

多目的強化学習に基づくトピックモデルと予測モデルの同時最適化

中村 礼音[†] 伊藤 寛祥^{††} 森嶋 厚行^{††}

[†] 筑波大学人間総合科学研究群情報学学位プログラム 〒305-8550 茨城県つくば市春日 1-2

^{††} 筑波大学図書館情報メディア系 〒305-8550 茨城県つくば市春日 1-2

E-mail: [†]s2321708@u.tsukuba.ac.jp, ^{††}{ito,mori}@slis.tsukuba.ac.jp

あらまし 新興技術のトピックやトレンドを理解することは、企業や研究機関が技術開発の意思決定をする際に有益である。BERTopic は、Transformer を活用したトピックモデリング手法であり、高い精度でトピックの推定を行うことが可能である。本研究では、多目的強化学習の枠組みでトピックモデルとトピックのトレンド予測モデルを同時最適化する手法を提案する。具体的には、トピックの類似度 (Topic Diversity, Embeddings Similarity, Trend Divergence) を状態 (State) として扱い、報酬 (Reward) の最大化を目指す。Coherence と Topic Diversity をトピックモデルの報酬として、予測値と実測値の乖離度 (Euclidean Distance) をトピックのトレンド予測モデルの報酬として扱うことで、トピックモデルとトピックのトレンド予測モデル双方を考慮した同時最適化が可能となる。建築分野の特許文書を用いた実験の結果、提案手法を使用することで、比較手法よりも精度が高いトピックの抽出と将来のトピックのトレンド予測が可能であることが確認できた。

キーワード トピックモデル, テキストマイニング, 自然言語処理応用, LLM

1 序 論

新興技術のトピックやトレンドを理解することは、企業や研究機関が技術開発の意思決定をする際に有益である。一方、科学論文や特許などの文献情報から、新興技術のトピックやトレンドを理解することは非常に困難で、多大な努力と費用が必要である [1]。

トピックモデルは、文書集合からトピックを自動で推定する手法であり、「文書分類」「テキスト要約」「検索」「推薦」など、幅広い領域で利用されている [2] [3]。代表的なトピックモデルとして、潜在ディリクレ配分法 (LDA) [4] や、ニューラルトピックモデル (NTM) [5] [6] が存在し、大規模言語モデル (LLM) の登場以降は、文脈表現をトピックモデルに導入する試みが盛んになっている。

BERTopic [7] は、Transformer を活用したトピックモデルであり、高い精度でトピックの推定を行うことが可能である。また、BERTopic はさまざまな拡張機能をサポートしている。例えば、merge_topics は類似するトピック同士を結合することができる。さらに、BERTopic の拡張機能を利用することで、時間経過に伴うトピックの変化を分析することも可能である。これにより各トピック出現頻度が時刻ごとにプロットされるため、トピックのトレンドがこれまでどのように変化してきたかを確認することができる。

本研究では、BERTopic と予測モデルを使用することで、トピックのトレンド予測を行う。さらに、多目的強化学習の枠組みでトピックモデルとトピックのトレンド予測モデルを同時最適化する手法を提案する。具体的には、トピックの類似度 (Topic Diversity, Embeddings Similarity, Trend Divergence) を状態 (State) として扱い、Coherence と Topic Diversity をトピ

クモデルの報酬として、予測値と実測値の乖離度 (Euclidean Distance) をトピックのトレンド予測モデルの報酬として扱うことで、トピックモデルとトピックのトレンド予測モデル双方を考慮した同時最適化が可能となる。

実験では、はじめに DQN の枠組みでモデル学習が適切に行われているか否かを確認した。次に、トピックモデルとトピックのトレンド予測モデルの同時最適化を行うことで、両モデルを考慮した学習が行えているか否かを確認した。前者に関しては、DQN 学習前後の Coherence, Topic Diversity, 予測値と実測値の乖離度 (Euclidean Distance) を比較することでトピックモデルとトピックのトレンド予測モデルの性能がそれぞれ向上するかを検証した。後者に関しては、トピックモデルのみで最適化を行った場合と、トピックモデルとトピックのトレンド予測モデルの同時最適化を行った場合で実験結果を比較することで、両モデルを考慮した学習が行えているか否かを検証した。

建築分野の特許文書を用いた実験の結果、提案手法を使用することで、比較手法よりも高いトピックの抽出と将来のトピックのトレンド予測が可能であることが確認できた。

本研究の貢献は次の通りである。

- (1) 多目的強化学習に基づき、トピックモデルとトピックのトレンド予測モデルを同時最適化する新しい手法を提案した。
- (2) 提案手法により、トピックモデルとトレンド予測モデルの精度が向上することを実験的に示した。

