

LSTM モデルを使った県内総生産の推計

Forecasting Prefectural Gross Domestic Product with an LSTM Model

山澤成康

Nariyasu YAMASAWA

要旨

県内総生産の発表は約2年後と遅く、速報値を発表する自治体も減少している。速報値を作成する試みもあるが、第3次産業については都道府県別統計が少なく、推計が困難だった。本研究では深層学習のうちLSTM（長期短期記憶）モデルを用いた推計を試みた。第3次産業活動指数などの速報性のあるデータを使って、現時点の値を「予測」するナウキャスティング（Nowcasting）である。

2003年度から2020年度までのデータを使って2021年度を推計したところ、従来手法と比較して精度が高いことを確認した。

キーワード：県内総生産、ナウキャスティング、深層学習、LSTM

1. はじめに

都道府県別GDPにあたる県内総生産の発表はおよそ2年半後と遅く、2022年度の多くは、2025年3月前後に発表された。都道府県によっては2025年9月に発表されたものもある。発表が遅いため、都道府県の政策決定には使いにくく、あまり活用されない事態が続いている。

県内総生産の発表が遅いのは、基礎統計の発表が遅いためである。県民経済計算の作成法は内閣府の「県民経済計算推計方法ガイドライン」によって方向づけされている。県民経済計算は、生産面、支出面、分配面から作ることができるが、生産面に注目して解説すると、産業別に基礎統計があり、それらをもとに、実質化することで生産面の県内総生産が作成される。

その際重要なのが、経済構造実態調査（総務省・経済産業省）である。経済構造実態調査は国のGDPの精度を上げるために作られた統計で、製造業では工業統計（経済産業省）、サービス業ではサービス産業動向調査（総務省）、商業統計調査（経済産業省）、特定サービス産業実態調査（経済産業省）の3調査を統合・再編したものだ。

経済構造実態調査の登場で、都道府県別のサービス産業の売上高は把握しやすくなった。ただ、この統計を基礎統計とすれば、発表は2年後以降になり、これ以上の速報化は期待しにくい。

図表1 製造業の調査と発表時期

対象年	統計	発表日
2019年	工業統計地域別統計表	2021年 8月25日
2020年	経済センサス活動調査・製造業・地域編	2022年 12月26日
2021年	経済構造実態調査3次集計	2023年 10月27日
2022年	〃	2024年 10月29日

速報値作成の試みと衰退

「経済構造実態調査」を主要な調査として利用しているのは国のGDPでも同じだが、別途QE（四半期推計）という形で速報値を発表している。

都道府県においても、速報値を作る動きがあったが、最近その動きは下火になっている。佐藤（2010）によると、2009年度には、秋田県、茨城県、静岡県、兵庫県、島根県、広島県の8県が四半期速報値を発表した。しかし、2025年度では、福岡県、兵庫県、茨城県の3県に減少した。福岡県は2011年度から発表を開始している。

速報化を試みた場合、第1次産業は基礎統計が乏しいが、第2次産業の建設業や製造業は都道府県別の統計がある。しかし、第3次産業は都道府県別の統計がなく、都道府県別に推計するのには通常の積み上げ式の作成では難しい。そこで本研究では深層学習による推計を試みた。

深層学習を使う理由

深層学習を使う理由は以下の通りである。第一に変数の長期依存関係が捉えられることである。深層学習のうち、RNN（リカレントニューラルネットワーク）やその発展形のLSTMは、過去の値の情報を活かすことができる。第二に、非線形な関係をモデル化できることである。パラメーターの数が多く、柔軟なモデルをつくることができる。第三にノイズに強いことである。LSTMはデータパターンを柔軟に学習できるため、金融危機、新型コロナウイルス感染拡大の影響などのノイズを吸収できる。第四に、複数の特徴量を同時に捉えることができるため、多数の変数を

