

街角コメントは経済変動を予測するか？ - 埋め込み表現を活用したアプローチの提案とその応用 -

穴戸直樹¹ 渡部敏明¹ 吉田光男² 樗惇志¹

¹ 一橋大学大学院 ソーシャル・データサイエンス研究科 ² 筑波大学 ビジネスサイエンス系
{dm240012@g,t.watanabe@r,a.keyaki@r}.hit-u.ac.jp mitsuo@gssm.otsuka.tsukuba.ac.jp

概要

近年、マクロ経済分析においてテキストを定量化し経済変数との関係进行分析することが盛んに行われているが、従来のテキスト定量化手法では文脈情報等が捨象されるという課題があった。本研究ではファクターモデルの枠組みで埋め込み表現を活用することで、従来手法で捨象されていたテキスト情報を抽出する方法を提案する。景気ウォッチャー調査のコメントを対象にモデル化を行い、それがインフレ率の予測において従来手法より高い予測精度を達成することを示した。さらに、有効求人倍率の予測に応用し、提案手法の下で同調査が経済変動を広く捉える情報源となりうる可能性を示唆した。

1 はじめに

マクロ経済分析において、テキストは経済指標では捕捉しきれない経済主体の心理状態の把握やナウキャストニング¹⁾の情報源として有用である。

日本の経済分析に活用される代表的なテキストソースとして、内閣府が実施する「景気ウォッチャー調査」がある。同調査は景気動向に敏感な職業に従事する全国の人々から毎月コメントを収集しており、経済政策立案や投資判断などに幅広く活用されている。景気ウォッチャー調査のコメントを定量化し、経済分析に活用する研究は数多く行われてきた [1, 2]。

テキストを定量化し、経済分析に活用する方法は広く用いられてきた [3] が、その定量化の過程でテキストに含まれる文脈情報やニュアンスが捨象されるという課題があった。近年、自然言語処理技術の発展により、文脈情報を保持したままテキストを埋め込み表現 (embedding) に変換することが可能となった。埋め込み表現を用いれば、情報を捨象して

しまう従来のテキスト定量化手法を用いずとも、テキストを数値化することが可能である。しかしながら、埋め込み表現は高次元ベクトルであり、サンプルサイズが限られる経済分析において埋め込み表現をそのまま学習に用いると過学習に陥るという課題が想定される。

本研究では、経済変数の予測精度向上を目指し、景気ウォッチャー調査のコメントの埋め込み表現を経済分析で活用する手法を提案する。複数のドメインにおける実証分析の結果、提案手法は従来のテキスト定量化手法を用いた場合よりも高い予測精度を達成することを示した。

2 関連研究

景気ウォッチャー調査は、内閣府が2000年1月から毎月実施している調査である²⁾。

景気ウォッチャー調査のコメントを活用した研究は数多く行われてきた [1, 2, 4, 5]。同調査のコメントを定量化した代表的な指標として、物価センチメント指数 (Price Sentiment Index; PSI) [1, 2] がある³⁾。中島ら [2] は、PSIがインフレ率予測において有用な情報を含むことを実証している。

ただし、PSIをはじめとする従来のテキスト定量化手法にはいくつかの課題が存在する。第一に、テキスト定量化の過程の中で情報が捨象されてしまう点である。第二に、定量化の基準となる辞書の構築には専門知識と労力が必要であり、また分析者の恣意性が混入しうるリスクも存在する点である。

上記の課題を克服する手法として、近年、埋め込み表現の活用が目が集まっている [6, 7, 8, 9]。埋め込み表現の活用により、定量化のための分類基準などを用いずに、従来手法では捉えきれなかった文脈情報やニュアンスを保持したままテキストを数値化することができる。

