

ニュース記事に基づく景気指数の開発と長期 時系列予測への応用

森田, 彩星 / Morita, Ayase

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

65

(開始ページ / Start Page)

1

(終了ページ / End Page)

8

(発行年 / Year)

2024-03-24

(URL)

<https://doi.org/10.15002/00030759>

ニュース記事に基づく景気指数の開発と 長期時系列予測への応用

DEVELOPMENT OF ECONOMIC INDICATORS BASED ON NEWS ARTICLES AND APPLICATION TO LONG-TERM TIME SERIES FORECASTING

森田彩星

Ayase Morita

指導教員 藤井章博

法政大学大学院理工学研究科応用情報工学専攻修士課程

In this research, I apply recent techniques in natural language processing and propose a new method for constructing economic indicators using economic documents and Reuters news based on the economic judgment reasons included in the Economic Watcher Survey provided by the Cabinet Office. I also attempt to capture early economic fluctuations by predicting the future economy using an economic index constructed using a time-series prediction model.

Key Words: BERT, Economic Trend, Forecast

1. はじめに

現在、内閣府や日本銀行などは国内の景気や経済動向に関する景気指数を日々公表している。これらの景気指数は投資や在庫管理、コスト削減の判断に利用できるように企業の業績に関わっている。この景気指数には、GDPや景気動向指数のDIやCI、日銀短観の業況判断指数・DIなどがある。しかし現在公表されている多くの景気指数や経済レポートは公表頻度が低く、リアルタイムで景気状況を把握しにくい問題がある。景気指数の公表頻度の例として、GDPや日銀短観の業況判断指数・DIは四半期統計であり、四半期に一度のみ公表される。また、景気動向指数のDIやCIは月に一度公表される。このようにこれらの指数は経済動向を判断する上で重要な統計データであるにもかかわらず公表頻度が低く、景気状況をすぐに把握することができない。そこで最近では、これらの問題に対してナウキャストと呼ばれる、景気の現状をいち早く予測することができ、景気指数の公表よりも先に景気指数の把握をすることができる取り組みが盛んに実施されている。

またナウキャストの特徴は前述した通り、公表に先立って景気指数を把握することができる点であるが、景気の現状よりも将来の景気状況を把握したい状況の方が多いと考えられる。そこでフォーキャストと呼ばれる景気の現状を予測するのではなく、景気の将来を予測するものを利用することで、早期の経済動向の変動を予測することができるのではないかと考えた。

この問題に対して、本研究の目的は速報性の高いニュースデータを用いて、深層学習モデルの一つであるBERTモデルによる既存の景気指数に代わる新たな景気指数の構築手法の提案である。この本研究で構築する新たな景気指数を作成することで、既存の景気指数と併用して利用し景気状況の理解を促進することができると考えている。また、時系列予測モデルを用いて構築した新たな景気指数に基づく将来の景気予測を行い、早期の経済変動を捉えることを試みる。

2. 関連研究

現在、自然言語処理ではRNNやCNN、BERTなどの深層学習モデルを利用することにより高精度の景気分析を行う研究が行われている。ここでは、本研究に関連が深い景気指数の予測を行う研究について紹介する。

(1) BERTを用いた景気指数の予測

BERTモデルを使用したテキストデータに基づく研究として、[1]ではBERTモデルを使用して経済テキストデータのセンチメント分析(景気状況の極性分析)を行い、[2]におけるRNNモデルを用いた類似研究よりも適合率・再現率・F値が改善されたことが確認できた。これらの研究におけるテキストデータの自動判定技術が、月次での景気状況の指数算出の基礎となっている。

(2) ニュース記事を用いた景気指数の予測

上述した先行研究は経済レポートを用いて景気指数の構築を行っているが、1章で述べた通り経済レポートは月

に一度、四半期に一度の公表頻度であるため、機微な景気指数の推定ができないという課題がある。そこでより更新頻度の高いニュース記事やブログデータなどの大規模なテキストデータを利用することで、リアルタイム性の高い景気指数の推定を行うことが期待される。例えば関ら[3]では新聞記事に着目しドメイン適応や異常検知の技術を用いて新しい景気指数の推定手法を提案した。また五島ら[4]ではCNNモデルを用いて、ロイターニュースデータから景気指数の推定を行った。

そこで本研究では、更新頻度の高いロイターニュースデータに基づく月次の景気指数の推定のみならず日次の景気指数を推定し景気変動を捉える。また、推定した景気指数を用いて景気動向の将来予測を試みる。従来の多くの研究は、推定した景気指数を用いてナウキャストを行うことに焦点が当てられており、将来の景気予測を行う研究は管見の限りなく本研究の独自性となる。

