

ベイズ構造時系列モデルを用いた COVID-19 が
 教員の新年度準備への関心に与えた影響の定量化に関する検討
 A Note on Quantifying the Impact of COVID-19 on School Teachers' Interest in Preparing for
 the New Fiscal Year Using Bayesian Structural Time Series Model

安部 洋平¹⁾ 原川 良介¹⁾ 飯坂 正樹²⁾ 岩橋 政宏¹⁾
 Yohei Abe Ryosuke Harakawa Masaki Iisaka Masahiro Iwahashi

概要

COVID-19 への対策のため、2020 年に行われた全国的な学校の休校措置は、教員の業務内容や意識に変容をもたらした。本研究では教員向けソーシャルメディア上のテキストデータを活用し、COVID-19 に伴う休校措置が教員の新年度準備への関心に与えた影響を定量化する手法を提案する。データの収集の困難さを克服するために、教員向けソーシャルメディアであるフォレストアネットの閲覧履歴データを活用する。提案手法では、大規模言語モデルを用いることで、教員の日々の関心を表す時系列データを構築する。これにより、テキストデータをベイズ構造時系列モデルに適用可能とする。さらに、モデルの学習データ不足の課題に対しては、休校措置が行われた年よりも以前の年の閲覧履歴データを学習データとして導入することで対応する。実験結果として、休校措置はコロナ禍の新年度対応への教員の関心を大きく高め、通常の傾向を上回る閲覧行動を促したことが明らかとなった。休校措置に伴い教員が、感染防止を踏まえた学級経営の方法や、遠隔授業・ICT 活用を含む新年度準備に関する情報を積極的に収集していたことが示唆される。

1 序論

2020 年に発生した COVID-19 のパンデミックは、教育を含むあらゆる社会制度に深刻な影響を及ぼした。とりわけ学校教育の現場では、休校措置や遠隔授業の導入といった急激な環境変化により、教員の業務内容や意識に大きな変容が生じた。このような状況下で、教員の関心の変化を定量的に分析することは、教育政策の立案や危機時における支援体制の構築にとって重要である。なかでも、例年であれば計画的に進められる新年度準備が、不確実な状況下で多くの対応を迫られたことから、教員の関心の動向にも変化が生じたと考えられる。具体的には、授業方法の変更や感染対策の整備といった課題への対応が求められ、新年度準備に対する関心が従来以上に高まった可能性がある。

人々の関心を定量的に分析する古典的手法として、アンケート調査が用いられてきた。近年、ソーシャルメディアに投稿されるテキストデータが人々の実際の関心を反映することが報告されており [1]、ソーシャルメディア上の大量のテキストデータを分析するアプローチが注目されている [2, 3]。

しかしながら、教育分野においては、教員の関心を継続的かつ体系的に蓄積したデータが少ないため、ソーシャルメディア分析に基づく先行研究はほとんどない。

本研究では、COVID-19 に関するイベント (詳細は

4.1 節で定義) が教員の新年度準備への関心に与えた影響を定量化する手法を提案する。提案手法の第一の貢献は、日本最大の教員向けソーシャルメディアであるフォレストアネット¹⁾を活用することで、これまで困難であった教員の関心を反映したデータの収集を可能にした点である。フォレストアネットを用いた先行研究は存在するが、推薦システム [4, 5] やトピック抽出 [6] を目的としている。対して本研究は、フォレストアネットを教員の関心の時間的変化の推定に活用した初の試みである。第二の貢献は、提案手法にベイズ構造時系列モデル (以降、BSTS)[7] を導入した点にある。BSTS は、都市科学 [8] や金融 [9] など多様な分野において有効性が示されているモデルであり、時系列データに対するイベントの介入効果の推定に適している。本研究は、BSTS を教育分野、特に教員の関心の定量的分析に応用した初の事例である。