2) 景気ウォッチャー調査の詳細は付録 B を参照。

3) PSI の計算方法は付録 C を参照。

1) 経済指標の発表を待たずに経済状態を推定すること。

近年、金融市場を対象にいくつかの研究が埋め込み表現を用いた分析を行っている [6, 7, 8]。しかしながら、それらの研究の多くは十分なサンプルサイズを前提とし、機械学習といった複雑なモデルを用いている。経済変数は月次・四半期など低頻度でしか観測されないため、同様の手法を適用するとパラメータ数がサンプルサイズを大幅に超え、深刻な過学習が生じる。そのため、サンプルサイズが限られた経済分析において埋め込み表現を活用する方法の開発が求められてきた。

3 提案手法

3.1 モデリングの方針

埋め込み表現の取得には、テキストからより多くの文脈情報やニュアンスを取得できるという点から、事前学習済みモデルを用いる⁴⁾。

事前学習済みモデルから取得される埋め込み表現は数百次元から数千次元の高次元ベクトルであり、サンプルサイズが限られる経済分析では過学習を防ぐため次元削減が必要となる。本研究では、埋め込み表現の特性に基づきファクターモデルによる次元削減を採用する。埋め込み表現は各次元の解釈は困難で、ベクトル全体で意味を成すと考えられており、ファクターモデルによりベクトル全体の共変動構造を圧縮して低次元の表現を得ることが適切であると考えたためである。なお、この選択の妥当性は付録 A において実証的に検証している。

3.2 ファクターモデル

景気ウォッチャー調査では、毎月ごと複数人の回答者からコメントが収集される。各コメントを事前学習済みモデルにより p 次元の埋め込み表現に変換すると、時点 t における回答者 i のコメントに対応する埋め込み表現 $x_{i,t} \in \mathbb{R}^p$ が得られる。

本研究では、各回答者のコメントの背後に、コメントを生み出す背景にある共通の経済状況が存在すると仮定する。そして各回答者が経済状況に対してそれぞれの感応度でコメントを生成していると考え、以下のファクターモデルを定式化する。

$$x_{i,t} = \Lambda_i f_t + e_{i,t}, \quad i = 1, \dots, N_t, \quad t = 1, \dots, T. \quad (1)$$

4) 時系列予測においてある時点では知り得なかった将来の情報事前学習済みモデルに含まれる可能性があるという先読みバイアスがよく問題視される [9] が、特定の経済指標の将来値を学習させていない場合、影響は軽微であると考えられる。

ここで、 $f_t \in \mathbb{R}^r$ は時点 t における共通ファクターベクトル、 $\Lambda_i \in \mathbb{R}^{p \times r}$ は回答者 i のファクターローディング行列、 $e_{i,t}$ は誤差ベクトル、 N_t は時点 t における回答者数、 T はサンプルサイズである。

3.3 推定手順

まず、抽出したファクターを分析対象となる経済変数の説明変数として後ほど利用することから、すべての景気ウォッチャー調査のコメントの中から分析対象に関連するコメントのみを収集する。次に、事前学習済みモデルを用いて、時点 t の収集された各コメントを p 次元の埋め込み表現に変換する。

式 (1) のモデルに基づき、共通ファクターを推定するため、Westerlund [10] が提案した Cross-section average-based Principal Components (CPC) を適用する。この方法では、各時点の埋め込み表現の平均ベクトル $\bar{x}_t = N_t^{-1} \sum_{i=1}^{N_t} x_{i,t}$ を算出する。埋め込み表現の平均ベクトルに対して標準化処理を行った後、主成分分析法を用いて共通ファクター f_t を推定⁵⁾する。CPC の利点は、コメント数 N が十分大きければ、サンプルサイズ T が限られる状況でも漸近的に望ましい推定を行うことが出来る [10] ことにある⁶⁾。ファクター数 r の推定には Onatski の方法 [11] を用いる。

4 実証分析

4.1 インフレ率を対象にした実証分析

本分析の目的は、景気ウォッチャー調査の物価に関するコメントの埋め込み表現から抽出されたファクターが、インフレ率の予測において経済変数を補完する独自情報を持つかを検証するとともに、従来手法である PSI を用いた場合よりも予測精度が向上するかを検証することにある。

