

言語モデルが算出する文類似度は人の比喩選択率をなぞるか Does sentence similarity calculated by language models trace people's metaphor selection rate?

岡 隆之介¹⁾, 大島 裕明²⁾, 楠見 孝³⁾

Ryunosuke Oka, Hiroaki Ohshima, Takashi Kusumi

¹⁾三菱電機株式会社, ²⁾兵庫県立大学大学院情報科学研究科, ³⁾京都大学大学院教育学研究科

Mitsubishi Electric Corporation, University of Hyogo, Kyoto University

Qualia1006@gmail.com

概要

本研究では、Oka and Kusumi (2021)で見られた、主題に付与された特徴が増えることで字義文に対する比喩文の言い換えの割合が高まるという現象を、言語モデル (word2vec, BERT) で追試することを目的とする。結果、主題に付与される特徴が増えるほど文間の類似度は大きくなることを確認し、言語モデルは人の比喩選択割合を追試しなかった。一方で、各言語モデルに基づく文の類似度は人の比喩選択割合と正の相関関係にあった。

キーワード：比喩表現 (metaphor), 言語モデル (language model), 文類似度 (sentence similarity)

1. はじめに

ある事柄 (例: 人を傷つけてしまう皮肉) を言い表す際には、字義表現 (例: 彼女の皮肉は人を苦しめる) と比喩表現 (例: 彼女の皮肉はナイフだ) 2つの方法で表現できる場合がある。ある事柄が字義表現と比喩表現の両方で説明可能である場合、私たちはどのような状況で比喩表現を用いるのであろうか。

Ortony[1]は比喩を用いる状況を説明する仮説を2つ提案している。「比喩表現は字義表現で伝えきれない対象を説明する場合に用いられる」とする表現不可能仮説と、「比喩表現は物事を少ない単語で説明する場合に用いられる」とする簡潔性仮説である。これら2つの仮説から、比喩表現は字義表現で伝えきれない多くの特徴 (物事) を説明する場合に用いられる可能性が考えられる。

Oka and Kusumi[2]はこの可能性を検討した。彼らは、主題 (例: 彼女の笑顔) に対して1つ (彼女の笑顔は美しい)、2つ (彼女の笑顔は美しく、明るい)、あるいは3つ (彼女の笑顔は美しく、明るく、華やかだ) の特徴が付与された文を参加者に呈示し、その文の言い換えとして最も適切な表現を選択させる課題を参加者に課した (Experiment 1)。呈示される表現は比喩表現 (彼女の笑顔は花だ)、字義表現 (彼女の笑顔は綺麗だ)、そして無意味なフィラー2

つの計4つであった。主題に付与された特徴は全て、主題と喩辞 (例: 花) で共有される特徴であった。その結果、参加者は主題に付与された特徴の数が増えるほど、比喩表現を選択することが示された。この結果は、ある文の言い換え表現が字義表現となるか比喩表現となるかは、主題に付与された特徴の数によって決まる可能性を示唆した。

ところで、言い換え表現を作成するのは人間だけではない。近年では、自然言語処理技術を用いることで、文の言い換えなどの課題を解くことができる。特に、大規模なコーパスを対象とした事前学習済言語モデルを用いて、様々な課題を解く方法が提案されている。なかでも Mikolov[3]が提案した word2vec モデルは、コーパス中に含まれる単語を、その前後の単語の出現情報を用いて学習することで、単語の意味を表す高品質な数値ベクトルを獲得することに成功した。こうした数値ベクトルを用いることで、2つの単語が類似する意味をもつかを予測することができるようになった。また、近年ではより洗練された言語モデルとして、Devlin et al[4]が提案した BERT モデルがある。BERT は、ある単語の意味を周辺の単語の出現する文脈から学習するだけでなく、その単語を用いて課題を解く際は、周辺の単語の文脈に応じて単語の数値ベクトルを変化させる。この性質のために、BERT は類似文判定課題 (例: STS-B) などの多くの課題で、人間に近い (あるいは、それ以上の) 課題成績を収めることに成功している。

