバルファクター、製造業、非製造業、家計）ごとに合成基準化変化率を算出した。図表4は「合成基準化変化率による共通変動成分」と実質GDP成長率を比較したものである。いずれも連動性は非常に高く、コロナショック以降もある程度連動性が維持されている様子が見て取れる。

Soybilgen and Yazgan (2021) では、多くの変数の情報を集約する目的でダイナミックファクターを導入しているが、本稿ではGDPナウキャストに用いる変数はさほど多くない。このため、個別系列を直接機械学習モデルに取り込むことでも予測値の算出を行う。

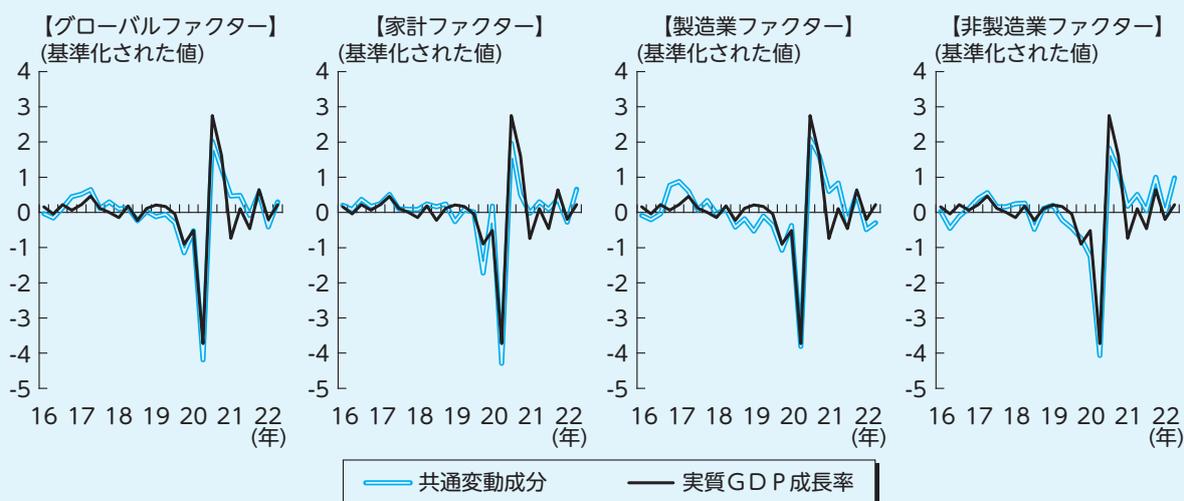
### 3. 各モデルのパフォーマンス評価と Nowcast 予測値の計算

以上の方法により、モデル（ダイナミックファ

クターモデルまたは機械学習）と変数の組み合わせごとに実質GDPの予測系列が算出され、全体として数百種類の予測系列を得る。この中から精度の高い系列を抽出する。こうして選ばれた系列に実質GDP成長率（前期比年率）との予測誤差（RMSE）を最小にするウェイトを乗ずることで、最終的なGDPナウキャストモデルの予測系列が計算される。

検証の結果、最終的には6種類の系列が選択され、これら6種類の系列にウェイト付けを行うことで、本稿におけるGDPナウキャストモデルの予測系列が算出された。内訳は、ダイナミックファクターモデルが1種類、合成基準化変化率を用いた機械学習モデルが1種類、個別系列を用いた機械学習モデルが4種類であった。個別系列にやや偏ったものの、ダイナミックファクターモデルや合成基準化変化率を用いた機械学習モデルも予測値に一定程度影響を与える形となっている。

図表4 合成基準化変化率による共通変動成分と実質GDP成長率の比較



(出所) 株式会社ナウキャスト/JCB「JCB消費NOW」、SRI一橋大学消費者購買指数、内閣府、経済産業省、日本銀行、厚生労働省、総務省、Refinitiv、日本政策金融公庫、日本自動車販売協会連合会から大和総研作成