モデル PSI を用いてインフレ率予測を行った中島ら [2] の研究を参考に、1 期先インフレ率の予測モデルを構築する⁷⁾。

$$\pi_{t+1} = \alpha + \beta \pi_t + \gamma' f_t + \delta' Z_t + \varepsilon_{t+1} \quad (2)$$

$$x_{i,t}^{price} = \Lambda_i f_t + e_{i,t} \quad (3)$$

5) ファクターの推定には回転不定性の問題があるが、予測が目的であるため、特別な考慮は必要ない。

6) ただし、主要な仮定として各コメントは共通ファクターを除き独立であることなど [10] が求められる。

7) 変数の定常性は、定数項とトレンドのある ADF (Augmented Dickey-Fuller) 検定により事前に確認している。

ここで、 π_t は時点 t のインフレ率（消費者物価指数（総合除く生鮮・エネルギー，消費税率引き上げの影響除く）前年同期比）， $x_{i,t}^{price}$ は個人 i の時点 t の物価関連コメントの埋め込み表現， f_t は時点 t のファクターベクトル， Z_t は経済変数ベクトル（実質実効為替レート（前年同期比），需給ギャップ）， ε_{t+1} は誤差項である。

分析方法 1,265 件のデータをアノテーションして FinBERT-Ja⁸⁾ (FinBERT) [12] をファインチューニングし，物価関連コメントの分類モデルを構築することで対象となるコメントだけを抽出する。埋め込み表現の取得では，FinBERT, ModernBERT-Ja⁹⁾ (ModernBERT), text-embedding-3-large-Ja¹⁰⁾ (OpenAI) の 3 つをそれぞれ使用する。データの頻度は四半期単位¹¹⁾となっており，回帰モデルの係数の推定には，2001 年第 1 四半期から 2025 年第 2 四半期までのデータを用いる。予測精度の評価を行うときは，拡張ウィンドウ方式で 2012 年第 1 四半期から 2025 年第 2 四半期までの各四半期のインフレ率をその 1 四半期前までのデータを用いて逐次的に予測を行う。式 (2) で用いられるマクロ経済変数からなるモデル (Baseline)，及び Baseline に PSI を追加したモデル (PSIm) と比較を行う。なお，短期的な予測だけでなく長期的な予測でも提案手法が有効か調査するため，1 期先予測モデルをベクトル自己回帰 (VAR) モデルに拡張し，その VAR モデルを利用して 4 期先予測まで実施する¹²⁾。予測誤差は平均二乗誤差 (RMSE) で評価し，Diebold-Mariano (DM) 検定 [13] と，Model Confidence Set (MCS) 検定 [14] を用いて予測精度の差が統計的に有意であるかを検定する。

分析結果 1 期先インフレ率予測モデルの推定結果を表 1 に示す¹³⁾。ファクター数は Onatski の方法で 1 が選ばれ，そのファクターの係数は有意水準 1% で統計的に有意であった¹⁴⁾。これは抽出されたファクター¹⁵⁾がマクロ経済変数では捕捉できないインフレ率予測に有用な情報を含んでいる可能性がある。

8) <https://huggingface.co/izumi-lab/bert-base-japanese-fin-additional>

9) <https://huggingface.co/sbintuitions/modernbert-ja-3-10m>

10) <https://openai.com/index/new-embedding-models-and-api-updates/>

11) 月次単位のデータは四半期単位で平均化する。

12) ラグ数は BIC をもとに算出する。

13) 表 1 は FinBERT [12] を用いたときの推定結果だが，他の事前学習済みモデルを用いた場合でも類似した結果となる。

14) 実質賃金指数（前年同期比），WTI 原油価格（前年同期比）をモデルに追加しても係数の有意性は変わらない。

15) ファクターの時系列プロットは付録 D を参照。

表 1 インフレ率モデルの推定結果（外部変数は除く）

変数	提案手法	PSIm	Baseline
インフレ率	0.837*** (0.046)	0.839*** (0.042)	0.967*** (0.037)
ファクター (FinBERT)	-0.015*** (0.003)		
PSI		0.253*** (0.062)	
修正済み決定係数	0.942	0.934	0.923