3. 分析対象と提案手法

(1) 要素技術

a) BERT

BERTモデルは、2018年にGoogleが発表したAttentionの構造を持つ自然言語処理モデルで、発表当初はGLUEと呼ばれる英語圏におけるベンチマークで既存のモデルを大きく上回る性能が確認された。

BERTの大きな特徴として、Transformerとは異なるAttention機構である双方向Attentionを採用している点と、事前学習とファインチューニングという二段階の過程を採用している点あげられる。

Attentionとは、与えられた文章から文章中の重要な情報を判断することのできるメカニズムである。また前述の通りBERTモデルの学習には二段階の過程があり、事前学習は大量の文書データにより学習をさせて言語の基礎理解を学習し、ファインチューニングは少量の文書データにより様々なタスクに対応することができる。従って、事前学習済みモデルさえあれば比較的容易に実装することができる手法となる[5]。

本研究では[1]と同様、BERTによる文章分類モデルを用いる。また、本研究で用いる事前学習モデルとして、東北大学の乾研究室によって作成された訓練済み日本語BERTモデル[6]を使用する。

b) 異常検知

異常検知とはデータの中から特異な点を見つけ出す技術であり、文章データや動画データ、また画像データなどを対象とするデータ解析に用いられることが多い[7]。

本研究では使用するロイターニュースにおける日本経済の分野に絞ってデータの抽出を行う。しかし全ての記事の内容を確認しながら抽出したのではなくルールベースによるデータ抽出を行うため、取得データに景気や経済に関連のないデータが混在している可能性がある。そのため本研究では関ら[3]と同様に異常検知に着目し、取得

データにおける本研究と関連のないデータの除去を行い、分析精度向上を試みる。

本研究における異常検知モデルの使用手法について、異常検知モデルの学習データとして景気判断理由集全文を用いて学習を行い、その学習モデルにロイターニュース全文を入力する。つまり、景気判断理由集と類似していないロイターニュースの文章は外れ値(景気に関連していない文章)であると仮定して文章の除去を行う。

異常検知モデルには様々な手法が存在するが、本研究ではIsolation-forest, One-Class SVM, GMM, K-means, PCAの手法を用いて、推定した指数の比較及び適切な異常検知モデルの選定を行う。

(2) 学習データ

本研究では景気指数の構築を行うために、内閣府が公表している景気ウォッチャー調査の景気判断理由集を用いて学習モデルを作成し、ロイターニュースを用いて指数化を行う。以下にそれぞれについて説明する。

a) 景気判断理由集

景気判断理由集とは、内閣府が公表している景気ウォッチャー調査に収録されている、景気の現状と先行きに対する判断の理由及びそれに対する追加説明等について、その主だったもの及び特徴的と考えられるものを取りまとめられたものとなっている。そもそも景気ウォッチャー調査とは、内閣府が毎月実施している調査であり、全国の12地域を対象に、百貨店、スーパーマーケット、コンビニなどの小売店やレジャー業界で働く人など、景気に敏感な職種の約2000人にインタビューし、調査結果を集計、分析したものである。

景気判断理由集は景気の現状に対する判断(3ヶ月前と比べた景気の方性、理由等)と景気の先行きに対する判断(現状と比べた2~3ヶ月前先の景気の方性等)の2つの調査事項があり、それぞれの内容には、地域ごとに5段階(◎, ○, ▲, □, ×)の評価と業種・職種、判断の理由、追加説明及び具体的状況の説明が含まれている。

本研究では、2000年1月から2021年7月までに公表された景気判断理由集に含まれる現状に対する判断(以下、「現状判断」と呼ぶ。)と先行きに対する判断(以下、「先行き判断」と呼ぶ。), また現状判断と先行き判断の両方を結合したものの3種類の学習データを作成し、これらの学習データから得られた3種類の景気指数の比較を行う。

図2に景気判断理由集の例を示す。図2は内閣府ホームページ[8]から引用した。

分野	景気判断理由集	業種・職種	判断の理由	追加説明及び具体的状況の説明
家計動向 関連 (北海道)	◎	商店街(代表者)	販売量の動き	・輸出が順調になってきたことで、果物の出荷量が増えた。人の出入りはままならないが、物流は戻りつつある。
	○	その他専門店【医薬品】(経営者)	お客様の様子	・客の動向を見ると、良くも悪くも新型コロナウイルスに慣れてきている。ただ、感染対策については、普通に対応している人と余りにも過剰になっている人に分かれている。新型コロナウイルス対策が順当に入っている分、客の表情がよく見える。