本研究では、フォレストアネットに投稿された 40 万件以上の記事のうち、「学級経営」に分類された 14,566 件のテキストデータを分析した。提案手法では、BERTopic[10] を用いて「新年度準備に関する話題」を抽出することで、教員の日々の関心を表す時系列データを構築する。これにより、テキストデータをベイズ構造時系列モデルに適用可能とした。さらに、BSTS の学習データ不足の課題に対して、COVID-19 に伴う休校措置が行われた年よりも以前の年の時系列データを学習データと用いることで対応した。これにより、反事実パフォーマンス (休校措置の影響がなかった場合の教員の関心) の高精度な予測を可能とした。実験結果より、コロナ禍の新年度対応への関心は例年を上回ることが分かり、教員は新たな対応策を求めて積極的に情報収集を行っていたことが示唆された。

2 関連研究

2.1 教育分野におけるデータマイニング手法

教育分野におけるデータマイニング研究は、主に学生を対象としたものと教員を対象としたものに大別される。学生を対象とした研究では、成績予測 [11, 12, 13, 14]、デジタル教材を用いた学習支援 [15, 16]、講義スライドを活用した知識の構造化 [17] などの手法が提案されている。一方、教員を対象とした研究には、教員の IT スキルが教員の労働時間に与える影響について検討した先行研究 [18] がある。しかし、この先行研究は、教員の関心に関するデータを活用しておらず、COVID-19 との関連性を分析していない点で、本研究とは異なる。

1) 長岡技術科学大学 大学院工学研究科

2) 株式会社スプリックス

1) 現在の授業準備ネット (<https://foresta.education>)

2.2 イベントの影響を推論する統計的手法

本研究では、COVID-19 に伴う休校措置が教員の関心に与えた影響を定量的に分析するため、統計的手法の活用を検討する。差の差分 (Difference in Differences: DID) 法は、処置群と対照群の経時的な平均変化を比較することでイベントの影響を推定する手法であるが、平行トレンドの仮定に依存しており、時間依存相関のような要因があるとこの仮定が成立しなくなる可能性がある [19]。さらに、DID 法は処置前後の 2 時点のみを考慮するため、時間的に変動する要因には適用が難しい場合がある [20, 21]。これに対し、構造時系列モデルは、平行トレンドの仮定を緩め、時間依存の局所的なトレンドや季節変動を捉えることができる [22]。文献 [7] では、BSTS を用いて、イベント前のデータを基に反事実パフォーマンスをシミュレートし、イベントの影響の推論を強化する方法が提案されている。

しかしながら、BSTS は、以下の理由により本研究に直接適用することは難しい。第一に、先行研究 [8, 9] では時系列データを対象としており、フォレストネットに投稿される記事のテキストデータを扱うことができない。第二に、BSTS は反事実パフォーマンスの予測精度を高めるために、トレンド成分や季節成分に加え、共変量 (詳細は 3 章で定義) を活用することが可能である。先行研究 [8] では、災害の影響を受けた地域の経済活動を評価する際に、影響を受けていない地域の同業種のデータを共変量として用いている。しかし、本研究ではそれに相当する適切な比較対象が存在しない。

3 提案手法

提案手法では、BSTS の適用に際して生じる課題を以下の新たなアプローチによって解決する。

- **新規点 1:** 大規模言語モデルに基づいたクラスタリング手法を用いて、テキストデータを時系列データへと変換することで、従来明示的に捉えられてこなかった教員の関心構造を抽出する。
- **新規点 2:** フォレストネット固有のデータ拡張手法を導入することで、反事実パフォーマンスにおける予測精度の向上を図る。

新規点 1 については、BERTopic[10] を用いて記事をクラスタリングする。ここで得られた各クラスタは、意味的に類似した記事の集合であり、本研究ではこれを話題とみなす。得られた複数のクラスタの中から「新年度準備に関する話題」に該当するクラスタを手動で抽出した。「新年度準備に関する話題」を c^* 、 y 年の d 日の閲覧数を $v_{c^*,y,d}$ 、 y 年の d 日の全クラスタの閲覧数の合計を $v_{y,d}$ とすると、 c^* の y 年 d 日の閲覧率は次のように定義される。

$$r_{c^*,y,d} = \frac{v_{c^*,y,d}}{v_{y,d}}. \quad (1)$$

本手法の定式化により、テキストデータを時系列データへと変換することが可能となる。

新規点 2 については、休校措置が行われた年よりも以前の年の時系列データを共変量として用い、反事実パフォーマンスを予測した。BSTS では、 $r_{c^*,y^*,d}$ は次の

