

単語分散表現の結合学習による単語の意味の通時的変化の分析

相田太一¹ 小町守² 小木曾智信³ 高村大也⁴ 坂田綾香⁵ 小山慎介⁵ 持橋大地⁵

長岡技術科学大学¹ 首都大学東京² 国立国語研究所³

産業技術総合研究所/東京工業大学⁴ 統計数理研究所⁵

aida@jnlp.org, komachi@tmu.ac.jp, togiso@ninjal.ac.jp,
takamura.hiroya@aist.go.jp, {ayaka, skoyama, daichi}@ism.ac.jp

1 はじめに

言語は時代とともに変化するものであり、現代社会においても、日々新しい単語が生まれている。既存の単語についても、ある単語が時間の経過とともに、全く異なる意味で使われる場合も少なくない。Hamilton ら [2] は、1800 年代から 2000 年代までの書籍を集めたコーパスである Google Books Ngram¹ を任意の時期で区切り、word2vec [4] を用いて単語分散表現を学習させた。意味が変化した代表的な単語である ‘gay’ や ‘broadcast’ と類似度の高い周辺語の変化から実際の変遷の時期を調査し、

1. 頻度が高い単語ほど意味の変化が起りにくい
2. 多義語は意味が変化する可能性が高い

という 2 つの法則が英語、フランス語、ドイツ語、中国語において成り立つことを示した。昨年、単語の意味の変遷を計算言語学的に調べる Historical Language Change (LChange)² というワークショップが開かれ、単語の意味の変遷について通時的に調査する手法が数多く提案された [6, 7, 8] こともあり、言語学だけでなく様々な分野から注目を集めている。

しかし、これらの研究で扱われている言語は英語や中国語が多く、日本語について調査した研究はほとんど見受けられない。また、手法の多くは、幅広い年代のコーパスを任意の時期で分けた後、分割した時期ごとに独立して単語分散表現を学習させ、線形変換を用いて各時期の単語分散表現の対応を近似的にとるものである [1]。この際には、事前に時期間で意味が変化しない単語をいくつか挙げておき、その単語の分散表現を時期間で近づけるように訓練させた線形回帰モデルを用いる。意味の変遷を調べる対象語についても、意味の変化が自明な単語が例に挙がることが多く、網羅的な分析は行われていない。

そこで、我々はまず従来の Levy ら [3] による共起

行列を用いた単語分散表現学習手法を拡張して、線形変換による対応付けを用いることなしに各時期の単語分散表現を同時に学習させた。次に、学習した分散表現を用いて単語ベクトルの通時的な変化を算出し、ベクトルの変化が大きい単語を中心に意味が変化したとされる単語を、言語学の側面から網羅的に分析した。本論文における貢献を以下に示す。

- 従来の共起行列を用いた単語分散表現の学習手法を拡張することで、線形変換による各時期の分散表現の対応付け、及びそのために時期間で意味が変化しない単語を選ぶことなく、単語の意味の変化を調べることができる。

2 先行研究

Kulkarni ら [1] は、時期毎に単語ベクトルを学習した後で、ある単語 w の近傍ベクトル $\vec{w'}$ を用いて、

$$\Lambda(w, t' \rightarrow t) = \operatorname{argmin}_{\Lambda} \sum_{w'} \|\Lambda \vec{w'} - \vec{w}\|^2 \quad (1)$$

で求められる行列 $\Lambda(w, t' \rightarrow t)$ で単語ごとの局所的な線形回帰で単語ベクトルを対応づけ、検定により単語ベクトルの変化点を検出する方法を提案した。その後 Hamilton ら [2] は、時期 t での単語ベクトルを並べた行列 \mathbf{W}_t を

$$\mathbf{R}(t) = \operatorname{argmin}_{\mathbf{R}: \mathbf{R}\mathbf{R}^T = \mathbf{I}} \|\mathbf{W}_t \mathbf{R} - \mathbf{W}_{t+1}\|_F^2 \quad (2)$$

($\|\cdot\|_F$ は行列のフロベニウスノルム) で求められる回転行列 \mathbf{R} で時期ごとに大域的にアラインした。各単語ベクトルの変化量について単語の頻度と、共起から計算される意味の数について回帰モデルを推定することで、意味の変化について冒頭に示した法則を得ている。

さらに Yao ら [5] は、単語ベクトルを後の式 (1) の観測値 \mathbf{M} について、近似的なカルマンフィルタの形で

$$\frac{1}{2} \sum_{t=1}^T \|\mathbf{M}_t - \mathbf{W}_t \mathbf{W}_t^T\|_F^2 + \frac{\lambda}{2} \sum_{t=1}^T \|\mathbf{W}_t\|_F^2 + \frac{\tau}{2} \sum_{t=1}^T \|\mathbf{W}_{t+1} - \mathbf{W}_t\|_F^2 \quad (3)$$

¹<https://books.google.com/ngrams>

²<https://languagechange.org/events/2019-acl-lcworkshop/>




図 1: 行列分解としての単語ベクトルの学習. 観測値から得られる SPPMI 行列 \mathbf{M} の特異値分解により、左特異行列 \mathbf{X} の各行として得られる単語ベクトルは、Word2vec や GloVe で計算される単語ベクトルと数学的に等価である [3].