2 関連研究

トピックモデルは、文書が生成される過程を、確率を用いてモデル化した確率的生成モデルであり、代表的な手法として、潜在ディリクレ配分法 (LDA) [4] やニューラルトピックモデル





図 1: BERTopic の拡張機能である Dynamic Topic Modeling の結果

STEP1 トピックのトレンド予測の枠組みを構築



STEP2 トピックモデルとトピックのトレンド予測モデルのリファインメント

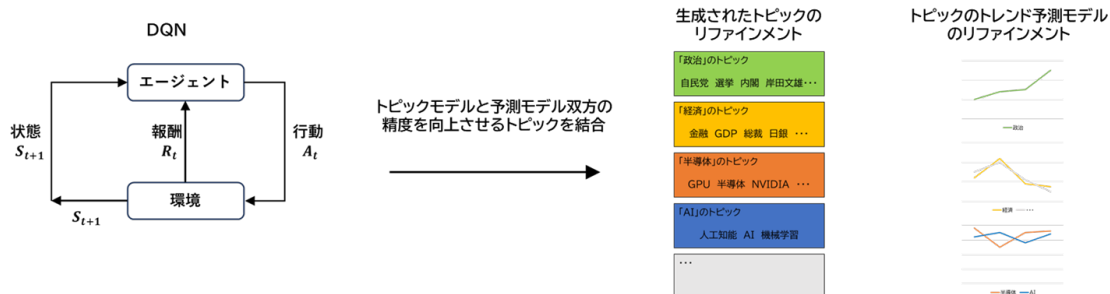


図 2: 提案手法のアーキテクチャ

(NTM) [5] [6] が存在する。また、トピックモデルの派生モデルも存在し、Blei らの Dynamic Topic Model (DTM) [8] は時間変化を扱った代表的なトピックモデルである。しかし、DTM は将来のトピックのトレンド予測を目的としておらず、筆者の調べではトピックの時間変化と将来のトピックのトレンド予測双方を学習としたモデルは存在しない。1, 2 節では、本研究に関連したトピックモデル手法を概説し、提案手法との関係を述べる。3 節では本研究に使用する予測モデルを紹介する。

2.1 BERTopic: Neural topic modeling with a class-based TF-IDF procedure

LDA [4] や Non-Negative Matrix Factorization (NMF) [9] といった従来のモデルでは、文書を Bag of Words (BoW) と

して記述しており、トピックの生成にトークンの出現頻度のみしか考慮していない。そのため BoW の入力では、単語間の関係や文脈を考慮しないため、トピック抽出の際に単語間の関係や文脈を考慮することができないという問題がある。一方 LLM 登場以降、LLM のテキストエンベディング技術をとピックモデルに導入する試みが盛んになっており、文脈を考慮したトピックの生成において大きな成果を示している [10]。Top2Vec [11] や HDBSCAN [12] では、単語とクラスタのエンベディングを作成し、クラスタのセントロイド (重心) からトピック表現を抽出する手法であり、LLM のテキストエンベディング技術を導入したトピックモデルの学習の有効性が確認された。一方セントロイドベースのクラスタリングアプローチを利用したトピックモデルは、クラスタの重心に近い単語がそ

のクラスタを最も代表すると仮定している。しかし、実際はクラスタの中心がクラスタの重心となるという仮定が成り立たない場合も多く、クラスタにおける単語の重要度は考慮されていないという問題が存在する。

BERTopic [7] は、Transformer とクラスベースの TF-IDF を活用して、クラスタにおける単語の重要度を考慮したトピックモデルであり、高い精度でトピックの学習を行うことが可能である。また、BERTopic の拡張機能である Dynamic Topic Modeling を利用することで、各タームにおけるトピックの出現頻度シーケンスを手に入れることができ、トピックのトレンドがこれまでどのように変化してきたかを確認することができる。図 1 は Dynamic Topic Modeling の結果である。

本研究では、トピックの学習精度の高さと時系列コーパスを扱うことが可能であるという理由から、トピックモデルの学習に BERTopic を採用する。

2.2 強化学習に基づくトピックモデルの学習

Reinforcement Learning for Topic Models [13] は、強化学習の枠組みを利用してトピックの学習を行うトピックモデル手法である。LDA [4] などの従来のトピックモデルは、元の文書の再構成に焦点を当ており、トピックの質を向上させるという本質の問題に取り組んでいない [14] [15] [16] [17]。

Reinforcement Learning for Topic Models では、強化学習の枠組みを利用して、Coherence を最大化するようトピックを反復的に学習する。アーキテクチャの詳細は以下の通りである。はじめに、行動 (Action) は高い Coherence スコアを持つ単語を文書中からサンプリングし、サンプリングされなかった単語を文書からマスクする。次に、単語間の潜在的なトピックの分布を状態 (State) とし、トピックを学習する。最後に、報酬 (Reward) に、トピックの一貫性を図る Coherence を利用することで、より高い Coherence スコアを持つ単語により高い重みを割り当てることが可能となる。

