

潜在含意関係認識

Latent Recognizing Textual Entailment

椿 真史 *¹ 新保 仁 *¹ 松本 裕治 *¹
 Masashi Tsubaki Masashi Shimbo Yuji Matsumoto

*¹ 奈良先端科学技術大学院大学
 Nara Institute of Science and Technology

Natural language inference (NLI) is the task to determine whether from a premise sentence we can infer a hypothesis sentence. The recently published large Stanford NLI (SNLI) corpus make it possible to develop and evaluate machine learning methods for NLI such as deep neural networks. In this paper, we propose a new neural machine inference architecture which combine (i) a long short-term memory (LSTM) for representing the premise and the hypothesis, (ii) a latent semantic space to capture the relation between the representations, and (iii) a multiple kernel learning with deep neural network for NLI. This architecture allows us to model semantic inclusion relation between the premise and the hypothesis in the latent space, and learn the multiple kernels including LSTM using an end-to-end network.

1. 背景

含意関係認識とは例えば、「円城塔は『道化師の蝶』で芥川賞を受賞した」という前提文から「円城塔は小説家である」という仮説文が含意関係にあると推論することである。一方で「円城塔は小説家ではない」は矛盾、「村上春樹は SF 作家である」は無関係となる。本稿で我々は、このような推論を機械学習を用いて適切に行うことを目的とする。

ここで我々は含意関係認識を、近年盛んに研究されている意味ベクトル空間 [Pennington 14] をベースにモデル化することを考える。その際に重要となるのは、以下の点である。

前提文と仮説文の関係は意味的な包含関係であり、これをベクトル空間でどのように捉えるのか。

例えば冒頭の例では、前提文と仮説文を入れ替えると含意関係が成り立たない。これはつまり、前提文が持つ意味の範囲が大きく、仮説文がその範囲に含まれるか否かで含意関係が決まるということである。本稿で我々は、このような意味の包含関係を、ベクトル空間においてモデル化することに焦点を当てる。そこで我々は、前提文について以下のように仮定する。

前提文は潜在的に多くの意味を持っている。

つまり、「円城塔は『道化師の蝶』で芥川賞を受賞した」という前提文には「円城塔は小説家である」や「円城塔は『道化師の蝶』の作者である」だけでなく、「『道化師の蝶』は小説である」や「円城塔は人間である」等の様々な意味を潜在的に含むとする。そして、潜在的に持つこれら無数の文の中に仮説の文が含まれる時、2つの文が含意関係にあると判断する。

これまでの議論を踏まえた上で我々は、ベクトル空間における意味の包含関係を以下のようにモデル化する。

前提文を行列 (空間)、仮説文をベクトルで表現した上で、その前提文空間と仮説文ベクトルとの関係として意味の包含関係を捉える。

このように我々は、2つの文に対して空間とベクトルという非対称な表現を用いることで、含意関係認識に重要な意味の包含

連絡先: 椿真史, masashi-t@is.naist.jp

関係をベクトル空間上で自然に扱うことができる。以下の章ではこのアイデアを、具体的に機械学習のモデルとしてどのように実現するかを述べる。

2. 提案法

前提文を行列で、仮説文をベクトルで表現するために我々は、近年成功を収めている long short-term memory (LSTM) [Hochreiter 97, Sutskever 14] を用いる。我々はまず、文中の各単語に対して単語ベクトル $\mathbf{w} \in \mathbb{R}^d$ を割り当て、この単語ベクトルの系列を LSTM の入力とする。仮説文 H に対しては、LSTM の出力を仮説文ベクトル $\mathbf{h} \in \mathbb{R}^d$ とし、

$$\mathbf{h} = \text{lstm}_H(H) \quad (1)$$

と表現する。ここで関数 lstm_H は仮説文 H を入力として仮説文ベクトル \mathbf{h} を出力する LSTM とする。一方で前提文 P は、より高次元のベクトル $\mathbf{p} \in \mathbb{R}^{nd}$ に変換し、これを以下のように行列化 $\mathbf{P} \in \mathbb{R}^{n \times d}$ する。