図2 景気判断理由集の例

b) ロイターニュース

ロイターニュースとは、世界最大の通信社であるトムソン・ロイター社が提供しているニュースであり、為替相場についてのニュースだけでなく、内外の株式、内外の経済指標など、経済動向を把握していく上で欠かせないニュースなど幅広い記事を日々配信している。

本研究ではロイターニュースの日本経済のみに着目し、2010年1月から2023年6月までの33294本のニュースを用いる。またこのデータの前処理として、文章を句点区切り、半角スペースの削除、正規化、全角から半角への統一を行った。その結果、全体の文章数は約39万文となり、その文章に対するラベルは配信日時となっている。

(3) 提案手法

続いて、本研究における提案手法について述べる。以下に、景気指数の算出方法、景気指数の評価方法、算出した景気指数を用いた長期時系列予測の手法、その長期時系列予測モデルの評価方法のそれぞれについて説明する。

a) 指数化の手順

ロイターニュースデータを用いて景気指数の推定を行うために、ここでは指数化を行う手順を述べる。

本研究では2010年1月から2019年12月までの約10年分のロイターニュースデータを用いてその期間の景気指数の推定を行う。本研究では前述した景気判断理由集に含まれる追加説明及び具体的状況の説明を学習データ、景気判断理由集に含まれる5段階の評価を正解ラベルとしてBERTによるファインチューニングを行う。また景気判断理由集に含まれる5段階の評価である◎、○、▲、□、×をそれぞれ4、3、2、1、0として設定した。

以下に学習データと正解ラベルから景気指数の推定を行うための過程について説明する。この過程における各段階を次の(1)～(5)で実装する。

(1) 現状判断、先行き判断、現状判断と先行き判断の両方を結合したものの3種類の学習データに対して、BERTモデルによる5段階分類タスクの学習を行う。本研究では学習データ、検証データ、テストデータの3つのデータを全体の8:1:1の割合で分割し、学習時に設定したハイパーパラメータについて、バッチサイズを4、学習率を $1e^{-5}$ 、最大エポック数を10に設定する。ここで過学習防止のためにEarlyStoppingを設定し、最小lossが5回連続更新できなければ学習を打ち切るよう設定する。

(2) ロイターニュースの文章における景気に関連しない文章を除去するために異常検知モデルを用いてロイターニュース内の異常文の除去を行う。

(3) (1)で得た3種類の事前学習モデルそれぞれに異常文の除去を行ったロイターニュース全文を入力することで、入力文章ごとに5段階(0~4)のスコアを出力させる。

(4) 出力したスコアの平均値を期間ごとに出力し、その算出した値をその期間の予測値として設定する。

(5) 全期間の予測値を正規化し、既存景気指数との比較、

分析を行う。本研究では内閣府が公表している景気動向指数のCIを比較対象とする。

また、以下の図3にこの学習過程の概略図を示す。




図3 景気指数の算出過程

b) 指数の評価

本研究では、構築した景気指数を評価するために内閣府の公表している景気動向指数を利用する。景気動向指数とは総合的な景気局面の判断・予測を行うために複数の指標を組み合わせることで算出した指数である。また景気動向指数は景気変動の方向性を把握するための指数であるDIと、景気変動を量的に把握する指数であるCIで構成される。内閣府では2008年3月までDIを中心に公表していたが「近年、景気変動の大きさや量感を把握することがより重要になっている。[8]」という理由で同年4月からはCIを中心に公表している。本研究ではこのCIを本研究で構築した景気指数との比較対象として設定した。

またCIは基準となる年を100として、現在のCIの値が100より上昇していれば景気は拡張局面に、100より低下していれば景気は後退局面にあることが確認できる。図4、図5にCIの例を示す。図3、図4は内閣府ホームページ[8]から引用した。




図4 CI(先行指数)の推移の例

② 先行指数採用系列の寄与度		令和5(2023)年			
		6月	7月	8月	9月
C1 先行指数		100.0	100.4	100.5	100.3
I1 最終需要財在庫率指数	前月差(ポイント)	-0.1	-0.6	1.1	-0.2
	寄与度(乗サイクル)	0.4	0.6	-0.5	0.2
I2 鉱工業用生産財在庫率指数	前月差(ポイント)	-0.02	-0.05	0.10	0.01
	寄与度(乗サイクル)	-0.3	0.7	-2.7	-1.7
I3 新規求人数(除学卒)	前月比増(%)	0.11	-0.06	0.53	0.51
	寄与度	-2.8	0.9	2.8	-5.7
I4 実質機械受注(製造業)	前月比増(%)	-0.07	-0.09	0.31	-0.09
	寄与度	1.5	-0.2	2.0	-1.7
		0.05	-0.30	0.07	-0.05