LSTM モデルを使った県内総生産の推計

使うことができる。

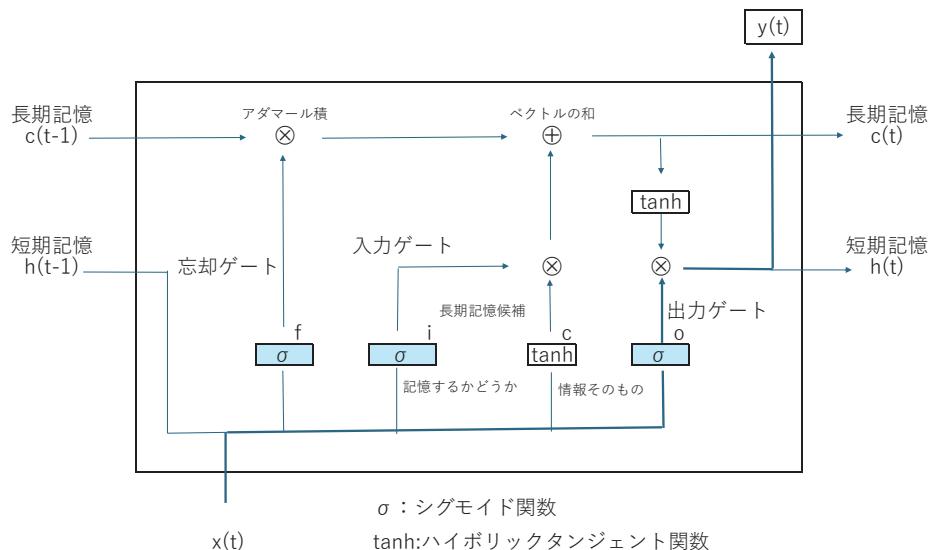
一方で、過学習で汎化性能が失われる可能性もあり、検証データでのチェックが必要である。

LSTM について

LSTM は、深層学習の発展形の一つである。学習に過去の値を入れたものとして RNN があるが、それを発展させたものである。RNN は記憶がすぐになくなり、勾配消失問題も起こることが知られており、それを克服するために、短期記憶と長期記憶にわけ、長期的な記憶も生かせるものである。

LSTM について図解をすると以下の通りである。基本的な深層学習では、左下に入力された $x(t)$ が隠れ層を通って右上の $y(t)$ として出力される。LSTM では、隠れ層が短期記憶（隠れ状態） $h(t)$ と長期記憶（セル状態） $c(t)$ の 2 種類ある。1 期前の短期記憶 $h(t-1)$ と入力 $x(t)$ から、長期記憶に必要なないもの（忘却ゲート）、長期記憶として残すもの（入力ゲート）を選ぶ。長期記憶 $c(t)$ をベースに、入力 $x(t)$ によって情報を選別し、その時点の短期記憶 $h(t)$ を作る。 $h(t)$ は次の時刻にも渡されるし、出力 $y(t)$ を決めるのにも使われる。

図表 2 LSTM の仕組み



2. 先行研究

第3次産業について都道府県別に推計した先行研究には山澤（2021）や Fujii et al. (2025) がある。山澤（2021）では、生産面から県内総生産を推計している。第3次産業活動指数については、第3次産業活動指数の業種別指数をクラスター分析によって、2グループの指標に統合し、回帰分析によって都道府県別指数を求めた。Fujii et al. (2025) では、都道府県別の業種別ウエートを用い、第3次産業活動指数の業種別指数を加重平均して県内総生産（第3次産業）を求めている。

次に、GDP を目標変数とした深層学習に関する先行研究を挙げる。Lin (2022) は、米国 GDP 成長率の予測に長期短期記憶（LSTM）モデルを適用した。LSTM モデルは単独では不安定で複雑すぎるが、周期別に予測すると予測精度が上がることを示した。

J.Laborda et al. (2023) は、OECD 加盟 25カ国 の GDP を同時に予測する手法を提案した。一つのモデルで1四半期先から4四半期先まで予測する。テンポラル・フェージョン・トランスフォーマー（TFT）と呼ばれる最新の深層学習手法を使っている。

Xie et al. (2024) は、複数国の GDP 成長率予測に関し、過去の GDP 成長率データを用いる場合は線形回帰モデルの方が精度が高いが、ほかの経済変数を加えた場合は深層学習モデル（LSTM）の方が精度が高いことを示した。

Wang et al. (2024) は、主要 13カ国 のデータで 10 年先までの GDP 成長率の長期予測を行っている。LSTM、双方向 LSTM、エンコーダー・デコーダー LSTM、CNN などさまざまな時系列学習モデルを使っている。このうち、エンコーダー・デコーダー LSTM が最も精度が高いとしている。