$$\mathbf{P} = \text{lstm}_P(P). \quad (2)$$

これにより我々は、前提文の行列と仮説の文ベクトルを LSTM を用いて計算することができる。

次に我々は、前提文行列 \mathbf{P} が持つ潜在的な意味空間 $\mathbf{L} \in \mathbb{R}^{n \times k}$ ($k < n$) を抽出するために、 \mathbf{P} を以下のように特異値分解する。

$$\mathbf{P} \approx \mathbf{U}\mathbf{\Sigma}\mathbf{L}^\top. \quad (3)$$

この \mathbf{L} は、前提文が潜在的に持つ様々な意味を含む空間と考えることができる。この前提文が持つ潜在空間と、前述の仮説文ベクトルとの関係で、意味の包含関係をモデル化する。

ここで我々は、前提文行列と仮説文ベクトルを用いてその含意関係を捉えるために、以下のような含意関係スコア s を定義する。

$$s = \frac{1}{|\mathbf{L}|} \sum_{i=1}^{|\mathbf{L}|} \mathcal{K}(\mathbf{L}_i, \mathbf{h}). \quad (4)$$

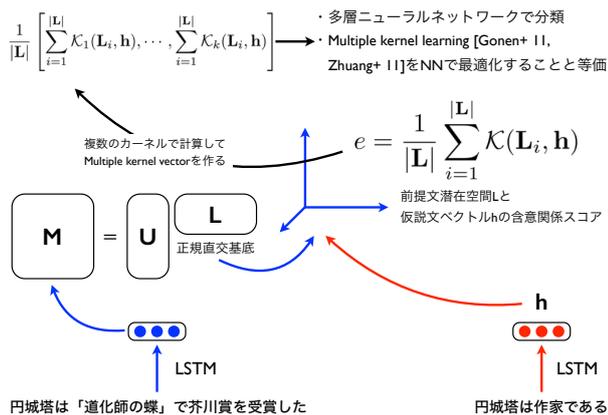


図 1: 提案法の概略図。

ここで、 \mathcal{K} は任意のカーネル関数、 \mathbf{L}_i は行列 \mathbf{L} の i 番目の行ベクトルである。これはつまり、前提文空間の基底ベクトルと仮説文ベクトルとのカーネル平均である。この値が大きければ、それはベクトルが空間に含まれることを意味するため、包含関係を直感的に表現していると考えられる。この包含関係の値は、任意個のカーネルで計算することができ、本稿ではこれを k 個用いた *multiple kernel vector* \mathbf{s} を以下のように計算する。

$$\begin{aligned} \mathbf{s} &= [s_1, s_2, \dots, s_k] \\ &= \frac{1}{|\mathbf{L}|} \left[\sum_{i=1}^{|\mathbf{L}|} \mathcal{K}_1(\mathbf{L}_i, \mathbf{h}), \dots, \sum_{i=1}^{|\mathbf{L}|} \mathcal{K}_k(\mathbf{L}_i, \mathbf{h}) \right]. \end{aligned} \quad (5)$$

特に本稿では以下の、正規化された多項式カーネルを複数用いて、multiple kernel vector を計算する。

$$\mathcal{K}_p(\mathbf{L}_i, \mathbf{h}) = \frac{(1 + \mathbf{L}_i^\top \mathbf{h})^p}{\sqrt{(1 + \mathbf{L}_i^\top \mathbf{L}_i)^p} \sqrt{(1 + \mathbf{h}^\top \mathbf{h})^p}}. \quad (6)$$