図5 CI(先行指数)の例

CIには数ヵ月先の景気の動きを示す先行指数、景気現状を示す一致指数、数ヵ月から半年程度遅れで反応する遅行指数の3つの指数があり、使用用途に応じてこの指数を選択する必要がある。本研究の目的は、時系列予測モデルを用いて将来の景気予測を行い早期の経済変動を捉えることを試みることであるため、先行指数が本研究

に適していると判断できる。しかし先行指数については曖昧な点が多く、先行指数は数ヶ月先の景気の動きを示すがそれがどの程度先の景気状況なのかは明確ではない。本研究ではリアルタイム性を重視しているため、この点が曖昧であると期間ごとの機微な景気動向のズレを把握できなくなる。以上の理由から本研究ではCIの一致指数を利用する。

このCIを用いて2010年1月から2019年12月の期間の構築した景気指数と同じ期間のCIとの相関係数を測定しどの手法の相関係数が高くなるかを判断する。また最も高い相関係数を測定することのできた景気指数を、長期時系列予測を行うためのデータセットとして選定する。

c) 長期時系列予測

構築した2010年1月から2019年12月までの景気指数を用いて景気の将来予測を行うため、本研究では時系列予測モデルを用いて2020年1月から2023年6月までの時系列データ解析を行う。以下の図6に本研究で行う時系列データ解析の手順を示す。




図6 時系列データ解析の手順

まず時系列データに対して定常性検定という時系列データが定常性であるかを検証することを行う。定常性とは時系列データの特性(平均, 分散, 共分散)が時間によらず一定であるという特定のことである。つまり時系列データの構造が時間によって変化せず、過去のデータのパターンが将来も同様に続くとされる。非定常なデータをそのまま分析するとデータの特性が時間の経過とともに変化していくため、過去のデータに基づくモデルが将来的に有効であるという保証が得られない。このような理由から時系列データ解析では一般的にデータを定常化してから分析を行う。以下に弱定常性の定義を示す。

以下の3つの条件を満たすとき、時系列データは弱定常性をもつ。

時系列データ観測値 $y(t)$ の平均値 E は以下のように時間に依存せず、平均値は一定あるいは定常である。

$$E[y(t)] = a \quad (1)$$

$$a = \frac{1}{n} \sum_{i=1}^n y(t_i) \quad (2)$$

時系列データ観測値 $y(t)$ の分散 V は以下のように時間に依存せず、一定あるいは定常である。

$$V[y(t)] = E\{(y(t) - a)[(y(t) - a)]\} = \gamma_0 \quad (3)$$

$$\gamma_0 = \frac{1}{n} \sum_{i=1}^n [y(t_i) - a]^2 \quad (4)$$

時系列データ観測値 $y(t)$ と $y(t-h)$ からなる自己共分散 Cov は以下のように時間に依存せずラグ h のみに依存する。

$$V[y(t), y(t-h)] = E\{(y(t) - a)[(y(t-h) - a)]\} = \gamma_h \quad (5)$$

$$\gamma_h = \frac{1}{n} \sum_{i=h+1}^n \{y(t_i) - a\} \{y(t_{i-h}) - a\} \quad (6)$$

本研究ではADF(Augmented Dickey-Fuller)検定と呼ばれる定常性検定を利用する。ADF検定では時系列データが非定常である。という帰無仮説を検定し、p値が一定の有意水準以下であれば帰無仮説を棄却しデータが定常であると結論づけるものである。一般的にp値が0.01より小さいとき1%有意, 0.05より小さいとき5%有意, 0.1より小さいとき10%有意と呼ばれ、有意の場合は帰無仮説を棄却し対立仮説を採択する。このようにして時系列データが定常であるかを検証することができる。

次に時系列予測モデルの選定とモデルのパラメータの推定を行う。本研究で使用するモデルは、AR, MA, ARMA, ARIMA, SARIMA, SARIMAX, カルマンフィルタ, モンテカルロ粒子フィルタ, 線形回帰, SVR, RFRの11種類を使用する。パラメータの推定は総当たり法と呼ばれる必要となるパラメータの候補を総当たりで探す方法を用いてパラメータの推定を行う。

d) 時系列予測の評価方法

最後に時系列予測を行う際の評価について説明する。評価方法として2020年1月から2023年6月までに公表されたCIと予測した景気指数との評価を行うため、RMSEと呼ばれる評価指標を用いる。RMSEは値が小さい方がよいモデルだと判断できる。またRMSEが小さくなるモデルを利用して、CIと予測指数にどのような局面で差があるか等の分析を行う。