Reinforcement Learning for Topic Models はより高度なトピック抽出とトピックの一貫性の測定の両方において優れたパフォーマンスを示している。

本研究では、Reinforcement Learning for Topic Models の枠組みを応用して、トピックモデルとトピックのトレンド予測モデル双方のリファインメント手法を構築する。

2.3 時系列モデル

本研究では、BERTopic と予測モデルを使用することで、トピックのトレンド予測を行う。一方、トピックのトレンドはさまざまな因子によって決定づけられるため、トピックの出現頻度シーケンスをそのまま予測モデルで学習することは不適切な学習結果を招いてしまう恐れがある。例えば、異なるトレンドを持つトピックを同一の予測モデルで学習することは不適切な結果を招いてしまう可能性が高く、予測結果の信頼度も低いものとなる。

複雑なシステムをモデル化する際には、システムを部分的に分析する手法が一般的である。この手法は複数モデル学習

(multiple model learning) と呼ばれる [18]。交通状況の予測などの分野では、多くの場合で時系列シーケンスのクラスタリングを事前ツールとして使用している例が存在する [19] [20]。

本研究もこのアイデアを借用し、トピックのトレンド予測のプロセスをクラスタリング部分と予測部分に分割して実行する。はじめに BERTopic の拡張機能である Dynamic Topic Modeling から取得したトピックの出現頻度シーケンスデータを自然なクラスタに分割する。次にクラスタごとの予測モデルを利用することで、トピックのトレンド予測を実行する。クラスタはシステムをより正確に表すことができるため、予測精度と予測結果の信頼度を向上させることが期待できる。

本研究では、時系列クラスタリングモデルとして Time-SeriesKMeans [21]、予測モデルとして Prophet [22] を使用することで、トピックのトレンド予測を実施する。

3 提案手法

本研究では、BERTopic と予測モデルを使用することで、トピックのトレンド予測を行う。さらに、多目的強化学習の枠組みでトピックモデルとトピックのトレンド予測モデルを同時最適化する手法を提案する。具体的には、類似するトピックを結合することでトピックの更新 (リファインメント) を実行する。多目的強化学習の枠組みでは、トピックペアの類似度 (Topic Diversity, Embeddings Similarity, Trend Divergence) を状態 (State) として扱い、状態 (State) を受け取ったエージェントが報酬 (Reward) が最大となるようトピックの結合判定を行う。この際、トピックモデルの報酬として Coherence と Topic Diversity を、トピックのトレンド予測モデルの報酬として予測値と実測値の乖離度 (Euclidean Distance) を扱うことで、トピックモデルとトピックのトレンド予測モデル双方を考慮した同時最適化が可能となる。

提案手法の概要を示した図が図 2 である。提案手法は 2 つのステップで構築される。STEP1 では、トピックのトレンド予測の枠組みを構築する。STEP2 では、トピックモデルとトピックのトレンド予測モデルの同時最適化を行う。

3.1 トピックのトレンド予測の枠組みを構築

STEP1 では、トピックのトレンド予測の枠組みを構築する。BERTopic [7] は、Transformer を利用したトピックモデル手法であり、高い精度でトピックの推定を行うことが可能である。次に BERTopic の拡張機能である Dynamic Topic Modeling を使用し、各タームにおけるトピックの出現頻度シーケンスを取得する。

トピックのトレンド予測モデルは、2.3 節の説明の通り、時系列クラスタリングモデルの TimeSeriesKMeans [21] と予測モデルの Prophet [22] を使用して行う。具体的には、Dynamic Topic Modeling から取得したトピックの出現頻度シーケンスを、TimeSeriesKMeans を利用しクラスタに分割し、Prophet を利用することでクラスタごとに予測を行う。以上のプロセスを経て、トピックのトレンド予測の枠組みを構築する。