Németh・Hadházi (2024) は、予測分布も含んだ GDP 成長率のナウキャストを試みた。米国四半期 GDP 成長率を対象とした。深層学習によって GDP 成長率の密度予測を生成する手法を提案した。

Dong et al. (2025) では、PAA—LSTM という手法を提案している。経済局面にも注意しながら、GDP データを予測するというものである。

これらの先行研究には査読前のプレプリントのものもあるが、LSTM の応用が進んでいることを示すために掲げた。これらの研究を踏まえても、日本の県内総生産に LSTM を応用した研究としては、本研究が初めてである。

3. データ

目標変数は、県内総生産（第3次産業）とした。特徴量には、さまざまな候補が考えられるが、都道府県別に得られる鉱工業生産指数、建設工事出来高と地域別支出総合指数（RDEI）を候補とした。第3次産業活動指数とその業種別指数は、全国値しかないが、どの都道府県にも全国値を使うことで特徴量の候補とした。また、第3次産業活動指数は、業種別にあるので、県内総生産の分類に合わせて組み替えたものを特徴量として使った。業種は、電気・ガス・熱供給・水道・廃棄物処理、情報通信業、運輸業・郵便業、卸売業、金融業・保険業、その他サービス、専門・科学技術・業務支援サービス業、小売業、不動産業、保健衛生・社会事業、宿泊・飲食サービス業である。

図表3 特徴量一覧

	県内総生産（第3次産業）	都道府県	年度
1	RDEI（消費）	内閣府	月次
2	RDEI（住宅投資）	内閣府	月次
3	RDEI（民間設備投資）	内閣府	月次
4	RDEI（公的固定資本形成）	内閣府	月次
5	鉱工業生産指数	経済産業省	月次
6	建設総合統計（建設工事出来高）	国土交通省	月次
7	第3次産業活動指数（全国値のみ）	経済産業省	月次