4. 結果

(1) BERTによる分類精度の確認

まず景気判断理由集における現状判断, 先行き判断, 現状判断と先行き判断の両方を結合したものの3種類の学習データに対して、BERTモデルによる5段階分類タスクのファインチューニングを行った際の分類精度を以下の表1に示す。

表1 BERTモデルによる5段階分類タスクの分類精度の比較

データセット	分類精度
現状判断	0.829
先行き判断	0.844
現状判断及び先行き判断	0.830

表1から先行き判断のデータセットで学習を行うことで、他のデータセットよりも予測精度がやや高いことが確認できる。しかしそれぞれのデータによる精度はそこまで離れていないため、この結果のみでは先行き判断が指数算出に適しているとは判断できない。

(2) ロイターニュースに基づく景気指数の結果

a) 構築した景気指数について

ここでは、景気判断理由集の現状判断から構築した景気指数(以下、「Index_Current」と呼ぶ。)と先行き判断から構築した景気指数(以下、「Index_Future」と呼ぶ。), 現状判断及び先行き判断から構築した景気指数 (以下、「Index_Both」と呼ぶ。)について確認する。以下の図7は、それぞれの景気指数の推移を表している。また表2はそれぞれの景気指数における記述統計量を表している。




図7 景気指数の推移

表2 景気指数の記述統計量

	Index_Current	Index_Future	Index_Both
count(期間)	120	120	120
mean	1.722	1.871	1.900
std	0.081	0.061	0.082
min	1.503	1.658	1.620
25%	1.671	1.841	1.844
50%	1.736	1.878	1.909
75%	1.776	1.919	1.945
max	1.889	1.991	2.047

図7は2010年1月から2019年12月における構築した景気指数を表している。この図から Index_Current, Index_Future, Index_Both それぞれのグラフの形状には大きな違いはなく Index_Current の推移が他と比べて全体的に景気指数の値が小さいことが視覚的に判断できる。またこの図では多くの箇所で景気推移の激しい減少が確認できる。例えば、2011年3月付近や2011年11月付近、2012年6月付近などである。2011年3月には東日本大震災の発生、2011年11月付近では16年ぶりに最高値を更新するといった歴史的円安に、また2012年7月付近において世界各国で景気減速となったように、本研究で構築した景気指数の変動は実際に日本国内で起きた出来事と同様のトレンドを持つことが確認できる。

また表2から Index_Current と Index_Future の値は全て、景気判断理由集の0から4の5段階評価の中間値である2を上回っていない。Index_Bothは最大値が2を超えてはいるものの大部分の指数が2を下回っている。この結果は五島ら[4]の結果と同様であり[4]では「中立な

表現のテキストや景気と無関係なテキストが含まれており、日次あるいは月次で集計するとそれらのスコアによってニュース指数の範囲が狭くなることが要因と考えられる。」と考察されている。そこで本研究では、異常検知モデルによる中立な表現の文章や無関係な文章の除去を行い、記述統計量が変化するか確認を行った。以下の表3に本研究で用いる異常検知モデルで構築した景気指数における記述統計量の平均値を示す。

表3 景気指数の記述統計量(異常検知モデル適用)

	Index_Current	Index_Future	Index_Both
count(期間)	120	120	120
mean	1.743	1.876	1.884
std	0.081	0.063	0.083
min	1.533	1.657	1.606
25%	1.689	1.845	1.838
50%	1.752	1.882	1.903
75%	1.800	1.920	1.941
max	1.923	1.99	2.027

結果から表3と表2を比較しても大きな差は確認できないため異常検知モデルによる景気指数の変化は見られず、指数の大部分が2を下回っている理由はニュース記事の配信内容の特徴によるものだと考えられる。このことについては5章で述べる。

b) 構築した景気指数とCIとの比較

次に構築した指数(Index_Current, Index_Future, Index_Both)と景気動向指数のCIの比較を行う。まずは構築した景気指数とCIに相関があるかを確認するため相関係数の算出を行った。以下の表4はCIと構築した景気指数についての相関係数を示し、景気指数については異常検知を行わずに構築した指数と異常検知モデルを使用した場合の指数についての相関係数を示している。

表4 景気指数とCIとの相関係数

	異常検知なし	Isolation_Forest	GMM	k-means	PCA	One-class SVM
Index_Current	0.43	0.44	0.43	0.31	0.44	0.54
Index_Future	0.48	0.51	0.49	0.42	0.53	0.49
Index_Both	0.41	0.43	0.41	0.27	0.46	0.46