*** は 1% 水準で有意。括弧内は

Heteroskedastic and Autocorrelation Consistent (HAC) 標準誤差。

ることを示唆する。さらに，提案手法のモデルの修正済み決定係数が最も高く，提案手法のモデルの説明力が高いことが示された。

次に各モデルのインフレ率の予測結果を表 2 に示す。金融テキストで事前学習された FinBERT から得られた埋め込み表現を活用したファクターモデルが最も高い精度を記録した。この結果は提案手法において，ModernBERT や OpenAI といった一般に埋め込み表現としての精度が良いモデルを用いるよりも，ドメイン特化の言語モデルを使用することの重要性を示唆するものである¹⁶⁾。

Baseline や PSIm の予測精度と比較すると，埋め込み表現から抽出されたファクターが短期的にも長期的にも一貫して予測精度を改善させていた。統計的にもその改善は認められ，MCS 検定の結果，信頼水準 75% で 3 つの事前学習済みモデルから得られた埋め込み表現を用いたモデルは最良モデル群として選ばれている。さらに，DM 検定により，最も精度が高い FinBERT を用いたファクターモデルは Baseline よりも，すべての予測期先において有意水準 10% で予測精度を有意に上回った。そのうえで，PSIm との予測精度比較を行った結果，1 期先予測において有意水準 10% で提案手法が予測精度を有意に上回ることが示された。これは提案手法が従来手法よりも予測の観点において有効である可能性を示すものである。

4.2 労働市場を対象にした実証分析

第 4.1 節の結果より，提案手法が従来手法よりもテキストを経済変数予測に有効活用する方法であることが示された。本節では提案手法を応用し，景気ウォッチャー調査のコメントが物価以外の経済変数予測においても有効かという問いに挑む。従来，景気ウォッチャー調査のコメントは主にインフレ予測

16) これは Loughran・McDonald [15] などの経済分析でのテキスト活用に関する研究の主張と類似する。

表2 インフレ率予測：予測期先別 (RMSE)

モデル	1 期先	2 期先	3 期先	4 期先
FinBERT	0.384 ^{††} _{§‡}	0.611 ^{††} _§	0.850 ^{††} _§	1.024 ^{††} _§
ModernBERT	0.397 [†]	0.641 ^{††}	0.883 ^{††}	1.052 ^{††}
OpenAI	0.400 [†]	0.643 ^{††}	0.877 ^{††}	1.036 ^{††}
PSIm	0.411 [†]	0.666 ^{††}	0.903 ^{††}	1.065 ^{††}
Baseline	0.439	0.746	1.026	1.214 [†]

†, †† は、MCS においてそれぞれ信頼水準 90%, 75% で最良モデル群に含まれたことを表す。§, ‡ は DM 検定においてそれぞれ Baseline, PSIm の予測精度を有意水準 10% で有意に上回ることを表す。

の文脈で分析されてきたが、他のマクロ経済変数、特に労働市場を対象にした研究は極めて限られている。本節では提案手法を用いて、同調査の雇用に関するコメントが有効求人倍率の予測においても有用であるかを検証する。

モデル 中島・渡部 [16] を参考に、1 期先有効求人倍率（前年同期差）の予測モデルを構築する¹⁷⁾。

$$\Delta E_{t+1} = \alpha + \beta \Delta E_t + \gamma' f_t + \delta' Z_t + \varepsilon_{t+1} \quad (4)$$

$$x_{i,t}^{emp} = \Lambda_i f_t + e_{i,t} \quad (5)$$

ここで、 ΔE_t は時点 t の有効求人倍率（パートを含む）の前年同期差、 $x_{i,t}^{emp}$ は個人 i の時点 t の雇用関連コメントの埋め込み表現、 f_t は時点 t のファクターベクトル、 Z_t は経済変数ベクトル（需給ギャップ、米国 PMI（前年同期比）、実質賃金指数（前年同期比））、 ε_{t+1} は誤差項である。