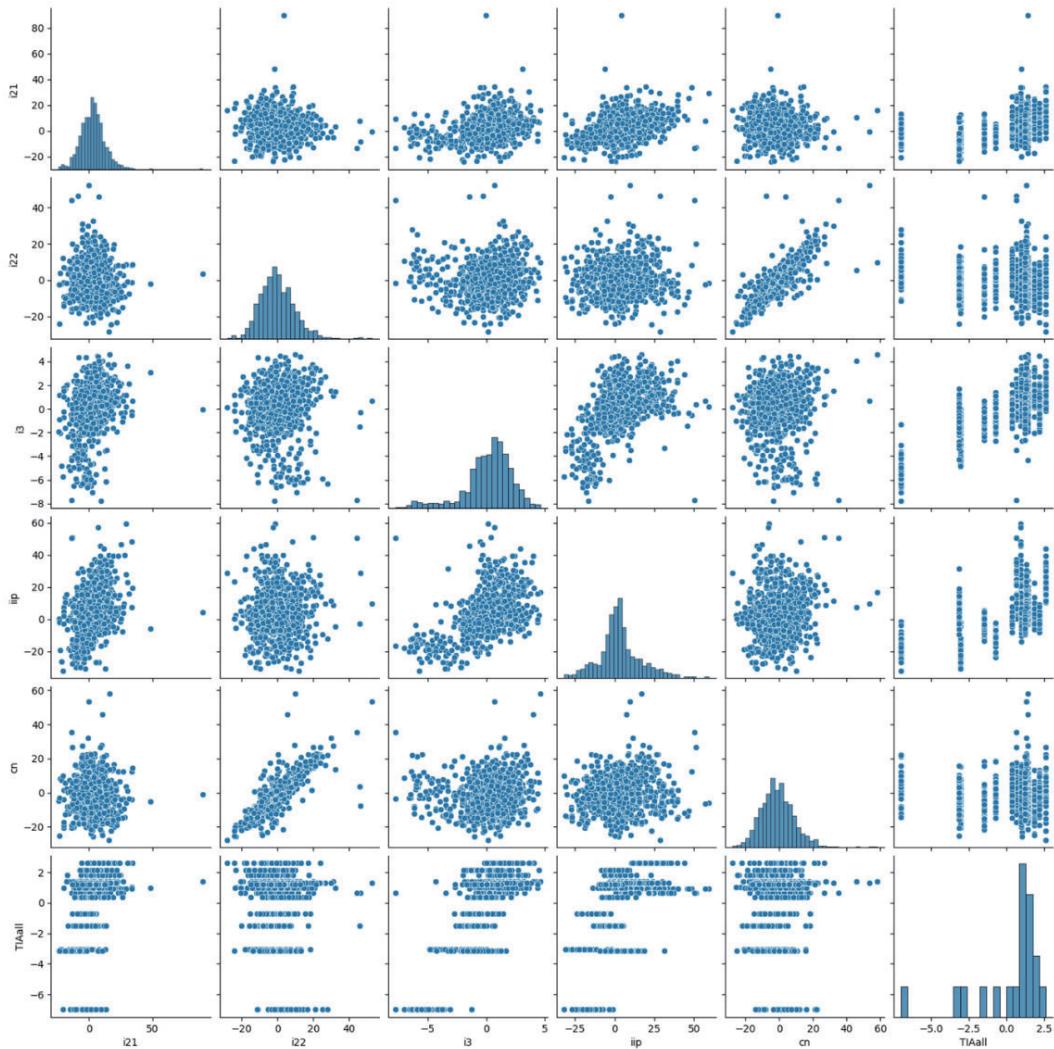
（注）ほかに、第3次産業活動指数の業種別がある。

相関係数

都道府県、年度別に県内総生産とその基礎統計の散布図をみたのが以下の図である。すべて前年度比のデータである。

製造業と鉱工業生産指数はほぼ無相関であることがわかる。一方、建設業と建設総合統計には相関がある。第3次産業活動指数は年度の数値しかないので、縦軸に第3次産業活動指数をとり、横軸に都道府県別の県内総生産（第3次産業）をとった場合、横一列に並ぶことになる。相関はありそうだが、年によって都道府県別にばらつきがあることがわかる。

図表4 統計の散布図（伸び率）



(注) 縦軸、横軸ともに、順に県内経済計算（製造業）、同（建設業）、同（第3次産業）、鉱工業生産指数、建設総合統計、第3次産業活動指数（全国値）。

4. 推計法

推計の概要

LSTMの推計にはPythonのライブラリーであるPyTorchを使用した。学習・検証期間は2003年度から2020年度とし、学習期間70%、検証期間30%とした。学習サンプルはランダムに選んだ。このモデルを使って、2021年度の予測精度を比較した。

LSTM モデルを使った県内総生産の推計

特微量としては、データで記した特微量のほか、都道府県別ダミー変数、ラグ変数（1期前、2期前）を使用した。

一つのサンプルは、特微量を何年間かセットにしたものだ。1サンプルの期間の長さをシーケンス長と呼ぶ。1サンプルの最後の年の県内総生産（第3次産業）を予測するものとした。学習・検証サンプルは2003年度から2020年度までで、47都道府県あるので、全部で18（=2020-2003+1）年間、846（=47×18）サンプルある。

シーケンス長が5年だとすると、サンプル期間は4年分減って14年分になる。サンプル数658（=47×14）サンプルとなる。また、学習サンプルはこのうちの70%で、460（=658×0.7）サンプルとなる。