を最小にするように \mathbf{W}_t を学習させる方法を示した。これらのいずれも、単語ベクトル間の対応が線形モデルで表されるという強い仮定を置いている [1][2]、単語ベクトルの変化が一様だと仮定している [2][5]、ハイパーパラメータ λ, τ の設定に依存する [5] といった問題がある。

3 提案手法

これに対し、本研究では、意味の変化しない語の指定や、それによる学習後の単語ベクトルの近似的な対応づけを必要としない手法を提案する。Levy ら [3] は、Word2vec [4] や GloVe [9] といった単語ベクトルの学習が、PMI(自己相互情報量)を要素とする共起行列の主成分分析と等価であることを示した。

単語 w とその周辺に現れる文脈語 c との共起回数を $n(w, c)$, w と c それぞれの出現回数を $n(w), n(c)$ としたとき、単語ベクトルの学習は、Shifted Positive PMI

$$M[w, c] = \max \left(\log \frac{n(w, c)}{n(w)n(c)} - \log k, 0 \right) \quad (4)$$

を要素とする (単語 \times 文脈語) の行列 \mathbf{M} を、

$$\mathbf{M} \simeq \mathbf{X}\mathbf{Y} \quad (5)$$

と特異値分解したときの \mathbf{X} の各行に等しい (図 1)[3]。 \mathbf{X} の列数 (および \mathbf{Y} の行数) が単語ベクトルの次元 K であり、以下本研究では $K=100$ とした。式 (4) の定数 k は Word2vec の負例サンプリングにおける負例数に相当し、以下 $k=10$ とした。

この方法を拡張すると、時期の違う単語ベクトルを同時に計算することが可能になる。 \mathbf{Y} の各列である文脈ベクトルが変化しないとすると、時期 1 (たとえば明治時代) における共起行列を \mathbf{M}_1 , 時期 2 (たとえば平成時代) における共起行列を \mathbf{M}_2 とすると、 \mathbf{M}_1




図 2: 提案法による時期毎の単語ベクトルの計算。 \mathbf{X}_1 と \mathbf{X}_2 の同じ行が、異なる時期での同じ単語の単語ベクトルに相当し、これらは同時に最適化される。

と \mathbf{M}_2 を縦に結合した $\mathbf{M} = [\mathbf{M}_1; \mathbf{M}_2]$ も同様に

$$\begin{bmatrix} \mathbf{M}_1 \\ \mathbf{M}_2 \end{bmatrix} \simeq \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix} \begin{bmatrix} \mathbf{Y} \end{bmatrix} \quad (6)$$

と行列分解することができる (図 2)。このとき \mathbf{X}_1 および \mathbf{X}_2 の対応する行が、時期 1 と時期 2 の同じ単語の単語ベクトルとなり、後処理による近似的な対応づけは必要としない。式 (4) および式 (6) の計算は、 $\mathbf{M} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T$ と SVD で分解した後で、 $\mathbf{X} = \mathbf{U}\mathbf{\Sigma}^{1/2}$ とすることで行うことができる。

4 実験

4.1 コーパス

幅広い年代にわたるコーパスとして、国立国語研究所の『日本語歴史コーパス』[12] の一部として公開されている近代雑誌コーパス³ に、「昭和・平成書き言葉コーパス」として構築中の雑誌 (『中央公論』『文藝春秋』) データを追加したものを用いた。コーパス全体は明治 6 年 (1895 年) から平成 9 年 (1997 年) までに刊行された雑誌から成るが、これを 1945 年を挟んだ戦前と戦後に二分割して調査を行った。使用したコーパスの統計量を表 1 に示す。

4.2 実験方法

まず、共起行列を作成する対象となる単語を選定するために、我々は以下の 3 つの条件を設定した。

表 1: 実験に用いた通時コーパスの統計量.

	戦前 (1895–1945)	戦後 (1945–1997)
文数	1,731,335	1,828,240
語数	18,596,776	18,773,979

³https://pj.ninjal.ac.jp/corpus_center/cmj/woman-mag/

表 2: 意味の変化した単語と類似度. 上の段から名詞、動詞、形容詞、副詞の順.