ようにモデル化される。

$$\begin{cases} r_{c^*,y^*,d} = \mu_{c^*,y^*,d} + \tau_{c^*,y^*,d} + \beta r_{c^*,y < y^*,d} + \epsilon_{c^*,y^*,d} \quad \forall d, \\ \epsilon_{c^*,y^*,d} \sim \mathcal{N}(0, \sigma_r^2), \\ \sigma_r \sim \text{Cauchy}(0, 2.5). \end{cases} \quad (2)$$

ここで y^* は休校措置が行われた年を表す。 $r_{c^*,y^*,d}$ は、時系列データにおける局所的な変動であるトレンド成分 $\mu_{c^*,y^*,d}$ 、季節成分 $\tau_{c^*,y^*,d}$ 、および静的係数と提案する共変量の積 $\beta r_{c^*,y < y^*,d}$ によって予測される [7, 8]。モデルの構造を簡素化するために、トレンド成分の初期平均値 $\mu_{c^*,y^*,1}$ はランダムウォークとして仮定される。

$$\begin{cases} \mu_{c^*,y^*,d+1} = \mu_{c^*,y^*,d} + \eta_{1,c^*,y^*,d} \quad \forall d > 1, \\ \mu_{c^*,y^*,1} \sim \mathcal{N}(\mu_0, \sigma_\mu^2), \\ \eta_{1,c^*,y^*,d} \sim \mathcal{N}(0, \sigma_\mu^2), \\ \sigma_0, \mu_0, \sigma_\mu \sim \text{Cauchy}(0, 2.5). \end{cases} \quad (3)$$

季節成分は、 S を周期として、季節効果の合計が 1 周期 (期間 S) に渡ってゼロになるよう制約を課す。本研究では週次の季節性を想定し、 $\tau_{c^*,y^*,1}, \tau_{c^*,y^*,2}, \tau_{c^*,y^*,3}, \tau_{c^*,y^*,4}, \tau_{c^*,y^*,5}, \tau_{c^*,y^*,6}$ を初期化した。

$$\begin{cases} \tau_{c^*,y^*,d+1} = -\sum_{s=0}^{S-2} \tau_{c^*,y^*,d-s} + \eta_{2,c^*,y^*,d} \quad \forall d > 1 \\ \tau_{c^*,y^*,1}, \dots, \tau_{c^*,y^*,6} \sim \mathcal{N}(\mu_{\tau_0}, \sigma_{\tau_0}^2) \\ \eta_{2,c^*,y^*,d} \sim \mathcal{N}(0, \sigma_\tau^2) \\ \mu_{\tau_0}, \sigma_{\tau_0}, \sigma_\tau \sim \text{Cauchy}(0, 2.5). \end{cases} \quad (4)$$

次に、休校措置が行われた日を d^* とし、もし休校措置がなかった場合の「新年度準備に関する話題」の閲覧率 $\hat{r}_{c^*,y^*,d}$ を、次の条件付き確率分布により表現する。

$$\hat{r}_{c^*,y^*,d} \sim p(\hat{r}_{c^*,y^*,d} | r_{c^*,y^*,d}), \quad d \geq d^*. \quad (5)$$

そして、休校措置による影響を次のように推定する。

$$\phi_{c^*,y^*,d} = r_{c^*,y^*,d} - \hat{r}_{c^*,y^*,d}, \quad d \geq d^*. \quad (6)$$

さらに、総日数 D における休校措置の総影響を次のように推定する。

$$\phi_{c^*,y^*} = \sum_{d=d^*}^D \phi_{c^*,y^*,d}. \quad (7)$$

4 実験

本章では、提案手法の有効性を確認するため、以下を検証する。

- 新規点 1 により構築された時系列データは BSTS の仮定を満たすか。
- 新規点 2 であるフォレストネット固有のデータ拡張手法により反事実パフォーマンスの予測精度は向上するか。