分析方法 第 4.1 節の分析方法と同様にして、864 件のアノテーションデータを用いて雇用関連コメントの分類モデルを構築し、コメントを抽出する。第 4.1 節の分析結果より、埋め込み表現の取得は FinBERT を用いる。係数推定および予測精度の評価は、第 4.1 節の分析方法と同じ設定とする。式 (4) で用いられるマクロ経済変数からなるモデル (Baseline)、及び Baseline に日本銀行短観の雇用人員判断 DI（全規模合計）¹⁸⁾ を追加したモデル（日銀短観 m）との比較を行う。

分析結果 1 期先有効求人倍率予測モデルの推定結果を表 3 に示す。ファクター数は Onatski の方法で 2 が選ばれ、第 1 ファクターの係数は有意水準 1% で統計的に有意であった。これは抽出された

17) 変数の定常性は定数項とトレンドのある ADF 検定により事前に確認している。

18) 日銀短観の雇用人員判断 DI：日本銀行が企業にアンケートを取ることで得られた雇用人員について「過剰」と回答した割合から「不足」と回答した割合を差し引いた値。標準化処理をしたのち、前年同期差を取った値を分析では用いる。

表3 有効求人倍率モデルの推定結果（外部変数は除く）

変数	提案手法	日銀短観 m	Baseline
有効求人倍率 (前年同期差)	0.619 ^{***} (0.089)	1.048 ^{***} (0.081)	0.823 ^{***} (0.077)
第 1 ファクター (FinBERT)	-0.004 ^{***} (0.001)		
第 2 ファクター (FinBERT)	0.000 (0.000)		
日銀短観 (前年同期差)		0.097 ^{***} (0.028)	
修正済み決定係数	0.925	0.912	0.899

*** は 1% 水準で有意。括弧内は HAC 標準誤差。

表4 有効求人倍率予測：予測期先別 (RMSE)

モデル	1 期先	2 期先	3 期先	4 期先
提案手法	0.057 ^{††} _{§‡}	0.107 ^{††} _{§‡}	0.144 ^{††} _{§‡}	0.170 ^{††} _{§‡}
日銀短観 m	0.062 ^{††}	0.121 ^{††}	0.163 ^{††}	0.183 ^{††}
Baseline	0.064 ^{††}	0.122 ^{††}	0.159 ^{††}	0.178 ^{††}

†† は MCS において信頼水準 75% で最良モデル群に含まれたことを表す。§, ‡ は DM 検定においてそれぞれ Baseline, 日銀短観 m の予測精度を有意水準 10% で有意に上回ることを表す。

ファクター¹⁹⁾がマクロ経済変数では捕捉できない有効求人倍率の予測に有用な情報を含んでいる可能性を示唆する。また、提案手法のモデルの修正済み決定係数が最も高く、提案手法のモデルの説明力が高いことが示された。

次に各モデルの有効求人倍率モデルの予測結果を表 4 に示す。埋め込み表現から抽出されたファクターが短期的にも長期的にも予測精度を改善させている。MCS 検定においては信頼水準 75% でモデル間の予測精度に関する有意差は検出されなかったが、DM 検定を実施した結果、提案手法のモデルは Baseline よりも、すべての予測期において有意水準 10% で予測精度を有意に上回り、日銀短観 m を用いた場合と比較しても、2・3 期先予測において有意水準 10% で予測精度を有意に上回った。

5 おわりに

本研究では、景気ウォッチャー調査のコメントの埋め込み表現をファクターモデルの枠組みで活用する手法を提案した。提案手法は従来のテキスト定量化手法よりも高い予測精度を達成し、回帰モデルの説明力も向上することが確認された。また、景気ウォッチャー調査のコメントが複数の経済変動を捉える情報源となる可能性があることを示した。提案手法により、景気ウォッチャー調査のコメントの活用がさらに広がることが期待される。