単語	余弦類似度	意味の変化
投入	-0.143	物理的に投げ入れる→手法、労力を導入する
手合い	-0.078	勝負→連中
物言い	-0.041	議論、口論→物を言う
陽性	0.063	電氣的な陽性→病院の診断
温床	0.070	苗床→悪いものが生じる原因
競り	0.091	競うこと→競り売り
奮発	0.113	奮い立たせる→思い切ってお金を使う
生みの親	0.118	子供の実親→製品の開発者
点滴	0.121	水の滴→病院での治療
圧縮	0.127	物理的に小さくする→財源などの規模を小さくする
団塊	0.140	地学関係→「団塊の世代」
管制	0.140	軍事関係→航空関係
突貫	0.162	突撃すること→「突貫工事」
蒸発	0.224	水が蒸発すること→人、物が姿を消すこと
中絶	0.241	物事が途中で途絶えること→人工妊娠中絶
潤う	-0.010	物理的→金銭的
天下る	0.050	天候→官僚用語
押し上げる	0.083	物理的→勢いがつく、官僚用語
色褪せる	0.085	色が薄くなる→年月が経って古くなる
取り組む	0.108	相撲の取り組み→プロジェクトに取り組む
打ち出す	0.227	銃で弾を撃つ→意見を提案する
編み出す	0.324	編み物→意見を提案する
孕む	0.394	子供を孕む→何かを含む
心許ない	0.058	心配、落ち着かない→頼りない
軟らかい	0.233	物理的→人の言動
ぎこちない	0.249	機械的→人の動作
味気無い	0.285	魅力がない→儂い、哀愁漂う
重々しい	0.312	物理的→人の言動
幾許	0.178	量が多いさま→余命を表す
どろどろ	0.243	物理的に混ざり合う→思考などが混ざり合う
遮二無二	0.249	猛烈に→無理に
強か	0.252	量が多いさま→とても強いさま

表 3: 変化はしているが余弦類似度が高い単語: 上の段から名詞、動詞、形容詞の順

単語	余弦類似度	意味の変化
遊撃	0.540	軍事用語→軍事用語、野球の守備位置
免許	0.688	許諾、横綱免許→運転免許、ライセンス
軌道	0.813	惑星軌道、物理的→物理的、プロジェクトなど
障害	0.830	障害物、肉体的な不自由→障害物、肉体・精神的な不自由
通信	0.859	軍事用語→一般的な電波通信
教授	0.898	教えること、大学教授→大学教授
抱える	0.687	物理的→厄介なもの
嘸み付く	0.737	物理的→物理的、議論
曇る	0.742	天候→天候、表情
築く	0.752	建築→建築、時代、体制
乗る	0.878	乗り物に乗る→乗り物、流れ、軌道に乗る
固い	0.693	物理的→物理的、結束、義理
冷たい	0.787	物理的→物理的、態度

- 戦前・戦後それぞれに 20 回以上出現すること
- 品詞が 名詞 | 動詞 | 形容詞⁴ | 副詞 のいずれかであること

- 2 文字以下の平仮名、カタカナは除外する

上記の条件を満たした単語で共起行列を作成し、単語ベクトルを獲得した。今回、文脈語は対象語と同じ単語集合を用いた。コーパス内の各単語は MeCab に

⁴ただし、形状詞 (形容動詞) は対象外とした。

よって UniDic 単位で区切られており、調査対象の単語には見出し語（語彙素）を用いた。また、共起の窓幅は前後 10 単語とし、学習した単語分散表現の後処理として、All-but-the-top [11] を用いた。この理由として、以下の 2 つが挙げられる。

- ベクトルの平均が 0 でない
- 偏った方向を向いている

今回は予備実験からの考察に基づき、後処理を行う主成分の数を 5 とした。次に、得られた単語分散表現をもとに、戦前・戦後において同じ単語の余弦類似度を計算し、余弦類似度の低い単語、つまり戦前から戦後にかけてベクトルに変化があった単語を調査した。

5 結果および考察

得られた結果を表 2 に示す。表 2 は 4 つの行に分かれており、それぞれ上から順に名詞、動詞、形容詞、副詞となっている。この結果より、主に 2 種類の変化が見られていることがわかる。

- 特定の対象に用いられていた語が、別の特定の対象にも用いられるようになる
- 具体的な対象に用いられていた語が、抽象的な対象にも用いられるようになる

1 つ目の変化については、表 2 における「陽性」、「温床」、「奮発」、「管制」、「突貫」、「潤う」、「天下る」、「色褪せる」、「取り組む」などがこれに当てはまると考えられる。この変化は意味の転移と呼ばれており、その単語における元々の対象と別の対象との間に役割や形状といった何らかの類似性が見られる際にこうした変化が起こる [13]。2 つ目の変化については、「投入」、「生みの親」、「蒸発」、「孕む」、「軟らかい」、「ぎこちない」、「味気無い」、「重々しい」などがこれに当てはまると考えられる。この変化は意味の抽象化や比喩的拡張と呼ばれており [13]、「打ち出す」や「編み出す」をはじめとする複合動詞に特によく見られた。