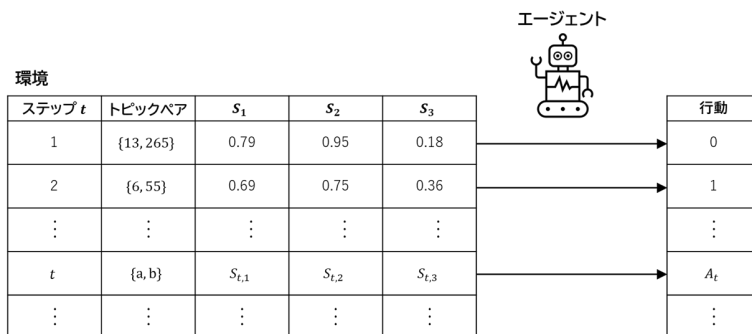


図 3: 環境とエージェントの関係

3.2 トピックモデルとトピックのトレンド予測モデルの同時最適化

STEP2 では、類似するトピックを結合することでトピックの更新（リファインメント）を実行する。トピックペアの類似度（Topic Diversity, Embeddings Similarity, Trend Divergence）を状態（State）として扱い、状態（State）を受け取ったエージェントが報酬（Reward）が最大となるようトピックの結合判定を行う。トピックモデルの報酬として Coherence と Topic Diversity を、トピックのトレンド予測モデルの報酬として予測値と実測値の乖離度（Euclidean Distance）を扱うことで、トピックモデルとトピックのトレンド予測モデル双方を考慮した同時最適化が可能となる。

以下のサブセクションにて、DQN による多目的強化学習の枠組みの詳細を説明する。

3.2.1 状態 (State)

状態 (State) は、3つのトピックペアの類似度（Topic Diversity, Embeddings Similarity, Trend Divergence）で構成される。Topic Diversity を $S_{t,1}$ 、Embeddings Similarity を $S_{t,2}$ 、Trend Divergence を $S_{t,3}$ で表すと状態 S_t は以下のようにあらわされる。なお、 t は各学習のステップ値である。

$$S_t = \{S_{t,1}, S_{t,2}, S_{t,3}\} \quad (1)$$

Topic Diversity は、トピック同士の構成単語（上位 10 語）に同一単語がどれだけ含まれるかを測るための指標である。同一単語が複数含まれる場合 Topic Diversity は 0 に近づき、同一単語が一つも含まれない場合 Topic Diversity は 1 となる。Topic Diversity が 0 に近いほど類似しているトピックペアである。一般に Topic Diversity はトピックモデルから生成されるすべてのトピックを対象に計算されるが、本件研究における強化学習の環境ではトピックのペアに対して Topic Diversity を計算する。

Embeddings Similarity は、トピックペアの Embedding の cosine 類似度である。BERTopic は sentence-transformers を利用してトピックを生成しているため、各トピックは Embedding をもつ。Embedding の cosine 類似度が 0 に近いほど類似しているトピック同士である。

Trend Divergence は、トピックペアのトレンド乖離スコアの平均である。トピックの出現頻度シーケンスを p 、Time-

SeriesKMeans で時系列クラスタリングの中心線を c とする。なお、 c はそれぞれのクラスタに所属するトピックの出現頻度シーケンスを p の平均で構成される。 p と q のユークリッド距離を $d(p, q)$ とすると Trend Divergence は以下のような式で表すことができる。

$$\frac{d(p_a, c_a) + d(p_b, c_b)}{2} \quad (2)$$

Trend Divergence が高いほど、トピックのトレンド把握の際にノイズとなり、Trend Divergence が低いほど、トピックのトレンドの中心である。

3.2.2 行動 (Action) とエージェント

行動 (Action) では、トピックのペアを結合するか否か決定する。 α_0 をトピックを結合しないという行動、 α_1 をトピックを結合するという行動とすると行動空間は以下のようにあらわされる。

$$A = \{\alpha_0, \alpha_1\} \quad (3)$$

エージェントは、トピックペアの類似度 ($S_{t,1}, S_{t,2}$) とトピックのトレンド乖離度 ($S_{t,3}$) 双方を考慮して行動を決定する。 $S_{t,1}, S_{t,2}$ に基づいてトピックを結合するか否かを判定することで、よりよいトピックの生成が可能となる。また、 $S_{t,3}$ に基づいてトピックを結合するか否かを判定することで、トピックのトレンド予測精度の向上が期待される。高い報酬が得られる行動 (Action) に、より高い確率を割り当てられ、エージェントはその確率に基づいて行動 (Action) を選択する。エージェント行動は以下のようにあらわされる。 ϵ の確率でエージェントがランダムな行動 (Action) をとるようにすることで、探索と活用の双方を考慮できるよう設計する。

$$\begin{cases} \alpha \stackrel{R}{\leftarrow} A & \text{if random} < \epsilon \\ \underset{\alpha}{\operatorname{argmin}} f(\text{State}) & \text{else} \end{cases} \quad (4)$$

3.2.3 環境 (Environment)

環境 (Environment) ではエージェントが結合判定をするトピックペアの順序を提供する。環境 (Environment) は、トピックペア a, b とトピックペアの結合判定指標 $S_t = \{S_{t,1}, S_{t,2}, S_{t,3}\}$ を含んでいる。エージェントは各ステップ t ごとに環境 (Environment) から S_t が与えられ、トピックペア a, b を結合する