自然言語処理を用いた比喩表現の言い換え研究は、字義表現と比喩表現のペアから比喩表現の言い換えを作成する課題に取り組んでいる。Bizzoni and Lapin[5]は、言い換え元の字義表現と、人手でアノテーションされた比喩表現を含む、4種類の言い換え候補文を入力として、2文が適切な比喩の言い換え文であるか否かを分類するモデルを提案した。このモデルは200セット教師データを基にした教師あ

り学習を基にしたモデルであった。また、Stowe et al[6]は、end-to-end で入力された字義表現を比喻表現に変換するモデルを提案した。このモデルでは、VUMAC[7]などの比喻文に対してアノテーションされたコーパスを用いて比喻文の言い換えモデルを作成し、出力された比喻文の比喻らしさや理解可能性を人手で評価させた。これら2つの研究は、比喻表現と字義表現の言い換えコーパスを用いて、比喻表現の言い換え文や、比喻表現を作成することを試みている。

本研究の目的は、Oka and Kusumi[2]で観測された、主題に付与された特徴の数が増えるほど比喻の選好が高まるという傾向を、言語モデルで追試できるかを検討することである。言語モデルが、人間のように特徴の数が増えるほど比喻を選好するかについては十分に検討されていない。本研究では、人間の比喻選択は文間の類似度に基づいて決定されるという仮定のもと、事前学習済みの言語モデルによって作成される文ベクトルを用いて、2文間の類似度が、特徴数が増えるほど上昇するかを検討する。また、人間の表現の選択率と言語モデルの類似度の間に関連があるかを確認するため、文類似度と表現の選択率の相関関係についても検討する。

2. 方法

刺激 主題に対して特徴(1つ,2つ,3つ)が付与された言い換え元の文と、4種類の選択肢(比喻表現, 字義表現, フィラー1, フィラー2)からなる45セットを刺激とした。刺激の具体例を表1にまとめた。

言い換え元の文の主題は、中本・楠見[8]で報告された名詞隠喩表現の中から主題だけを取り出し、45語用意した。また、主題に付与される特徴は、岡他[9]で報告された名詞隠喩表現を名詞直喩表現に変更して参加者に呈示し得られた解釈のなかで、出現頻度の高い上位3つの解釈を用いた。

4種類の選択肢のうち、比喻表現は言い換え元の主題と対となる名詞隠喩表現を中本・楠見[8]から選択した。字義表現は、上記隠喩の出現頻度の高さが1位の解釈を同義語で置き換えたものを用いた。フィラー1は言い換え元の文の適切な言い換えとはならない喩辞を、言い換え元の主題とは異なる主題と対をなす比喻表現から選択した。フィラー2は、言

い換え元の文の適切な言い換えとはならない同義を、言い換え元の主題とは異なる主題と対をなす字義表現から選択した。

表1. 刺激の具体例

言い換え元/ 選択肢	特徴 (特徴数)
言い換え元 1	彼女の皮肉は人を傷つける (1つ)
言い換え元 2	彼女の皮肉は人を傷つけて、鋭い (2つ)
言い換え元 3	彼女の皮肉は人を傷つけて、鋭く、心に刺さる (3つ)
比喻表現	彼女の皮肉は短刀だ
字義表現	彼女の皮肉は人を苦しめる
フィラー1	彼女の皮肉は吐息だ
フィラー2	彼女の皮肉はぬくい
言い換え元 1	あの蝶は美しい (1つ)
言い換え元 2	あの蝶は美しく、舞う (2つ)
言い換え元 3	あの蝶は美しく、舞い、華やかだ (3つ)
比喻表現	あの蝶は踊り子だ
字義表現	あの蝶はきれいだ
フィラー1	あの蝶は牢獄だ
フィラー2	あの蝶は苦しい

言語モデルと文のベクトル化手法 言語モデルはword2vec[3]とBERT[4]を用いた。

word2vecはコーパス中のある単語とその単語前後の単語の情報を多層パーセプトロンに基づいて獲得する言語モデルである。word2vecは学習方法やハイパーパラメータの設定などで自由度があるが、今回の検討ではベクトル自体の精度については関心がないため、web上で公開されている事前学習済みのword2vecモデルを用いることとした。今回の検討では、東北大学の乾研究室が公開している、日本語Wikipediaエンティティベクトル