4.1 実験方法

小学校教員による「新年度準備に関する話題」の閲覧率 ($r_{c^*,2020,d}$) を式 (1) に基づいて 2019 年 12 月 16 日から 2020 年 6 月 23 日の期間について算出した。また、共変量として用いるために、同様の手法で 2018 年 12 月 16 日から 2019 年 6 月 23 日までの期間における同話題の閲覧率 ($r_{c^*,2019,d}$) も算出した。本研究では、2020 年 ($y^* = 2020$) に発生したイベント、すなわち 2020 年 3 月 2 日 (d^*) に実施された COVID-19 に伴う全国的な休校措置が、「新年度準備に関する話題」への関心に与えた影響を分析する。そのために、構築した 2020 年の時系列データ ($r_{c^*,2020,d}$) を対象に、2019 年の同話題に関する閲覧率 ($r_{c^*,2019,d}$) を共変量として用い、休校措置による影響を分析する。

4.2 評価指標

提案手法により構築された時系列データが、BSTS の仮定である予測誤差の正規性を満たしているかを検証するために、休校措置前 ($d < d^*$) の期間における「新年度準備に関する話題」の閲覧率を対象に、BSTS で予測された値との残差を用いて検定を行った。検定には、Q-Q プロットによる視覚的評価と、とコルモゴロフ・スミルノフ正規性検定による統計的検証を用いた。

次に、共変量 ($r_{c^*,2019,d}$) の有効性を検証するために、共変量を用いない場合と比較し、休校措置前 ($d < d^*$) の期間における予測精度を、絶対平均誤差 (以降、MAE) およびピアソンの相関係数 (以降、Pearson's r) に基づいて評価した。

$$MAE = \frac{1}{D'} \sum_{d=1}^{d^*} |r_{c^*,y^*,d} - \hat{r}_{c^*,y^*,d}| \quad (8)$$

ここで D' は休校措置前までの日数である。

4.3 評価結果

図 1 には、休校措置前 ($d < d^*$) の期間における残差の Q-Q プロットを示す。この図から、提案手法により構築された時系列データの予測誤差は、概ね正規分布に従っていることが確認できる。さらに、コルモゴロフ・スミルノフ正規性検定を行った結果、 p 値は 0.07 となり、有意水準 5% のもとで帰無仮説 (正規性を仮定) が棄却されないことが示された。

表 1 には、提案手法において共変量を導入した場合と導入しない場合の予測精度を、MAE および Pearson's r に基づいて比較した結果を示す。MAE は共変量を導入した場合は導入しない場合よりも低く、予測誤差が小さいことが分かる。また Pearson's r においても、共変量の導入により相関係数が高まり、より精度の高い予測が可能であることが確認された。

表 1 共変量の導入有無による反事実パフォーマンス予測結果の比較

Evaluation metric	Use of covariates	
	No covariates	$r_{c^*,2019,d}$
MAE ($\times 10^{-4}$)	6.60	6.52
Pearson's r	0.26	0.30

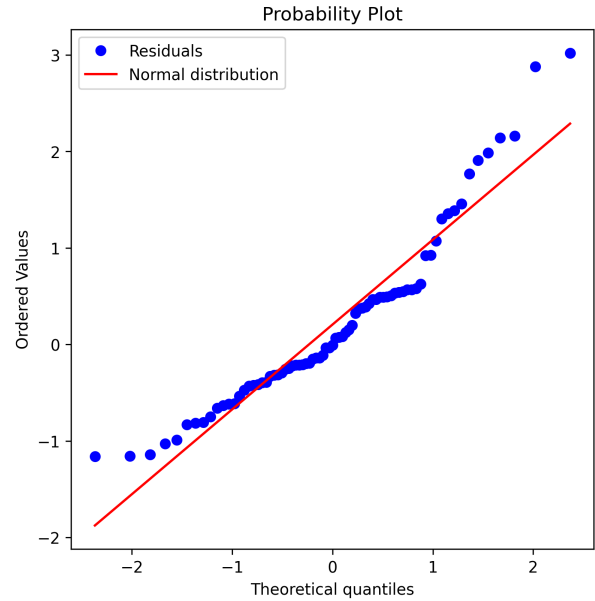


図 1 残差の正規性を示す Q-Q プロット

5 考察

最後に、提案手法によって推定された休校措置による影響について述べる。図 2 は、2020 年 3 月 2 日に実施された COVID-19 に伴う全国的な休校措置が、小学校教員による「新年度準備に関する話題」への関心に与えた影響を示している。図の上段は、2020 年における当該話題の閲覧率の実測値 (黒線) と、提案手法によって予測された値 (橙色の点線および信頼区間) である。この図から、実際の閲覧率が予測値より上回っている期間には、休校措置によって関心が高まったと解釈できる。中段は、式 (6) に基づき算出した日次の休校措置の影響を示し、値が大きいほどその影響が大きいことを表す。一方、値が 0 に小さいほど影響は小さいことを示す。下段は、式 (7) に基づく累積的な総効果を示しており、累積値が増加するほど、関心が継続的に高まっていたことを意味する。