ハイパーパラメーター

ハイパーパラメーターの設定は、以下の通り。

1サンプルの長さについては、1年度から3年度までとした。

学習率はどの程度パラメーターを更新するかを表すが、0.001とした。

最適化手法は、SGD（確率的勾配降下法）を使った。

損失関数の損失（実績値と推計値の差）の計算法は、MSELoss（平均二乗誤差）を使った。

エポック数は、何回収束計算をするかを表すが、5000回とした。

5. 推計結果

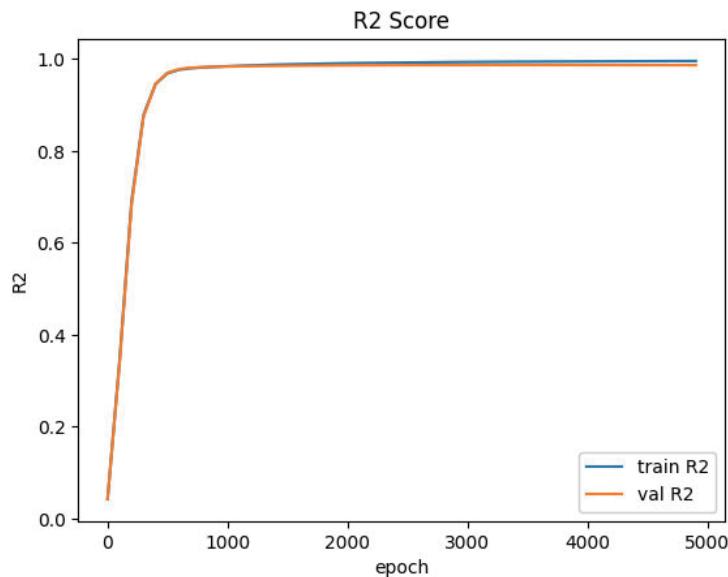
推計結果は、2021年度の予測値で比較した。誤差を測る指標としては、直感的にわかりやすい、絶対平均誤差を使った。誤差の絶対値の平均である。

結果的に最も精度が高かったシーケンス長（1サンプルの期間）が2で説明変数が第3次産業活動指数の場合は以下の結果となった。図表5をみると、エポック数が増えるとともに、決定係数が上がっていることがわかる。学習データから得られたモデルを使って、検証データで予測したが、ほぼ同じ精度が得られている。

図表6の散布図は、上記モデルの2021年度の県内総生産（第3次産業）の伸び率の予測値と実績値である。横軸を実績値、縦軸を予測値としたものである。両者が一致すれば45度線上に並ぶ。

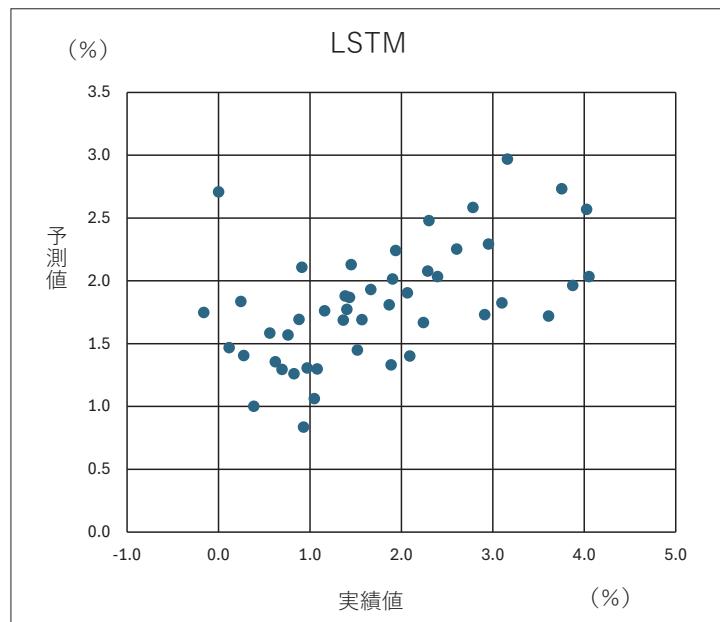
図表7は、2015年度の各都道府県の県内総生産（第3次産業）の業種別比率を使って、業種別第3次産業活動指数を加重平均したものの前年度比伸び率である。この推計法だと全国値平均に近い予測値が多く、都道府県別の違いがはっきり表れないことがわかる。