つまりベクトル \mathbf{s} は、1 から k 次までの多項式カーネルで計算した値を要素とする k 次元ベクトルであり、これが含意関係ラベルの分類器に対する入力ベクトルとなる。本稿ではその分類器に、通常が多層ニューラルネットワークを用いて、誤差逆伝播法で最適化する。図 1 に提案法の概略図を示す。以上の LSTM、特異値分解、そして multiple kernel vector を入力とした多層ニューラルネットワークは、既存の機械学習ライブラリを用いて end-to-end で構築し学習することができる。

3. 実験

提案法を評価には、Stanford Natural Language Inference (SNLI) [Bowman 15] のデータセットを用いた。訓練/開発/テストデータに含まれる前提文と仮説文のペアの総数はそれぞれ、549367/9842/9824 である。このデータセットではこれらの文ペアについて、entailment(含意)、contradiction(矛盾)、neutral(無関係)の3つのラベルが付与されており、この含意関係ラベルを適切に分類するのが目標である。単語ベクトルの初期値には 300 次元の GloVe^{*1} を、最適化には Adam

*1 <http://nlp.stanford.edu/projects/glove/>

手法	精度 (%)
[Bowman 15]	77.6
[Rocktäschel 15]	83.5
[Wang 15]	86.1
[Cheng 16]	89.1
提案法	66.6

表 1: 既存法と提案法の精度比較。

[Kingma 14] を用いた。また提案法はすべて Chainer^{*2} で実装し、multiple kernel vector における多項式カーネルの次数は 6 次まで、含意関係ラベルの分類器である多層ニューラルネットワークは 3 層とした。

表 1 に、既存法と提案法の精度を示す。提案法は既存法と比較して精度が低い結果となった。特に性能が良い 3 つ既存法 [Rocktäschel 15, Wang 15, Cheng 16] はすべて、neural attention を用いた LSTM である。この手法は、ニューラルネットワークを用いて 2 つの文のソフトアライメントを取るものであり、含意関係認識においてアライメントが重要な役割を果たしていることを示唆している。

しかしながら、アライメントを適切に捉えることが含意関係の精度を向上させている要因には疑問が残る。例えばこのデータセットが、2 文間の主語や目的語、さらには否定語のアライメントによって含意関係がほぼ決まるようなデータで占められているだけとも考えられる。今後の課題として、データを詳細に分析する必要がある。

4. 結論

本稿では、含意関係認識のための新たなモデルを提案した。提案法の優位性を確認するには至らなかったものの、アライメントがどの程度含意関係認識の精度向上に寄与するのかを分析するという新たな課題が見えてきた。

参考文献

- [Bowman 15] Bowman, S. R., Angeli, G., Potts, C., and Manning, C. D.: A large annotated corpus for learning natural language inference, in *Proceedings of the Conference on Empirical Methods on Natural Language Processing (EMNLP)* (2015)
- [Cheng 16] Cheng, J., Dong, L., and Lapata, M.: Long Short-Term Memory-Networks for Machine Reading, *arXiv preprint arXiv:1601.06733* (2016)
- [Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)
- [Kingma 14] Kingma, D. and Ba, J.: Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980* (2014)
- [Pennington 14] Pennington, J., Socher, R., and Manning, C.: Glove: Global Vectors for Word Representa-

*2 <http://chainer.org/>

tion, in *Proceedings of the Conference on Empirical Methods on Natural Language Processing (EMNLP)* (2014)

[Rocktäschel 15] Rocktäschel, T., Grefenstette, E., Hermann, K. M., Kočiský, T., and Blunsom, P.: Reasoning about Entailment with Neural Attention, *arXiv preprint arXiv:1509.06664* (2015)

[Sutskever 14] Sutskever, I., Vinyals, O., and Le, Q. V.: Sequence to sequence learning with neural networks, in *Advances in Neural Information Processing Systems (NIPS)* (2014)

[Wang 15] Wang, S. and Jiang, J.: Learning Natural Language Inference with LSTM, *arXiv preprint arXiv:1512.08849* (2015)