19) ファクターの時系列プロットは付録 D を参照。

6 謝辞

本論文執筆にあたり、一橋大学ソーシャル・データサイエンス研究科の植松良公准教授、および同大学経済研究所の中島上智教授には有益なコメントをいただいた。また同研究室のメンバーにも感謝を申し上げたい。

本研究の一部は、JSPS 科研費（基盤研究 (B) (課題番号: 23H03686, 25K03178), 基盤研究 (C) (課題番号: 24K15066)), 令和 7 年度次世代人工知能技術等研究開発拠点形成事業「生成 AI モデルの透明性・信頼性の確保に向けた研究開発拠点形成」, 株式会社デンソーアイティラボラトリとの共同研究の支援による。ここに記して謝意を表す。

参考文献

- [1] 大高一樹, 菅和聖. 機械学習による景気分析—『景気ウォッチャー調査』のテキストマイニング—. 日本銀行ワーキングペーパーシリーズ, No. 2018-J-8, 2018.
- [2] 中島上智, 山縣広晃, 奥田達志, 香月信之輔, 篠原武史. 景気ウォッチャー調査のテキスト分析からみた企業の短期インフレ予想. 日本銀行ワーキングペーパーシリーズ, No. 2021-J-12, 2021.
- [3] 新谷元嗣. テキスト情報と機械学習を用いた景気動向分析. 経済分析, No. 208, pp. 128–145, 2023.
- [4] 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, 2016.
- [5] 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, pp. 1–41, 2019.
- [6] Luca Barbaglia, Sergio Consoli, and Susan Wang. Financial forecasting with word embeddings extracted from news: a preliminary analysis. In *Joint european conference on machine learning and knowledge discovery in databases*, pp. 179–188. Springer, 2021.
- [7] Yifei Chen, Bryan T. Kelly, and Dacheng Xiu. Expected returns and large language models. *Available at SSRN*, 2022. SSRN 4416687.
- [8] Eghbal Rahimikia and Fergus Drinkall. Re(visiting) large language models in finance. *Available at SSRN*, 2024. SSRN 4963618.
- [9] Douglas K. Godoy de Araujo, Nikola Bokan, Francesco A. Comazzi, and Michele Lenza. Word2prices: Embedding central bank communications for inflation prediction. BIS Working Papers No. 1253, Bank for International Settlements, 2025.
- [10] Joakim Westerlund. A cross-section average-based principal components approach for fixed-t panels. *Journal of Applied Econometrics*, Vol. 35, No. 4, pp. 776–785, 2020.
- [11] Alexei Onatski. Determining the number of factors from empirical distribution of eigenvalues. *Review of Economics and Statistics*, Vol. 92, No. 4, pp. 1004–1016, 2010.
- [12] Masahiro Suzuki, Hiroki Sakaji, Masanori Hirano, and Kiyoshi Izumi. Constructing and analyzing domain-specific language model for financial text mining. *Information Processing & Management*, Vol. 60, No. 2, p. 103194, 2023.
- [13] Francis X. Diebold and Roberto S. Mariano. Comparing predictive accuracy. *Journal of Business & Economic Statistics*, Vol. 13, pp. 253–263, 1995.
- [14] Peter Reinhard Hansen, Asger Lunde, and James M. Nason. The model confidence set. *Econometrica*, Vol. 79, No. 2, pp. 453–497, 2011.
- [15] Tim Loughran and Bill McDonald. When is a liability not a liability? textual analysis, dictionaries, and 10-Ks. *The Journal of Finance*, Vol. 66, No. 1, pp. 35–65, 2011.
- [16] 中島上智, 渡部敏明. 時変多変量自己回帰モデルを用いた日本の輸出量の計量分析. 経済研究, Vol. 68, No. 3, pp. 237–249, 2017.
- [17] 鈴木雅弘, 坂地泰紀. 景気ウォッチャー調査のデータセット構築と物価センチメント分析. 人工知能学会第二種研究会資料, No. FIN-034, pp. 109–115, 2025.