図表5 モデルの収束状況



(注) エポック数に対応した決定係数の推移。trainR2は学習データによる結果、valR2は検証データによる結果。

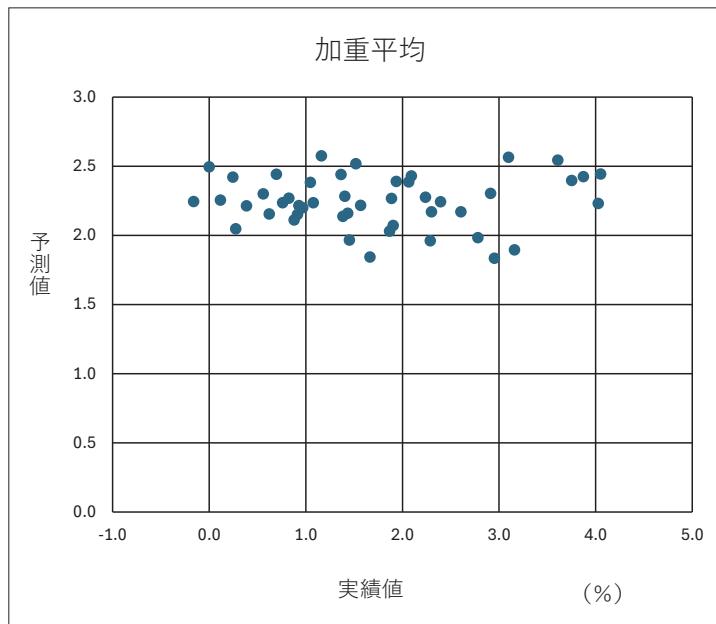
図表6 LSTMによる予測値



(注) 2021年度の県内総生産（第3次産業）の伸び率の比較。

LSTM モデルを使った県内総生産の推計

図表 7 加重平均による予測値



(注) 2021 年度の県内総生産（第 3 次産業活動指数）の伸び率の比較。

特徴量の違い

特徴量（説明変数）の違いによる精度の違いを絶対平均誤差で調べた。特徴量が第 3 次産業活動指数のみの場合が最も誤差が小さかった。

業種別の変数を特徴量として加えた場合は、むしろ誤差が大きくなかった。県内総生産と業種別指数との相関は低く、予測に対してノイズとして作用している可能性がある。鉱工業生産指数や

図表 8 特徴量の違いによる精度の差

	第 3 次産業活動指数のみ	第 3 次産業活動指数、業種別	IIP など月次指標 6 個 + 第 3 次産業活動指数	IIP と第 3 次産業活動指数	ダミー変数なし	ラグ変数なし
シーケンス長	2	2	2	2	2	2
特徴量の数	1	12	7	2	1	1
検証データの比率	0.3	0.3	0.3	0.3	0.3	0.3
隠れ層の次元	32	32	32	32	32	32
絶対平均誤差	0.73	1.53	0.79	0.96	0.74	1.12
隠れ層の数	1	1	1	1	1	1

建設工事出来高、地域別総合支出指数（RDEI）の6指標と第3次産業活動指数を使った場合や鉱工業生産指数と第3次産業活動指数2つを使った場合も精度が落ちた。

都道府県別ダミー変数は、各都道府県の特徴を捉えられることを期待していた。精度はあがるがそれほど大きな貢献ではなかった。一方、1年前、2年前のラグ変数は予測の精度に影響を与えている。ラグ変数がない場合の精度は大幅に落ちた。

ハイパーパラメーターの違い

次にハイパーパラメーターを変化させた場合である。隠れ層の次元を16、32、64と変えた場合は、32の精度が最も高かった。

次にシーケンス長（1サンプルの期間）を変えた場合である。シーケンス長が長くなれば長期記憶の情報が活用されて精度が上がりそうだが、むしろ精度が下がった。県内総生産の場合は、長期記憶がそれほど重要ではないと考えられる。シーケンス長が1の場合は、過去の情報を使わないということになるが、それよりは、図表8にあるように、シーケンス長が2の場合の方が精度が高い。

隠れ層の数を2層にした場合も行ったがむしろ精度は下がった。

図表9 ハイパーパラメーターの違いによる精度の差

	第3次産業活動指数のみ							
	2	2	2	1	3	5	7	2
シーケンス長	2	2	2	1	3	5	7	2
特徴量の数	1	1	1	1	1	1	1	1
検証データの比率	0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.3
隠れ層の次元	16	32	64	32	32	32	32	32
絶対平均誤差	0.74	0.73	0.83	0.77	0.82	0.80	0.91	0.75
隠れ層の数	1	1	1	1	1	1	1	2

代替予測との比較

代替予測手法として、ランダムフォレストとダミー付き線形回帰による予測も行った。ランダムフォレストは、2003年度から2020年度までの70%の学習データを選んでモデルを推計した。決定木の数300、枝の階層数15である。

ダミー変数付き線形回帰は、2003年度から2020年度までのデータで2021年度を予測した。いずれの場合もLSTMより誤差が大きくなってしまい、LSTMが他の手法を上回る精度を示した。