か否か判定する。環境 (Environment) がエージェントに与える S_t の順序は、本研究では学習の対象とはせず、あらかじめトピックの類似度等を参考に作成する。エージェントは、環境から与えられた状態 S_t に基づいて、以下のように行動 A_t を決定する。ただし、 f_a は DQN ネットワークを指す。

$$A_t = \operatorname{argmin}_a f_a(S_t) \quad (5)$$

環境とエージェントの関係は、図3のようになる。

3.2.4 報酬 (Reward)

報酬 R_t は、トピックモデルの報酬 $R_{t,1}$ とトピックのトレンド予測モデルの報酬 $R_{t,2}$ で構成される。トピックモデルの報酬 $R_{t,1}$ はさらに Coherence の報酬 $Q_{t,1}$ と Topic Diversity の報酬 $Q_{t,2}$ で構成される。 α は Coherence と Topic Diversity の報酬の調整を担い、 β はトピックモデルとトピックのトレンド予測モデルの報酬の調整を担う。結合しないという判定をエージェントがとった場合は、報酬 R_t は 0 となる。以上の定義より、報酬は以下の式となる。

$$\begin{cases} R_t = 0 & \text{if } A_t = 0 \\ R_t = \beta \cdot R_{t,1} + (1 - \beta) \cdot R_{t,2} & \text{else} \end{cases} \quad (6)$$

ただし、

$$R_{t,1} = \alpha \cdot Q_{t,1} + (1 - \alpha) \cdot Q_{t,2} \quad (7)$$

はじめにトピックモデルの報酬 $R_{t,1}$ の説明をする。Coherence と Topic Diversity をトピックモデルの報酬として扱うことで、トピックモデルのリファインメントが可能となる。 $Q_{t,1}$ はトピックペアの結合前後で Coherence が増加したか否かで決定する。 $Q_{t,2}$ はトピックペアの結合前後で Topic Diversity が増加したか否かで決定する。以上より、 $Q_{t,1}$ と $Q_{t,2}$ は以下のように決定する。

$$\begin{cases} Q_{t,1} = 1 & \text{if } \text{Coherence}_t > \text{Coherence}_{t-1} \\ Q_{t,1} = -1 & \text{else} \end{cases} \quad (8)$$

$$\begin{cases} Q_{t,2} = 1 & \text{if } \text{Topic Diversity}_t > \text{Topic Diversity}_{t-1} \\ Q_{t,2} = -1 & \text{else} \end{cases} \quad (9)$$

トピックのトレンド予測モデルの報酬 $R_{t,2}$ は、トピックペアの結合前後で、予測値と実測値の乖離度 $Q_{t,3}$ が減少したか否かで決定する。トピックの出現頻度シーケンスを p 、トピックの出現頻度シーケンスの予測値を \hat{p} 、 p と q のユークリッド距離を $d(p, q)$ とすると $R_{t,2}$ は以下のような式で表すことができる。

$$\begin{cases} R_{t,2} = 1 & \text{if } Q_{t,3} > 0 \\ R_{t,2} = -1 & \text{else} \end{cases} \quad (10)$$

ただし、

$$Q_{t,3} = \frac{d(p_a, \hat{p}_a) + d(p_b, \hat{p}_b)}{2} - d(p_{ab}, \hat{p}_{ab}) \quad (11)$$

4 実 験

実験では、はじめに DQN による多目的強化学習の枠組みでモデル学習が適切に行われているか否かを確認した。次に、トピックモデルとトピックのトレンド予測モデルの同時最適化を行うことで、両モデルを考慮した学習が行えているか否かを確認した。前者に関しては、DQN 学習前後の Coherence, Topic Diversity, 予測値と実測値の乖離度 (Euclidean Distance) を比較することでトピックモデルとトピックのトレンド予測モデルの性能がそれぞれ向上するかを検証した。後者に関しては、トピックモデルのみで最適化を行った場合と、トピックモデルとトピックのトレンド予測モデルの同時最適化を行った場合で実験結果を比較することで、両モデルを考慮した学習が行えているか否かを確認した。

4.1 データセット

本研究では、日本語の時系列コーパスとして「建築分野に関連した特許文書 (1999 年から 2022 年)」を使用した。総文書数は、21352 件である。

4.2 性能評価指標

提案手法は、トピックモデルとトピックのトレンド予測モデル双方の精度を検証する必要がある。トピックモデルの性能評価指標として、Coherence u-mass と Topic Diversity を導入した。また、トピックのトレンド予測モデルの性能評価指標として、Euclidean Distance を導入した。いずれの評価指標も 3.2.4 節で説明したトピックモデルの報酬とトピックのトレンド予測モデルの報酬と同一である。

Coherence u-mass は、トピックの品質・一貫性を評価する指標であり、以下の式で定義される。

$$C(t; V^{(t)}) = \sum_{m=2}^M \sum_{l=1}^{m-1} \log \frac{D(v_m^{(t)}, v_l^{(t)}) + 1}{D(v_l^{(t)})} \quad (12)$$