A モデル選択の妥当性検証

第 3.1 節でスパースモデルではなくファクターモデルを採用すると述べたが、その選択の妥当性を実証的に検証する。

ファクターモデル以外にスパースモデルを用いたモデリングも考えられるが、スパースモデルは埋め込み表現の活用方法としては不適当である。なぜならば、スパースモデルが有効に機能するのは、多くの説明変数の中で目的変数と関連しているのは少数の変数のみである場合であり、埋め込み表現に対してスパースモデルを適用することは、その意味論的特性と根本的に矛盾するからである。表 5 に、経済変数のみを用いたモデル、スパースモデル (Lasso)、ファクターモデルの予測精度を比較した結果を示す。埋め込み表現を用いているにも関わらず、スパースモデルでは予測精度の改善が見られなかった。この結果は、埋め込み表現を単に用いるだけでは予測改善に結びつかず、ファクターモデルの枠組みでモデリングすることの重要性を示している。

表 5 モデル間の予測精度比較：1 期先予測 (RMSE)

	Baseline	Lasso	提案手法
インフレ率	0.439	0.433	0.384 ^{††}
有効求人倍率	0.063 ^{††}	0.089	0.057 ^{††}

予測値はそれぞれ 1 期先予測モデルから取得。

^{††} は MCS において信頼水準 75% で最良モデル群に含まれたことを表す。

B 景気ウォッチャー調査の詳細

景気ウォッチャー調査は、内閣府が 2000 年 1 月から毎月実施している調査である。タクシー運転手、小売店店員、飲食店経営者など、景気動向を敏感に反映する職業に従事する全国約 2,000 人を対象としている。本調査では、景気の現状および先行きに関する 5 段階評価とその判断理由のコメントが収集される。各回答者は独立にコメントを記述するため、第 3.3 節で述べたクロスセクション平均に基づく推定的前提を満たすと考えられる。表 6 に景気ウォッチャー調査のコメント例を示す。

表 6 景気ウォッチャー調査のコメント例

景気評価	業種	コメント
良い	不動産	マンションの売れ行きが良い。
横ばい	職業安定所	求人数は今後も変化しない。
悪い	輸送業	売上が下がり、経営が厳しい。

C PSI の詳細

PSI は、各コメントを「物価上昇」「物価横ばい」「物価下落」の 3 カテゴリに分類し、以下の式で算出される。

$$PSI = \frac{a - b}{a + b + c} \quad (6)$$

ここで、 a は「物価上昇」を示すコメント数、 b は「物価下落」を示すコメント数、 c は「物価横ばい」を示すコメント数である。

一般に PSI のデータは公開されていないため、大高・菅 [1] を参考に FinBERT で物価コメントに関する分類モデルを作成 [17] し、PSI の作成を行った。

D 時系列プロット

図 1 に、物価に関するコメントから抽出されたファクター、インフレ率、および PSI の時系列推移を示す。物価に関するコメントの埋め込み表現から抽出されたファクターが、物価動向の変動を全体的に捉えていることが視覚的にも確認できる。特に近年の物価変動を PSI は追従できていないのに対し、ファクターはインフレ率の変動を良く捉えている。



図 1 インフレ率・ファクター・PSI の時系列推移

図 2 に、雇用に関するコメントから抽出されたファクター、有効求人倍率、および日銀短観の時系列推移を示す。こちらも雇用に関するコメントの埋め込み表現から抽出されたファクターが、有効求人倍率の変動を全体的に捉えていることが視覚的に確認できる。特に図 2 からは日銀短観よりも先行性があることが見て取れる。

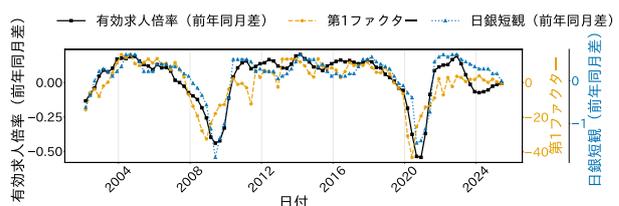


図 2 有効求人倍率 (前年同期差)・ファクター・日銀短観 (前年同期差) の時系列推移