LSTM モデルを使った県内総生産の推計

図表 10 代替予測との比較

モデル	絶対平均誤差
LSTM	0.73
ランダムフォレスト	1.02
ダミー変数付き線形回帰	2.12

6. おわりに

本研究では、LSTM モデルを用いて県内総生産（第 3 次産業）のナウキャスティングを試み、従来の推計方法と比較して高い精度を示すことができた。特に、シーケンス長を 2 とした場合に精度が高まり、ラグ変数が予測に重要な役割を果たしていることを確認した。また、ランダムフォレストや線形回帰との比較においても LSTM の優位性を明らかにした。

しかし、本研究にはいくつかの課題も残されている。第一に、検証年度が 2021 年度に限定されており、他の年度においても同様の結果が得られるかは未検証である。今後は、複数の年度を対象とした頑健性の確認が必要である。第二に、使用した特徴量は第 3 次産業活動指数や鉱工業生産指数などに限定されており、今後は POS データ、金融取引データ、移動統計などの高頻度データを組み込むことで、更なる精度向上が期待できる。第三に、LSTM 以外の深層学習モデル——例えばテンポラル・フェージョン・トランスフォーマー (TFT) やアテンション機構を組み込んだモデル——との比較も有益である。

また、政策的な観点からは、都道府県レベルで迅速に利用できる県内総生産の推計値が提供されれば、地域経済政策や災害・感染症対応などの迅速な意思決定に資する可能性がある。実用化に向けてさらに研究する必要がある。

謝辞

本研究は令和 7 年度跡見学園女子大学特別研究助成費（課題名：「都道府県・市町村活動指数のナウキャスティング——深層学習の活用」）の助成を受けたものである。記して謝意を表する。

参考文献

英語文献（著者アルファベット順）

1. Dong Thi Ngoc, L. · Hoan, N. D. · Nguyen, H.-N. (2025) 「Gross Domestic Product Forecasting Using Deep Learning Models with a Phase-Adaptive Attention Mechanism」『Electronics』, 14

- (11), 2132. <https://doi.org/10.3390/electronics14112132>
2. Fujii, Daisuke · Nakata, Taisuke · Sunakawa, Takeki (2025) 「Monthly prefecture-level GDP in Japan」『The Japanese Economic Review』, 10.1007/s42973-025-00193-w.
 3. Laborda, J. · Ruano, S. · Zamanillo, I. (2023) 「Multi-Country and Multi-Horizon GDP Forecasting Using Temporal Fusion Transformers」『Mathematics』, 11 (12), 2625. <https://doi.org/10.3390/math11122625>
 4. Lin, S. L. (2022) 「Application of empirical mode decomposition to improve deep learning for US GDP data forecasting」『Heliyon』, 8 (1), e08748. <https://doi.org/10.1016/j.heliyon.2022.e08748>
 5. Németh, K. · Hadházi, D. (2024) 「Generating density nowcasts for U.S. GDP growth with deep learning: Bayes by Backprop and Monte Carlo dropout」『arXiv Preprint』, <https://doi.org/10.48550/arXiv.2405.15579>
 6. Shams, M. Y. · Tarek, Z. · El-kenawy, E. S. M. 他 (2024) 「Predicting Gross Domestic Product (GDP) using a PC-LSTM-RNN model in urban profiling areas」『Computational Urban Science』, 4 (3), 3. <https://doi.org/10.1007/s43762-024-00116-2>
 7. Wang, T. · Beard, R. · Hawkins, J. · Chandra, R. (2024) 「Recursive deep learning framework for forecasting the decadal world economic outlook」『arXiv Preprint』, <https://doi.org/10.48550/arXiv.2301.10874>
 8. Xie, H. · Xu, X. · Yan, F. · Qian, X. · Yang, Y. (2024) 「Deep Learning for Multi-Country GDP Prediction: A Study of Model Performance and Data Impact」『arXiv Preprint』, <https://doi.org/10.48550/arXiv.2409.02551>

日本語文献

9. 内閣府 (2022) 「2015年(平成27年)基準 県民経済計算推計方法ガイドライン」https://www.esri-cao.go.jp/jp/sna/data/data_list/kenmin/files/contents/pdf/guideline/guide_220204.pdf
10. 佐藤智秋 (2010) 「県民経済計算の推計と利活用の現状」『研究所報』、法政大学日本統計研究所、40、63-75。
11. 山澤成康 (2021) 「生産側都道府県別月次実質GDPの作成」『跡見学園女子大学マネジメント学部紀要』、34、39-57。