ここで、 $V^{(t)} = v_1^{(t)}, \dots, v_M^{(t)}$ はトピック t の上位 M 個の単語集合、 $D(v)$ は単語の出現文書数、 $D(v_1, v_2)$ は単語の共起文書数である。

次に、Topic Diversity は以下のようにあらわされる。Topic Diversity はトピック同士の構成単語 (上位 10 語) に同一単語がどれだけ含まれるかを測るための指標である。同一単語が複数含まれる場合 Topic Diversity は 0 に近づき、同一単語が一つも含まれない場合 Topic Diversity は 1 となる。Topic Diversity が 0 に近いほど冗長なトピックを生成しており、1 に近いほど多様なトピックを生成していることを示す。

Euclidean Distance は、予測値と実測値のユークリッド距離 (乖離度) であり、予測値と実測値が近い場合、スコアは 0 に近づく。本研究では、使用した時系列コーパス「建築分野に関連した特許文書 (1999 年から 2022 年)」の最終年 2022 年のトピックの出現頻度をテストデータとして扱った。

4.3 実験設定

報酬で導入した α と β を複数用意して交差検証を行う。実験で使用した Q 関数は、10 の隠れ層サイズをもつネットワーク層 3 層で構成され、活性化関数として ReLU 関数を使用した。学習の最適化は、学習率が 0.0005 の Adam で実行した。そのほかのハイパーパラメータの設定として、学習回数を 50、環境のステップ数を 63、DQN のバッファ数を 50、バッチ数を 16、エージェントがランダムな行動をとる確率 ϵ を 0.1 と設定した。

4.4 実験結果

本節はじめて説明した通り、本研究では二つの検証事項を確認するための実験を行う。検証事項の一つ目は、DQN の枠組みでモデル学習が適切に行われているか否かである。検証事項の二つ目は、トピックモデルとトピックのトレンド予測モデルの同時最適化を行うことで、両モデルを考慮した学習が行えているか否かである。以下、各検証事項の実験結果を紹介する。

4.4.1 検証事項 1

検証事項 1 では、DQN の枠組みでモデル学習が適切に行われているか否かを検証する。方法としては、DQN 学習前後の Coherence、Topic Diversity、予測値と実測値の乖離度 (Euclidean Distance) を比較することでトピックモデルとトピックのトレンド予測モデルの性能がそれぞれ向上するかを確認した。

実験の結果は以下の通りである。なお、TC は Topic Coherence u-mass、TD は Topic Diversity、ED は Euclidean Distance を表す。また、以下の結果は α が 0.3、 β が 0.5 のものを採用した。

表 1: 検証事項 1 の結果

	TC	TD	ED Train	ED Test
Before	0.65687	0.97	0.02081	0.08918
After	0.66019	0.98116	0.01958	0.08025

表 1 を確認すると、Coherence、Topic Diversity、Euclidean Distance いずれのスコアも DQN の学習後に向上していることが確認できる。

図 6、4、5 は、報酬で導入した α と β を複数用意して交差検証を行った結果である。乖離度は結合後にどれだけ減らせたかを加算しているため、上昇すればするほど精度が向上していることを示している。いずれの場合も学習回数を経るほどモデルの精度が向上していることが確認できる。

以上の結果より、提案手法を用いることで、トピックモデルとトピックのトレンド予測モデルの精度がそれぞれ向上することが確認できた。

4.4.2 検証事項 2

検証事項 2 では、トピックモデルとトピックのトレンド予測モデルの同時最適化を行うことで、両モデルを考慮した学習が行えているか否かを検証する。方法としては、トピックモデルのみで最適化を行った場合と、トピックモデルとトピックのトレンド予測モデルの同時最適化を行った場合で実験結果を比較

することで、両モデルを考慮した学習が行えているか否かを確認した。

トピックモデルのみで最適化を行う場合では、3.2.1 節で紹介した 3 つのトピックペアの類似度 (Topic Diversity, Embeddings Similarity, Trend Divergence) のうち、トピックのトレンド予測モデル部分に関係する Trend Divergence を除いたトピックペアの類似度 (Topic Diversity, Embeddings Similarity) を状態として使用した。また、トピックモデルのみで最適化を行う場合は、トピックのトレンド予測モデル部分に関係する報酬を取り除くため報酬のパラメータ β を 0 とした。

実験の結果は以下の通りである。Single はトピックモデルのみで最適化を行ったモデル、Joint は同時最適化を行ったモデル (提案手法) であり、Joint は表 1 の After と同一である。また、Single の報酬パラメータ α は 0.3、 β はトピックのトレンド予測モデル部分に関係する報酬を取り除くため 0 とした。Joint の報酬パラメータはそれぞれ α が 0.3、 β が 0.5 である。