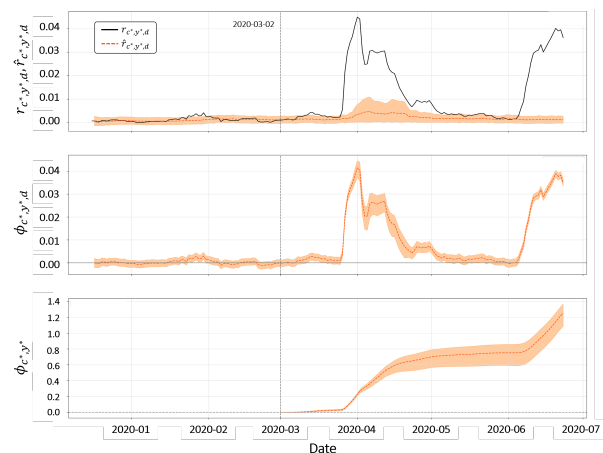


図 2 提案手法により推定された 2020 年 3 月 2 日の全国的な休校措置が「新年度準備に関する話題」の閲覧率に与えた影響

図 2 に示されるように、2020 年における「新年度準備

に関する話題」の閲覧率には、3月後半から4月にかけて大きなピークが確認される。これは例年にも見られる季節的な傾向ではあるが、2020年は予測値を大きく上回っており、全国的な休校措置に伴い、教員が新年度の対応に関する情報を積極的に収集していたことが示唆される。さらに、6月以降にも予測値には見られない新たなピークが確認される。このタイミングは、5月25日に緊急事態宣言が解除され、学校再開に向けた動きが本格化した時期と重なる。このことから、新年度準備が後ろ倒しになったことで、改めて関心が高まったと考えられる。

前半(3月および4月)のピークでは、過去(2019年以前)に投稿された記事の閲覧が多く、既存の情報を求める動きが顕著であった。一方、後半(6月以降)のピークでは、2020年に新たに投稿された記事、特に遠隔授業の方法やICTの活用、コロナ禍に対応した新年度準備に関する内容が多く閲覧されており、休校対応に関する新しい知見への需要が高かったことが読み取れる。

6 結論

本研究では、BSTSを用いて、教育現場における休校措置が教員の関心に与える影響を分析した。提案手法によって構築された時系列データはBSTSの仮定を満たすことと、共変量の導入により高い予測精度を示した。特に、休校直後と解除後に閲覧率の増加が確認され、教員が新たな対応策を求めて情報収集を行っていたことが明らかとなった。

謝辞

本研究の一部はJSPS科研費JP23K28193の助成を受けたものです。

参考文献

- [1] H. Kwak, C. Lee, H. Park, and S. Moon, "What is Twitter, a social network or a news media?" in *Proc. International Conference on World Wide Web*, 2010, pp. 591–600.
- [2] R. Harakawa and M. Iwahashi, "Ranking of importance measures of tweet communities: Application to keyword extraction from COVID-19 tweets in Japan," *IEEE Transactions on Computational Social Systems*, vol. 8, no. 4, pp. 1030–1041, 2021.
- [3] K. K. Osman, F. Barbaro, and A. Skumanich, "The potential for social media analysis to assess and optimize water management," in *Proc. International Conference on Computational Social Science (IC2S2)*, 2023.
- [4] K. Ohtomo, R. Harakawa, M. Iisaka, and M. Iwahashi, "AM-Bi-LSTM: Adaptive multi-modal Bi-LSTM for sequential recommendation," *IEEE Access*, vol. 12, pp. 12 720–12 733, 2024.
- [5] —, "Sequential recommender system of educational contents with end-to-end title feature extraction for reducing utility gap," in *Proc. IEEE Global Conference on Consumer Electronics (GCCE)*, 2021, pp. 197–199.
- [6] K. Takahashi, R. Harakawa, M. Iisaka, and M. Iwahashi, "Weighted LDA using metadata for extracting topics needed by teachers," in *Proc. IEEE Global Conference on Consumer Electronics (GCCE)*, 2020, pp. 413–414.
- [7] K. H. Brodersen, F. Gallusser, J. Koehler, N. Remy, and S. L. Scott, "Inferring causal impact using Bayesian structural time-series models," *Ann. Appl. Stat.*, vol. 9,