## 2章 パフォーマンスの検証と課題の精査

次に、上記のプロセスを経て算出されたモデルによる予測値と市場予測を比較することで、モデルの予測精度を検証する。

### 1. 市場予測との予測精度の比較

図表5は本稿におけるGDPナウキャストモデル（以下、Nowcastモデル）の予測と市場予測（ESPフォーキャスト）の精度を比較したものである。左図は、Nowcastモデルにおける予測と市場予測の実質GDP成長率（前期比年率）に対する予測誤差（RMSE）を比較したものである。この値が小さいほど、予測対象である実質GDP成長率との乖離が小さく、予測精度が高いことを意味している。

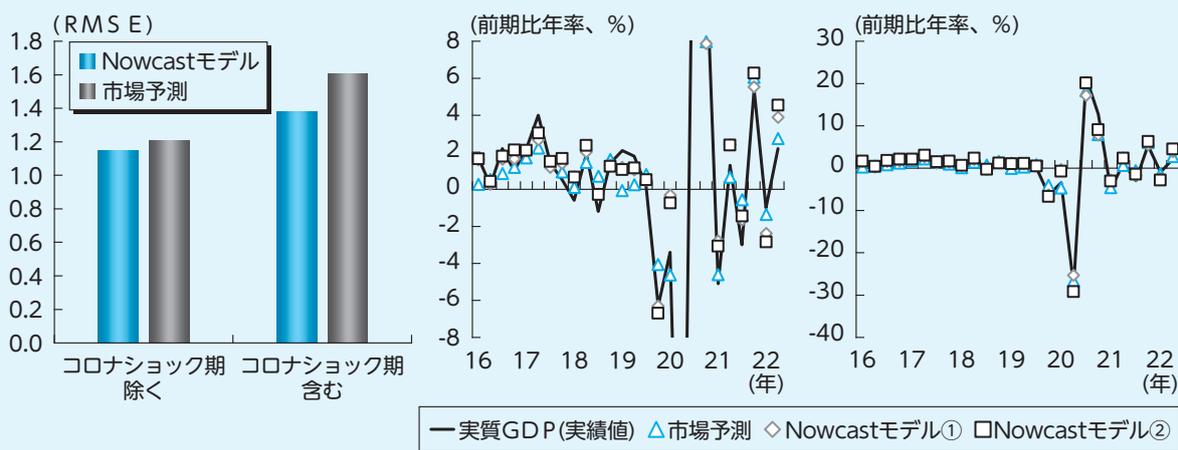
コロナショックを含む期間と除く期間のそれぞれ

れについて、Nowcastモデルの予測値をRMSEで評価すると、両者とも市場予測よりも小さいことが確認された。本稿の手法が一定程度有益である可能性を指摘できよう。

図表5中及び右は、2016年以降のNowcastモデル予測と市場予測、実質GDP成長率の実績値を比較したものである。Nowcastモデルについては、コロナショックを除く期間（Nowcastモデル①）と含む期間（Nowcastモデル②）について、それぞれRMSEを最小化したモデルを掲載している。なお、コロナショック期は実質GDPの変動がとりわけ大きかった2020年第2四半期から第4四半期とした。

2021年以降は「Nowcastモデル①」の方が「Nowcastモデル②」よりも実質GDP成長率の実績値に近い値を取る場合が多い。最近の傾向としては「Nowcastモデル②」の予測値の変動が実際のGDP成長率の変動よりも大きくなってい

図表5 GDP Nowcastモデルによる予測と市場予測の精度の比較



(注1) RMSEの計算には2016年以降のサンプルを使用。コロナショック期は2020年第2-4四半期とした。  
 (注2) RMSEは実質GDP成長率(1次速報)を基準とした。市場予測は1次速報公表月のESPフォーキャストを使用。Nowcastモデルは1次速報公表月の前月末時点で取得可能なデータを用いた予測値の結果を使用。  
 (注3) Nowcastモデル①はコロナショック期を除く場合、Nowcastモデル②はコロナショック期を含む場合に、RMSEが最も小さいモデル。  
 (注4) 中図と右図は同じデータを掲載しているが、前者はコロナショック期以外の期間の動きを捉えるため、後者はコロナショック期の動きを捉えるために縦軸を調整している。  
 (出所) 日本経済研究センター、株式会社ナウキャスト/JCB「JCB消費NOW」、SRI一橋大学消費者購買指数、内閣府、経済産業省、日本銀行、厚生労働省、総務省、Refinitiv、日本政策金融公庫、日本自動車販売協会連合会から大和総研作成