表4からK-meansによる異常検知を用いた景気指数は相対的に相関係数が小さくなることが確認できる。またCIと最も相関係数が高くなる手法はIndex_Currentに対してOne-Class SVMによる異常検知を用いた景気指数であることが確認できる。以上のことから、後述する時系列データ解析に用いるデータセットはIndex_CurrentにOne-Class SVMを適用させた景気指数を用いる。

(3) 時系列データ解析の結果

a) ADF検定

本節では、4-2節でCIと最も相関係数の高かったIndex_CurrentにOne-Class SVMを適用させた景気指数を用いて時系列データ解析を行う。まず、景気指数が定常性であるか確認するために行ったADF検定の結果を以下

の図 8 に示す。

```
ADF Statistic: -5.403911
p-value: 0.000003
Critical Values:
1%: -3.487
5%: -2.886
10%: -2.580
```

図 8 景気指数に対する ADF 検定の結果

図 8 より今回の場合は p 値が 0.01 よりも小さいため 1% 有意であり時系列データが非定常であるという帰無仮説が棄却され、使用した景気指数は定常であるということが確認できる。そのため本研究では、データを非定常性から定常性へと変換する工程は行わないものとする。

b) 時系列予測

次に時系列予測モデルにおける学習データを 2010 年 1 月から 2019 年 12 月までの景気指数として設定し、2020 年 1 月から 2023 年 6 月までの月次の景気指数の時系列予測を行った結果を以下に示す。使用した時系列予測モデルは前述した 11 種類のモデルを使用し、比較対象として 2020 年 1 月から 2023 年 6 月までに公表された CI も示す。また以下の図 10 に同期間の日次で予測した結果を示す。




図 9 CI と時系列予測結果の比較



図 10 日次による時系列予測結果

図 10 は日次による予測を行っており、公表されている CI とのデータ数が異なるため同じグラフ上で CI との比較ができなかった。しかし予測した景気指数の形状は、図 9 による予測した景気指数と同様の形状であることが視覚的に確認できる。以降は CI との比較を行うため、図 9 による月次の予測指数を基準として比較を行う。

また図 9 は複数の折れ線グラフが混在しているため、CI と予測結果との RMSE が低い上位 3 モデルのみを抜粋した。その結果カルマンフィルタ、モンテカルロ粒子フィルタ、線形回帰の RMSE が低くなることが確認できた。以

下の図 11 にこの 3 つのモデルによる予測結果と CI の推移を示す。



図 11 CI と時系列予測結果 (RMSE による評価が高い 3 手法) の比較

図 11 から、本研究における予測期間のうち 3 回ほど大きく予測指数が減少している期間が確認できる。1 つ目は 2020/01~2020/10、2 つ目は 2021/01~2021/10、3 つ目は 2022/01~2022/08 の期間である。実際にこの期間に起こった景気状況について調査した結果を以下に示す。

[2020/01~2020/10 の実際に起こった出来事]

コロナウイルス感染症の影響が顕在化し 4 月から初の緊急事態宣言が発出したことでさらに景気状況が後退した。その後緊急事態宣言が解除され社会経済活動の段階的な引き上げが図られた。

[2021/01~2021/10 の実際に起こった出来事]

再び新規感染者数が増加し、2021 年 1 月からは 2 回目の緊急事態宣言が発出された。2021 年 10 月からは全ての都道府県において緊急事態宣言等が解除され景気は持ち直しの動きに。

[2022/01~2022/08 の実際に起こった出来事]

2022 年 1 月からはオミクロン株の感染拡大により感染症による経済影響を与えた。3 月からはまん延防止等重点措置がすべて解除され緩やかに持ち直した。

このことから図 12 による予測結果の変動時期は、上記出来事の期間と同様のタイミングで発生しているため、正確な時系列予測が行えていることが確認できる。

(4) 将来予測の結果

最後にこの三つの予測モデルを利用して今後の景気・経済動向の予測を行った結果を以下に示す。予測した期間は 2023 年 1 月から 2024 年 12 月までであり、三つの予測モデルによる予測値の平均がグラフの推移となっている。




図 12 今後の景気予測

図 12 から 2023 年 1 月を基準とした場合 2023 年 4 月が最も高い景気指数を予測しているが、2023 年 7 月以降は大きく上昇する期間はなく 2024 年 3 月に最も低い景気指数が予測されることが確認できる。もし景気状況が悪くなるとすれば 2023 年 12 月以降であるという予測となるが、実際に 2024 年 1 月には能登半島地震による深刻な被害が被災地域の経済活動を下押ししている状況であるため予測結果はそれほど的外れではないと判断できる。