表 2: 検証事項 2 の結果

	TC	TD	ED Train	ED Test
Single	0.66031	0.97926	0.01994	0.08469
Joint	0.66019	0.98116	0.01958	0.08025

Single モデルと Joint モデル双方のトピックモデルの精度を比較してみると、Coherence は Single モデル、Topic Diversity は Joint モデルの方が高い結果となった。また、Euclidean Distance のスコアは Joint モデルの方がより高い精度を持つことが確認できた。Single モデルと Joint モデルで結合されたトピックのうち 5 件を表示したものが図 7 と図 8 である。

4.5 実験の考察

実験結果より、提案手法を用いることでトピックモデルとトピックのトレンド予測モデルの精度がそれぞれ向上することが確認できた。また、トピックモデルとトピックのトレンド予測モデルの同時最適化の枠組みを用いることで、両モデルを考慮したトピックのリファインメントが行われていることが定量的には確認できた。

一方で、図 7 と図 8 を確認してみると、Single モデルと Joint モデル双方で直観的には類似していないがトピックが結合されている事例が確認できる。この理由としては、2 つ考えられる。一つ目が、トピック数が減ること自体がトピックモデルの報酬となってしまう適切な報酬の設計がされていない点である。二つ目が、人間がトピック同士が直観的に類似しているか判断する基準と Topic Diversity との間にズレが生じている点である。例えば、Topic Diversity では「養生」と「養生方法」、「空調システム」と「空調」は全く別の単語として認識されてしまうといった問題が生じる。これらの問題に対処するため、再度報酬の設計と Topic Diversity の調整を行う必要がある。

5 考察と結論

本研究では、BERTopic と予測モデルを使用することで、ト

ピックのトレンド予測を行い、さらに、DQNによる多目的強化学習の枠組みでトピックモデルとトピックのトレンド予測モデルを同時最適化する手法を提案した。実験を通して、提案手法を用いることでトピックモデルとトピックのトレンド予測モデルの精度がそれぞれ向上することが確認できた。また、トピックモデルとトピックのトレンド予測モデルの同時最適化の有効性が定量的には確認できた。

一方で、図7と図8を確認してみると、直観的には類似していないがトピックが結合されている事例が確認できる。この理由としては、2つ考えられる。一つ目が、トピック数が減ること自体がトピックモデルの報酬となってしまう適切な報酬の設計がされていない点である。二つ目が、人間がトピック同士が直観的に類似しているか判断する基準と Topic Diversity との間にズレが生じている点である。今後の課題として、報酬の設計と Topic Diversity の調整を行うことでこれらの問題を解決し、さらなる実験と考察を行う必要があると考えられる。