る。コロナショックを評価対象期間に含むことで、同時期における経済の急激な変動を捉えようとするあまり、その後の公衆衛生上の措置の実施や解除による経済の変動を過大に捉えている可能性がある。

## 2. 週次データを用いた Nowcast モデルのアップデートの軌跡

次に、GDP が公表に至る過程において、Nowcast モデルによる予測値がどのような軌跡をたどるかを週次のデータを用いて考察することで、同モデルの特徴や運用における課題をあぶり出す。

先に考察した通り、直近のパフォーマンスはコロナショックを除く期間で評価したモデルの方が良好であったため、同モデルでの修正過程を中心に評価する。これに加えて、2021 年以降の RMSE を最小化したモデルによる系列の動きも確認する。ただし、同期間における RMSE を評価す

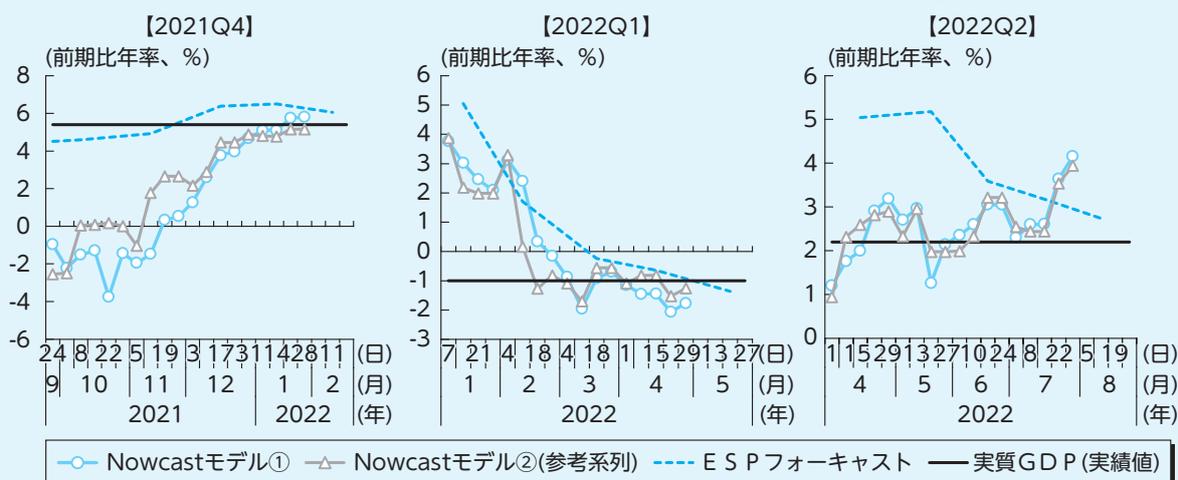
るためのサンプル数は非常に少なく、ウェイトの設定を行うには本来十分ではないことから、参考系列としている。

### (1) 2021 年 10-12 月期 (図表 6 左)

同期における実質 GDP 成長率 (1 次速報) は前期比年率 + 5.4%、2022 年 1 月末時点で取得可能であったデータから算出したモデル予測 (Nowcast モデル①) は同 + 5.8%、市場予測 (2022 年 2 月 E S P フォーキャスト) は同 + 6.1% であった。最終的には、モデルの予測値は市場予測よりも実績値に近く、非常に良好な結果であったと評価できよう。2021 年 12 月後半 (実質 GDP が公表される 1.5 カ月ほど前) 以降、モデル予測の値は安定している。

ただし、Nowcast モデルの予測値の変遷を見ると、同モデルにおける課題が浮かび上がる。2021 年 11 月末までは予測値が同 0% 近傍となっていたが、12 月に公表される統計を反映して、

図表 6 GDP ナウキャストモデルによる予測と市場予測、実績値の比較



(注) Nowcastモデル①はコロナショック期を除く期間のRMSEを最小化するモデル。Nowcastモデル②は2021年以降のRMSEを最小化するモデル。ただし、サンプル数が十分でないことから参考系列としている。  
 (出所) 日本経済研究センター、株式会社ナウキャスト/JCB「JCB消費NOW」、SRI—橋大学消費者購買指数、内閣府、経済産業省、日本銀行、厚生労働省、総務省、Refinitiv、日本政策金融公庫、日本自動車販売協会連合会から大和総研作成