- pp. 247–274, 2015.
- [8] T. Yabe, Y. Zhang, and S. V. Ukkusuri, "Quantifying the economic impact of disasters on businesses using human mobility data: a Bayesian causal inference approach," *EPJ Data Science*, vol. 9, no. 1, p. 36, 2020.
- [9] P. Ray, B. Ganguli, and A. Chakrabarti, "A hybrid approach of Bayesian structural time series with LSTM to identify the influence of news sentiment on short-term forecasting of stock price," *IEEE Transactions on Computational Social Systems*, vol. 8, no. 5, pp. 1153–1162, 2021.
- [10] M. Grootendorst, "BERTopic: Neural topic modeling with a class-based TF-IDF procedure," *arXiv:2203.05794*, 2022.
- [11] A. Ghazvini, N. Mohd Sharef, and F. B. Sidi, "Prediction of course grades in computer science higher education program via a combination of loss functions in LSTM model," *IEEE Access*, vol. 12, pp. 30 220–30 241, 2024.
- [12] S. D. A. Bujang, A. Selamat, R. Ibrahim, O. Krejcar, E. Herrera-Viedma, H. Fujita, and N. A. M. Ghani, "Multiclass prediction model for student grade prediction using machine learning," *IEEE Access*, vol. 9, pp. 95 608–95 621, 2021.
- [13] A. Nabil, M. Seyam, and A. Abou-Elfetouh, "Prediction of students' academic performance based on courses' grades using deep neural networks," *IEEE Access*, vol. 9, pp. 140 731–140 746, 2021.
- [14] A. H. Nabizadeh, D. Gonçalves, S. Gama, and J. Jorge, "Early prediction of students' final grades in a gamified course," *IEEE Transactions on Learning Technologies*, vol. 15, no. 3, pp. 311–325, 2022.
- [15] E. D. Lopez Z., C. Tang, Y. Taniguchi, F. Okubo, and A. Shimada, "Automated recommendations for revising lecture slides using reading activity data," in *Proc. International Conference on Computers in Education*, 2024.
- [16] X. Geng, H. Uchiyama, A. Shimada, and M. Yamada, "Decoding memos: The role of learning concept explanation system in a technology-enhanced learning environment," in *Proc. eLearn: World Conference on EdTech 2024*. Association for the Advancement of Computing in Education (AACE), 2024, pp. 269–277.
- [17] G. Li, C. Tang, L. Chen, D. Deguchi, T. Yamashita, and A. Shimada, "LLM-driven ontology learning to augment student performance analysis in higher education," in *Proc. International Conference on Knowledge Science, Engineering and Management (KSEM)*, 2024, pp. 57–68.
- [18] H. Akabayashi, S. Taguchi, and M. Zvedelikova, "School ICT resources, teachers, and online education: evidence from school closures in Japan during the COVID-19 pandemic," *Education Economics*, pp. 1–14, 2024.
- [19] A. Goodman-Bacon, "Difference-in-differences with variation in treatment timing," *Journal of econometrics*, vol. 225, no. 2, pp. 254–277, 2021.
- [20] A. Abadie, "Semiparametric difference-in-differences estimators," *The Review of Economic Studies*, vol. 72, no. 1, pp. 1–19, 2005.
- [21] J. Antonakis, S. Bendahan, P. Jacquart, and R. Lalive, "On making causal claims: A review and recommendations," *The Leadership Quarterly*, vol. 21, no. 6, pp. 1086–1120, 2010.
- [22] A. Harvey and S. J. Koopman, "Structural time series models," in *Wiley StatsRef: Statistics Reference Online*. Wiley, 2014.