(http://www.cl.ecei.tohoku.ac.jp/~m-suzuki/jawiki_vector/)を用いた。ベクトルは200次元であった。トークナイザはMeCabであった。その他のハイパーパラメータの設定はリンク元の設定に従った。文ベクトルは、各単語と対応する数値

ベクトルを平均することで算出した。

BERT は、単語の一部をランダムな確率でマスクすることで、その単語の左右の単語の出現順を考慮して学習する、注意機構付きエンコーダデコーダモデル (Transformer) に基づく言語モデルである。word2vec と同様の理由から、web 上で公開されている事前学習済みの BERT モデルを用いることとした。今回の検討では、huggingface で公開されている cl-tohoku/bert-base-japanese-v2

(<https://huggingface.co/cl-tohoku/bert-base-japanese-v2>) を用いた。単語のベクトルとしては最終層の隠れ層のベクトル (768 次元) を用い、トークナイザは cl-tohoku/bert-base-japanese-v2 準拠のものを用いた。その他のハイパーパラメータの設定はリンク元の設定に従った。文ベクトルは、各単語と対応する数値ベクトルを平均することで算出した。

モデルの評価方法 はじめに、モデルが算出する比喩表現の文類似度が、特徴数が増えるほど上昇するかを検討する。もし、言語モデルが人の比喩選択率をなぞるなら、特徴の数が増えるほど比喩表現との類似度が高くなると予測する。次に、モデルが算出する表現と言い換え元の文類似度が、人の比喩選択率と相関するかを、Oka and Kusumi[2]で求められた各言い換え文の各選択肢の選択率を用いて算出する。

3. 結果と考察

特徴数と文類似度の関係性 選択肢、特徴数ごとの、各モデルと人間の選択率を図 1 にまとめた。図 1 から明らかなように、比喩表現において特徴数が増えても、文類似度が上がることはなく、仮説は支持されなかった。また、特徴数が増えるほど文類似度が低下した。この傾向は比喩・字義・フィルターの選択肢で同様であった。

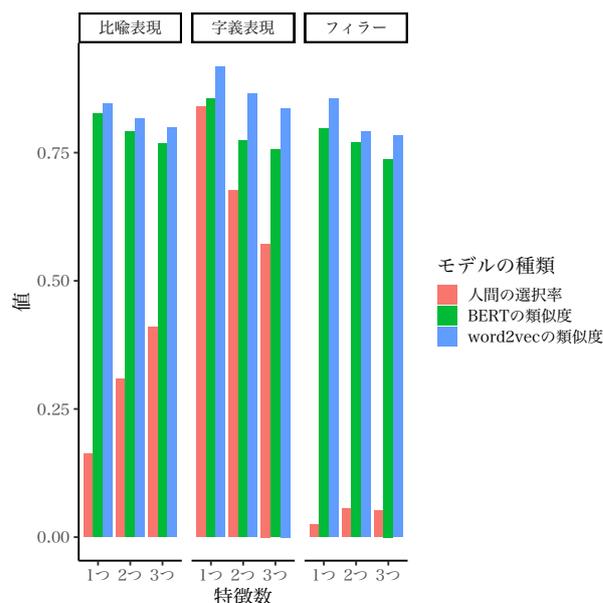


図 1. 選択肢、特徴数、モデルの種類ごとの選択率と文類似度

文類似度と選択肢の選択率の関係性 BERT の文類似度と人の比喩選択率の散布図を図 2 に、word2vec の文類似度と人の比喩選択率の散布図を図 3 に示す。図 2 と図 3 から明らかなように、言語モデルが算出する文類似度は、人の比喩選択率と弱い正の相関関係にあった。また、各モデルの相関係数は BERT で $r = .19, p < .001$, word2vec で $r = .34, p < .001$ であり、word2vec モデルの方がわずかに相関係数が大きかった。