急速に予測値が修正されていった。対照的に市場予測は9月時点で+4.5%と実績値と近い値を示しており、その後の修正幅も小さかった。

2021年7-9月期の実質GDPは緊急事態宣言やまん延防止等重点措置の影響でマイナス成長となったが、経済活動の再開によって10-12月期には反動増が予測されていた。市場予測ではあらかじめこうした動きを捉え、高めの成長率が予測されていた一方、モデルによる予測値は反動増が統計データに現れてから急速に修正が進んだ。

先に述べた通り、ロイター短観の先行きDIやオルタナティブデータを取り込むことで、急激な経済の変動をより早期に捉えるよう企図しているが、それでも修正のペースは緩慢であることが確認された。この点は今後の修正課題として挙げられる。

このように、大きな変動が予測される四半期のとりわけ期初には、市場予測と比較して予測精度が大きく下がる可能性があることには注意が必要だ。こうした変動は新型コロナウイルス感染症の感染拡大に伴う緊急事態宣言などに限らず、消費税率の引き上げが引き起こす、駆け込み需要とその反動減も該当すると考えられる。今後の運用に際しても、こうした点には留意が必要だろう。

## (2) 2022年1-3月期 (図表6中)

同期における実質GDP成長率(1次速報)は、前期比年率▲1.0%、2022年4月末時点で取得可能であったデータから算出したモデル予測(Nowcastモデル①)は同▲1.8%、市場予測(2022年5月ESPフォーキャスト)は同▲1.3%であった。市場予測の精度が上回った。ただし、参考系列では同▲1.3%となり、市場予測と同程度であった。また、2022年3月中頃(実

質GDPが公表される2カ月ほど前)以降、モデル予測の値は概ね安定している。

2022年1月はじめには、市場予測もモデル予測も比較的高い成長率を示していた。しかし、1月はじめから新規感染者数が急増し、まん延防止等重点措置が適用されたことを受け、市場予測は急激に低下した。モデル予測においても、こうした影響がはじめに現れるロイター短観が公表されて以降、急速に予測値が低下した。

2021年10-12月期の例では、予見された経済の変動に対してモデルの予測値は修正が遅れることを指摘した。しかし、2022年1-3月期の例では、期初時点で予期されないショックに対しては、本稿におけるNowcastモデルは市場予測と概ね同程度の速度で修正されることが確認された。

## (3) 2022年4-6月期 (図表6右)

同期における実質GDP成長率(1次速報)は前期比年率+2.2%、2022年7月末時点で取得可能であったデータから算出したNowcast予測は同+4.1%、市場予測(2022年5月ESPフォーキャスト)は+2.7%であった。Nowcast予測値の乖離幅は比較的大きく、市場予測がより高い精度を示した。2022年7月の初旬(実質GDPが公表される1.5カ月ほど前)以降、モデル予測の値は概ね安定していたものの、これまでの傾向とは異なり7月後半に大幅な修正が見られた。

市場予測を見ると、同四半期の開始直後は高い数値を示していたものの、徐々に下方修正されている。2022年1-3月期に実施されたまん延防止等重点措置が解除されたことで、実質GDPが反動増に転じるとの見方が強まっていたが、上海