以上の結果より、時期間の余弦類似度が低い単語を抽出することで、事前に対象語を指定することなく変遷を調査することができることがわかる。

次に、意味の変化は見られたが余弦類似度が高く出ている単語を表 3 に示す。表 3 は 3 つの行に分かれており、それぞれ上から順に名詞、動詞、形容詞となっている。得られた結果から、以下の特徴がわかる。

- 従来の意味に加え、新たな使われ方が追加された
- 従来の意味は現在も変わらず用いられている

表 3 の「軌道」、「築く」、「乗る」といった単語の意味

の変化は比喩的拡張に当てはまり、「固い」、「冷たい」といった単語は対象の感覚上の類似性によって起こる共感覚による意味の変化に当てはまる [13] が、本来の使われ方が今も多く用いられているため、ベクトルとしての変化に表れなかったのだと考えられる。

6 おわりに

本研究では、時期ごとの単語分散表現を同時に学習させ、時期間の余弦類似度が低い単語を抽出することで、線形変換の訓練に必要な時期間で意味の変化しない単語、および意味の変遷を調べる対象語を事前に指定せずに単語の変遷を調査した。調査の結果より、対象が変化する単語と対象が抽象化する単語の二種類がよく見られ、後者の抽象化は複合動詞に起こりやすいことがわかった。

今後はこれらの情報を用いて、単語の意味の変遷における規則性を調査していきたいと考えている。

謝辞 本研究は国立国語研究所の共同研究プロジェクト「現代語の意味の変化に対する計算的・統計学的アプローチ」、同「通時コーパスの設計と日本語史研究の新展開」および JSPS 科研費 19H00531, 18K11456 の研究成果の一部を報告したものである。

参考文献

- [1] Vivek Kulkarni, Rami Al-Rfou, Bryan Perozzi, and Steven Skiena. Statistically significant detection of linguistic change. In *Proc. of TheWebConf*, pp. 625–635, 2015.
- [2] William L. Hamilton, Jure Leskovec, Dan Jurafsky. Diachronic Word Embeddings Reveal Statistical Laws of Semantic Change. In *Proc. of ACL*, pp. 1489–1501, 2016.
- [3] Omer Levy and Yoav Goldberg. Neural Word Embedding as Implicit Matrix Factorization. In *Advances in Neural Information Processing Systems 27*, pages 2177–2185, 2014.
- [4] Tomas Mikolov, Kai Chen, Greg Corrado and Jeffrey Dean. Efficient estimation of word representations in vector space. In *Proc. of ICLR*, 2013.
- [5] Zijun Yao, Yifan Sun, Weicong Ding, Nikhil Rao, Hui Xiong. Dynamic Word Embeddings for Evolving Semantic Discovery. In *Proc. of WSDM*, 2018.
- [6] Yang Xu and Jiasheng Zhang. Treat the Word As a Whole or Look Inside? Subword Embeddings Model Language Change and Typology. In *Proc. of LChange*, pp. 136–145, 2019.
- [7] Melvin Wevers. Using Word Embeddings to Examine Gender Bias in Dutch Newspapers, 1950–1990. In *Proc. of LChange*, pp. 92–97, 2019.
- [8] Richard Zimmermann. Studying Semantic Chain Shifts with Word2Vec: FOOD>MEAT>FLESH. In *Proc. of LChange*, pp. 23–28, 2019.
- [9] Jeffrey Pennington, Richard Socher and Christopher D. Manning. GloVe: Global Vectors for Word Representation. In *Proc. of EMNLP*, pp. 1532–1543, 2014.
- [10] William L. Hamilton, Jure Leskovec and Dan Jurafsky. Cultural Shift or Linguistic Drift? Comparing Two Computational Measures of Semantic Change. In *Proc. of EMNLP*, pp. 2116–2121, 2016.
- [11] Jiaqi Mu and Pramod Viswanath. All-but-the-Top: Simple and Effective Postprocessing for Word Representations. In *Proc. of ICLR*, 2018.
- [12] 国立国語研究所 (2019) 『日本語歴史コーパス』 ver.2019.3 <https://pj.ninjal.ac.jp/corpus.center/chj/>
- [13] 沖森卓也, 木村一, 鈴木功真, 吉田光浩. 日本語ライブラリー 語と語彙. 朝倉書店. pp. 100–105, 2012.