5. 考察

図 11 における時系列予測結果の考察を行う。本研究ではニュース記事に基づく景気指数による予測指数の変動時期は実際の景気変動時期と同様の動きを示していることが確認できた。しかし図 11 の 2021/01~2021/10 付近と 2022/01~2022/08 付近の期間において予測した景気指数と CI との間に大きく乖離していることが確認できるため、この要因について分析する必要があると考える。まず予測した景気指数と CI との乖離期間を把握しやすくするために、以下の図 13 に CI の値を基準とした予測モデルの推移を作成した。



図 13 CI を基準とした予測モデルの推移

この図から、前述した 2021/01~2021/10 付近と 2022/01~2022/08 付近では予測した景気指数と CI は大きく乖離しており、全体の 6 割近い差がある期間も確認できる。また図 13 の三つの予測モデルにおける予測した景気指数と CI との差が小さい年月(以下、「最小局面」と呼ぶ。)と差が大きい年月(以下、「最大局面」と呼ぶ。)を計算した結果、最小局面が 2020/08, 2020/12, 2023/03, 最大局面が 2021/06, 2021/07, 2021/08 と出力された。




図 14 CI との最大局面と最小局面

最大局面について分析するため、最大局面の期間のニュース記事全文章から TF-IDF を算出しその期間の重要単語の抽出を行い、その重要単語が予測指数にどう影響を与えているか分析を行う。下表は最大局面における TF-IDF の高い重要単語 (一部抜粋)とその重要単語の極性値(ポジティブ:1~ネガティブ:-1)が記されている。

表 5 最大局面の全記事による TF-IDF 値(降順)と極性実数値

2021_06			2021_07			2021_08		
word	tfidf	polarity	word	tfidf	polarity	word	tfidf	polarity
自殺	1	-0.594225	別荘	1	NaN	謙虚	1	-0.301626
協議	1	-0.190272	少し	1	NaN	全文	1	-0.132873
油断	1	-0.604745	つらい	1	NaN	彼女	1	NaN
それ	1	NaN	仕事	1	-0.958117	和田康彦	1	NaN
病床	1	-0.754275	神宮外苑	1	NaN	要請	1	-0.273666
国会	0.92137724	-0.340642	和田康彦	1	NaN	愚問	1	-0.99427
要因	0.88716028	-0.29698	先取り	1	-0.136031	顧客層	1	NaN
忍耐強い	0.87146374	NaN	自分	1	NaN	相手	1	NaN
が	0.8493031	NaN	心配	1	-0.999307	ビークラフ	0.82822791	NaN
正式	0.84341109	-0.574927	ざやることに	1	NaN	主張	0.80706639	-0.722548
170	0.82359401	NaN	そう	1	NaN	イロヒュー	0.80364763	NaN
明言	0.81720828	-0.034884	17万円	1	NaN	記者	0.7849789	-0.400228
eu	0.80372129	NaN	引越	1	NaN	再選	0.77118684	-0.104438
当番者	0.80290005	NaN	もん	1	NaN	内容	0.76610557	-0.850617
ロードマップ	0.787487	NaN	自分	0.91790877	NaN	見もの	0.76031087	NaN
付	0.78195942	NaN	フット	0.91530803	NaN	情報	0.75930319	-0.58659
それら	0.78070872	NaN	休息	0.87639432	-0.416126	安全保障	0.75448693	NaN
4期	0.77812013	NaN	心配	0.85410754	-0.999307	語気	0.747867	-0.27441
問題	0.76840359	-0.716755	杉本	0.82225768	NaN	600億円	0.747867	NaN

表 6 最大局面における極性が正の割合(上位 40 単語)

	局面	正の割合
	最大局面	2021/06
2021/07		2/40
2021/08		2/40
最小局面	2023/3	5/40

重要単語の極性値を算出した理由として重要単語が一般的にポジティブ、またはネガティブのどちらの意味を持つのかを判断するためであり、元東工大の高村教授が公開している単語感情極性対応表[11][12]を使用した。

表 5 から最大局面の上位重要単語には極性が負の単語が多く存在しており、このことが図 11 における CI の数値は高いにも関わらず予測指数が低くなっている要因の一つだと判断できる。また表 6 は重要単語の上位 40 単語のうち極性が正である割合を示したものとなる。最大局面は最大で 2 単語のみ極性が正であることが確認できた。また比較対象として CI と予測指数の両方の数値が高い 2023/03(最小局面)における極性が正である割合を出力した結果、5 単語の極性が正であることが確認できた。