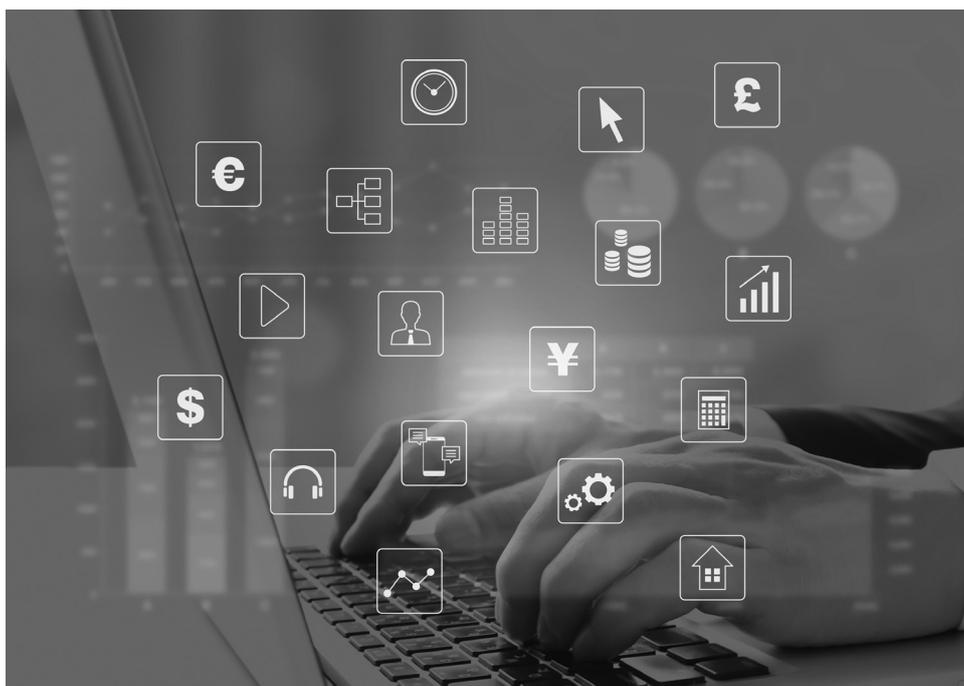
でのロックダウンの影響で供給制約が強まったことなどがこの背景にある。

他方、当該四半期における Nowcast 予測は4月はじめには前期比年率+1%程度と低かったものの徐々に上方修正された。4月末には同+3%程度まで高まったが、その後ソフトデータにおいて供給制約の影響が表れはじめ、それがハードデータでも確認されるにつれて、同+2%近傍で上昇と低下を繰り返した。この段階では、概ね実績値に近かったものの、7月後半に集中して発表された6月分の統計を経た修正によって予測値が実績値から乖離する結果となった。

## おわりに

本稿では、GDP ナウキャストモデルを構築し、その有効性を検証した。オルタナティブデータを取り込むことで早期に実質GDPの変動を捉えることを試みた。さらに、運用実績の高いダイナミックファクターモデルに加えて、機械学習モデルも導入することで、複数のモデルから最適な予測値が導き出される設計となっている。

モデルのパフォーマンスは市場予測と比較しても精度が高く、実質GDPの早期把握に一定程度有益である可能性が示唆される。ただし、コロナショックを含む期間において実質GDPとの予測誤差が最も小さくなるモデルでは2021年以降は予測誤差が大きくなる傾向が見られるなど課題も残る。ポストコロナにおけるGDP統計の蓄積を待ちつつ、モデルの改良を重ねることでこうした課題を克服する必要がある。



【参考文献】

- ・ Soybilgen, B., & Yazgan, E. (2021). “Nowcasting US GDP Using Tree-Based Ensemble Models and Dynamic Factors.” *Computational Economics*, 57, 387-417. <https://doi.org/10.1007/s10614-020-10083-5>
- ・ Bok, B., D. Caratelli, D. Giannone, A. Sbordone, and A. Tambalotti. (2017) “Macroeconomic Nowcasting and Forecasting with Big Data.” Federal Reserve Bank of New York *Staff Reports*, no. 830, November.
- ・ Hayashi, F., and Tachi, Y. (2022) “Nowcasting Japan’s GDP.” mimeo
- ・ 浦沢聡士 (2021) 「GDP ナウキャストリング：成果と課題」, Kanagawa University Economic Society Discussion Paper, 2021-01.
- ・ 浦沢聡士 (2022) 「GDP ナウキャストの枠組みの変更：更なる予測精度の向上にむけて」東京財団政策研究所ホームページ, available at: <https://www.tkfd.or.jp/research/detail.php?id=4055> (Last accessed: 2022/9/17)
- ・ 中澤崇 (2022) 「オルタナティブデータを用いたGDP ナウキャストリングモデルの構築」、日本銀行ワーキングペーパーシリーズ、No.22-J-1

[著者]

久後 翔太郎 (くご しょうたろう)



経済調査部  
シニアエコノミスト  
データサイエンティスト  
担当は、日本経済 / 財政、  
金融政策