謝 辞

本研究の一部は JST CREST(JPMJCR22M2), JSPS 科研費 (22H00508, 22K17944) および株式会社熊谷組の支援による。

文 献

- [1] Shuo Xu, Liyuan Hao, Guancan Yang, Kun Lu, and Xin An. A topic models based framework for detecting and forecasting emerging technologies. *Technological Forecasting and Social Change*, Vol. 162, p. 120366, 2021.
- [2] Xing Yi and James Allan. A comparative study of utilizing topic models for information retrieval. In Mohand Boughanem, Catherine Berrut, Josiane Mothe, and Chantal Soule-Dupuy, editors, *Advances in Information Retrieval*, pp. 29–41, Berlin, Heidelberg, 2009. Springer Berlin Heidelberg.
- [3] Shixia Liu, Michelle X. Zhou, Shimei Pan, Yangqiu Song, Weihong Qian, Weijia Cai, and Xiaoxiao Lian. Tiara: Interactive, topic-based visual text summarization and analysis. *ACM Trans. Intell. Syst. Technol.*, Vol. 3, No. 2, feb 2012.
- [4] David Blei, Andrew Ng, and Michael Jordan. Latent dirichlet allocation. In T. Dietterich, S. Becker, and Z. Ghahramani, editors, *Advances in Neural Information Processing Systems*, Vol. 14. MIT Press, 2001.
- [5] Yishu Miao, Edward Grefenstette, and Phil Blunsom. Discovering discrete latent topics with neural variational inference, 2017.
- [6] Akash Srivastava and Charles Sutton. Autoencoding variational inference for topic models, 2017.
- [7] Maarten Grootendorst. Bertopic: Neural topic modeling with a class-based tf-idf procedure, 2022.
- [8] David M. Blei and John D. Lafferty. Dynamic topic models. In *Proceedings of the 23rd International Conference on Machine Learning*, ICML '06, p. 113–120, New York, NY, USA, 2006. Association for Computing Machinery.
- [9] Cédric Févotte and Jérôme Idier. Algorithms for nonnegative matrix factorization with the beta-divergence, 2011.
- [10] Silvia Terragni, Elisabetta Fersini, Bruno Giovanni Galuzzi, Pietro Tropeano, and Antonio Candelieri. OCTIS: Comparing and optimizing topic models is simple! In Dimitra Gkatzia and Djamel Seddah, editors, *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: System Demonstrations*, pp. 263–270, Online, April 2021. Association for Computational Linguistics.
- [11] Dimo Angelov. Top2vec: Distributed representations of topics, 2020.
- [12] Claudia Malzer and Marcus Baum. A hybrid approach to hierarchical density-based cluster selection. In *2020 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*. IEEE, September 2020.
- [13] Lin Gui, Jia Leng, Gabriele Pergola, Yu Zhou, Ruifeng Xu, and Yulan He. Neural topic model with reinforcement learning. In Kentaro Inui, Jing Jiang, Vincent Ng, and Xiaojun Wan, editors, *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pp. 3478–3483, Hong Kong, China, November 2019. Association for Computational Linguistics.
- [14] Diederik P Kingma and Max Welling. Auto-encoding variational bayes, 2022.
- [15] Dallas Card, Chenhao Tan, and Noah A. Smith. Neural models for documents with metadata. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*. Association for Computational Linguistics, 2018.
- [16] Akash Srivastava and Charles Sutton. Autoencoding variational inference for topic models, 2017.
- [17] Diane Bouchacourt, Ryota Tomioka, and Sebastian Nowozin. Multi-level variational autoencoder: Learning disentangled representations from grouped observations, 2017.
- [18] Nikolas Julio, Ricardo Giesen, and Pedro Lizana. Real-time prediction of bus travel speeds using traffic shockwaves and machine learning algorithms. *Research in Transportation Economics*, Vol. 59, pp. 250–257, 2016. Competition and Ownership in Land Passenger Transport (selected papers from the Thredbo 14 conference).
- [19] Dongjoo Park and Laurence R. Rilett. Forecasting multiple-period freeway link travel times using modular neural networks. *Transportation Research Record*, Vol. 1617, No. 1, pp. 163–170, 1998.
- [20] Andres Ladino, Alain Kibangou, Hassen Fourati, and Carlos Canudas de Wit. Travel time forecasting from clustered time series via optimal fusion strategy. In *2016 European Control Conference (ECC)*, pp. 2234–2239, 2016.
- [21] Xiaohui Huang, Yunming Ye, Liyan Xiong, Raymond Y.K. Lau, Nan Jiang, and Shaokai Wang. Time series k-means. *Inf. Sci.*, Vol. 367, No. C, p. 1–13, nov 2016.
- [22] Sean J. Taylor and Benjamin Letham. Forecasting at scale. *The American Statistician*, Vol. 72, No. 1, pp. 37–45, 2018.




図 4: Coherence の比較




図 5: Topic Diversity の比較




図 6: Euclidean Distance の比較

	Topic 1	Topic 2
26	空調システム_空調_室内_空調装置_外気	強度コンクリート_圧縮強度_剥離_放電破砕装置_コンクリート構造物
14	コンクリート杭_鋼管杭_杭頭処理方法_杭頭処理工法_杭頭処理	コンクリート体_コンクリート製防護壁_サイトp c a 化工法_アン...
35	風力発電装置_風力_発電_ブレード_発電装置	マイクログリッド_電力システム_考え方_小型分散型電源_電気供給系
29	養生方法_養生装置_養生_養生シート_コンクリート養生方法	養生方法_養生_コンクリート用型枠パネル_コンクリート養生型枠...
54	廃棄物処分場_水構造_濁水_水シート_脱水ケーキ	耐震補強構造_耐震性_耐震補強工法_耐震補強方法_耐震性能

図 7: Single モデルで結合されたトピック

	Topic 1	Topic 2
2	本明細書_設済_新設コンクリート_上床版_空気圧送時	機器据付架台_ベDESTAL_プレキャストコンクリートスラブ_配筋...
38	鉄骨梁_鉄筋コンクリート柱_接合部構造_梁床部材接合構造_柱梁...	空隙_岩盤_注入構造_注入_亀裂
25	ジョイント_エキスパンション_エキスパンションジョイント構造_...	梁部材同士_プレキャスト鉄筋コンクリート梁部材同士_h型鋼梁...
21	廃棄体_緩衝材_放射性廃棄物_廃棄体パッケージ_緩衝体	構面内_耐震補強構造_耐震補強壁_複合梁架構_耐震補強要素
43	煙突_解体装置_塔状構造物_屋根_屋根面	建設機械_制限表示ゲート_運転席_作業員_警報装置

図 8: Joint モデルで結合されたトピック