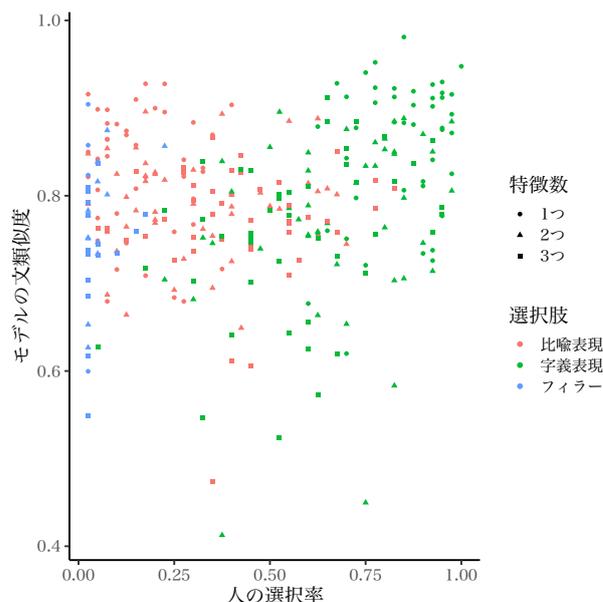


図 2. BERT の文類似度と選択率の散布図

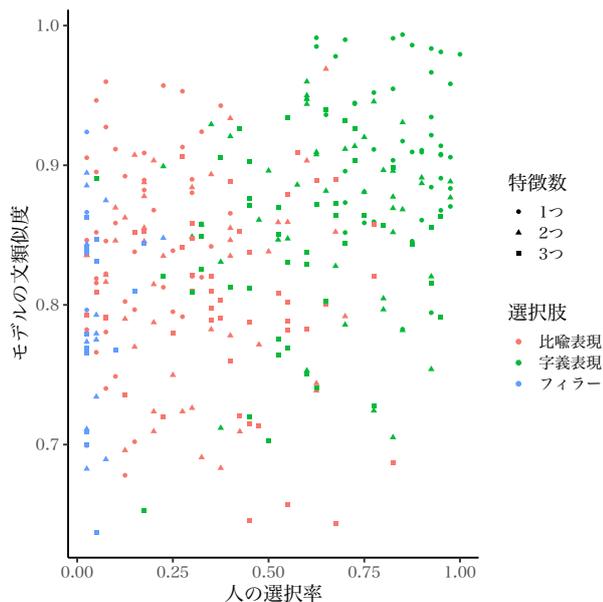


図 3. word2vec の文類似度と選択率の散布図

実験の結果、言語モデルは人の表現の選択率と弱い正の相関関係にはあったものの、Oka and Kusumi[2]で観測されたような、特徴数が増えると類似度が増加するといった関係性は見られなかった。

文献

- [1] Ortony, A. (1975). Why metaphors are necessary and not just nice. *Educational Theory*, 25, 45–53.
- [2] Oka, R., & Kusumi, T. (2021). Number of shared topic-vehicle significant features affects speakers' preference for metaphorical expressions. *Journal of Cognitive Psychology*, 33(2), 157–171.
- [3] Mikolov, T., Sutskever, I., Chen, K., Corrado, G., & Dean, J. (2013, December). Distributed representations of words and phrases and their compositionality. In *Proceedings of the 26th International Conference on Neural Information Processing Systems-Volume 2* (pp. 3111-3119).
- [4] Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019, June). BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)* (pp. 4171-4186).
- [5] Bizzoni, Y., & Lappin, S. (2018, June). Predicting human metaphor paraphrase judgments with deep neural networks. In *Proceedings of the Workshop on Figurative Language Processing* (pp. 45-55).
- [6] Stowe, K., Ribeiro, L., & Gurevych, I. (2020). Metaphoric paraphrase generation. *arXiv preprint arXiv:2002.12854*.
- [7] Steen, G. (Ed.). (2010). *A method for linguistic metaphor identification: From MIP to MIPVU (Vol. 14)*. John Benjamins Publishing.
- [8] 中本敬子・楠見孝 (2004). 比喩材料文の心理的特性と分類基準表作成の試み *読書科学*, 48, 1–10.
- [9] 岡隆之介・大島裕明・楠見孝 (2019). 比喩研究のための直喩刺激-解釈セット作成および妥当性の検討 *心理学研究*, 90, 53–62.