このことについて、2010 年 1 月から 2019 年 12 月の期間の学習データにおいても同様のことが言えるか確認す

るため、この期間においてCIが高いが景気指数が低くなる月と、CIも景気指数も高い月をそれぞれ3期間ずつ抽出した。結果、CIが高いが景気指数が低くなる月は2018年11月、2018年3月、2019年3月、CIと景気指数も高い月は2013年11月、2012年3月、2014年4月となった。以下の表7はそれぞれの期間における極性が正の割合を示し、表7における最小局面はCIと景気指数のそれぞれ数値は全体の50%であり、かつCIと景気指数の差が小さい期間の上位3つを示している。

表7 2010/01～2019/12における極性が正の割合(上位40単語)

	局面	正の割合
最大局面	2018/11	3/40
	2018/07	1/40
	2019/03	1/40
最小局面	2013/10	6/40
	2012/03	3/40
	2014/04	4/40

表7から、表6の結果と同様に、最大局面は最大で3単語のみ極性が正であることが確認でき、また比較対象である最小局面における極性が正である割合について、最大6単語の極性が正であることが確認できた。

このことから本研究で構築した景気指数はニュース記事における重要単語の極性情報の影響をやや受けやすい傾向にあることが確認できる。またCIは高いのにも関わらず予測した景気指数が低い箇所が複数見られたのは、ニュース記事の特徴と繋がりがあつたためだと考えられる。一般的に世間の明るい話題よりも暗い話題の方が話題に取り上げられるケースの方が多い印象がある。その理由として自然災害の多い日本では実際に起きた自然災害のニュース等から対策を講じる人が多く、より長く生存したいという考えから暗い話題に触れる機会が多くなる。このことは自然災害だけでなく自分も巻き込まれる可能性のある事件や事故も同様のことが言える。そのためニュース記事は暗い話題に需要があると考えられ、本研究におけるニュース記事を用いて構築した景気指数は基本的にCIと同様の動きであるが、暗い話題のニュースに敏感であり景気悪化の時期は長期的に指数が減少する特徴があると考察できる。

6. おわりに

ニュースデータを用いて深層学習手法による既存の景気指数に代わる新たな景気指数の構築手法の提案を行った。また時系列予測モデルを用いて構築した景気指数を用いた将来の景気予測を行い経済変動の分析を行った。

関連研究では景気の現状をいち早く予測する取り組みを行っているものが多かったが、本研究では将来の景気予測に注目し2024年12月までの景気予測を行うことができた。また本研究では速報性の高い景気指数の構築を行うことが研究目的の一つであり日次指数と月次指数を構築しそれぞれの指数に対して時系列予測を行ったが、日次指数と月次指数やCIとの時間軸のスケールが異なることによって、それぞれの時系列予測結果の比較を行うことができなかった。これを実現することでより細かいスケールにおける分析を行うことができると考えられる。

謝辞

本研究を進めるにあたり、熱心なご指導を頂きました法政大学大学院応用情報工学先行藤井章博教授に感謝いたします。様々な提案をしていただき、研究活動を支えてくださった藤井研究室の皆様にも感謝いたします。

参考文献

- 青嶋智久, 中川慧: 日本語BERTモデルを用いた経済テキストデータのセンチメント分析, 第33回人工知能学会全国大会 (JSAI 2019), pp.1-3 (2019).
- 山本裕樹, 松尾豊: 景気ウォッチャー調査の深層学習を用いた金融レポートの指数化, 第30回人工知能学会全国大会 (JSAI 2016), pp.1-4 (2016).
- 関和宏, 生田祐介, 松林洋一: ニュース記事に基づく景気指数S-APIRの開発, 第24回人工知能学会金融情報学研究会 (JSAI 2020), pp.1-8 (2020).
- 五島圭一, 高橋大志, 山田哲也: 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, No.3 (2019).
- 近江崇宏, 金田健太郎, 森長誠, 江間見亜利: BERTによる自然言語処理入門-Transformersを使った実践プログラミング-, 株式会社オーム社, pp.24-25, pp.30-41 (2021).
- TOHOKU NLP GROUP: Pretrained Japanese BERT models released / 日本語 BERT モデル公開, 東北大学, 2019-12-13, <https://www.nlp.ecei.tohoku.ac.jp/news-release/3284/>
- 曾我部東馬, 曾我部完: Pythonによる異常検知, 株式会社オーム社, pp2, pp 140-218, (2021).
- 内閣府: 景気動向指数: 内閣府 Cabinet Office, https://www.esri.cao.go.jp/jp/stat/di/menu_di.html.
- 高村大也, 乾孝司, 奥村学: スピンモデルによる単語の感情極性抽出, 情報処理学会論文誌ジャーナル, Vol.47 No.02 pp. 627--637 (2006).
- Hiroya Takamura, Takashi Inui, Manabu Okumura: Extracting Semantic Orientations of Words using Spin Model, In Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL2005), pages 133--140 (2005)