

# 共起を考慮した単語の特徴ベクトルの 主成分回帰分析による推理小説の犯人推定

勝島修平<sup>1</sup> 穴田一<sup>1</sup>

**概要:** 近年、機械学習の発展に伴い、これらの技術への社会的な期待が高まっている一方、専門家でも結果に対して解釈を与えられない解釈可能性が問題となっている。そんな中、解釈可能性を題材とした推論を行うコンテスト「ナレッジグラフ推論チャレンジ」が開催された。既存研究では、単語の意味の学習のために埋め込みに基づく手法が提案されているが、事象の同時性を考慮していない。そこで、本研究では単語の共起を考慮した特徴ベクトルに対する主成分回帰分析を用いた手法を提案する。

**キーワード:** 解釈可能性, ナレッジグラフ, vLBL, 主成分回帰分析

## A Criminal Detection of Mystery Novel Using the Principal Components Regression Analysis of the Feature Vector of Word Considering Co-Occurrence Words

SHUHEI KATSUSHIMA<sup>†1</sup> HAJIME ANADA<sup>†1</sup>

**Abstract:** In recent years, there is an interpretability problem that even experts cannot explain the reasoning process of machine learning. A contest featuring interpretability, “First Knowledge Graph Reasoning Challenge 2018,” was held in Tokyo. To learn the sense of word in the novel, a previous study proposed a method that was based on word embedding. However, it did not consider the flow of events. In this study, considering co-occurrence words, we propose a method using the principal components regression analysis of the feature vector of words

**Keywords:** Interpretability, Knowledge Graph, vLBL, Principal Components Regression Analysis

### 1. はじめに

近年、機械学習の発展に伴い、これらの技術への社会的な期待が高まっている一方、専門家でも結果に対して解釈を与えられない解釈可能性が問題となっている。そんな中、解釈可能性を題材とした推論を行うコンテスト「ナレッジグラフ推論チャレンジ」(以下、チャレンジ 2018)が開催された[1]。

既存研究では、黒川らが元の小説データをトリプルと呼ばれる構造に変換し、TransE[2]と呼ばれる埋め込み手法を用いることによって単語をベクトルに変換し、ベクトルのトリプル関係から犯人推定を行っている。しかし、小説データをトリプルに変換したことによって、本来同時に学習されるべき場所や時間といった、目的語の同時性に関する情報が失われてしまう。

本研究では、トリプルごとの学習を行う手法ではなく、一文章内で同時に出現する単語に着目した学習を行う。そして、得られた単語の特徴ベクトルに対して、主成分回帰分析を用いることによって犯人推定を行う手法を提案する。

### 2. ナレッジグラフについて

チャレンジ 2018 では、場面間の時間経過を考慮するために、内容を場面ごとの最小単位に分割したものに ID を付与し、登場人物やその行動の関係をナレッジグラフと呼ばれるデータ構造で表現した。図 1 にナレッジグラフのイメージを示す。

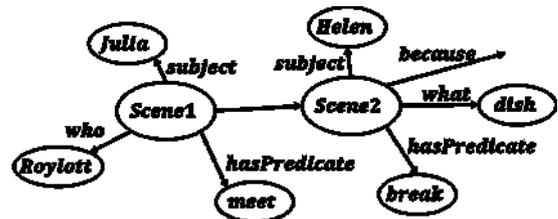


図 1 ナレッジグラフのイメージ

図 1 における場面間の関係(矢印で表される遷移)の例を以下に記す。

- subject: 場面間の記述において主語となる人やモノ
- hasPredicate: 場面の内容を表す述語
- 場面の詳細を表す目的語: who(誰), what(何)
- 場面間の関係: then, because など…

<sup>1</sup> 東京都市大学大学院 総合理工学研究所  
Graduate School of Integrative Science and Engineering, Tokyo City  
University Graduate School

### 3. 既存研究

既存研究では、与えられたナレッジグラフ上の単語の意味の学習を、TransE と呼ばれる埋め込み手法を用いて行った。TransE では、トリプルと呼ばれる、〈主語・述語・目的語〉で構成された単語それぞれにベクトルを割り当て、そのトリプルの正誤を判断しながら文章の学習を行う。

既存研究では、単語の学習に TransE を用いるために、小説ナレッジグラフをトリプルと呼ばれる単位に変換した。しかし、一つの文章からトリプルを生成する際に、2つ以上ある目的語(場所や時間、対象物)のそれぞれを分割し、主語と述語にそれぞれ付け加えることでトリプルを構成している。これではトリプル同士の時間的関係は考慮されておらず、本来単語の持っている同時性の情報が失われている。

### 4. 提案手法

本研究では、小説上の単語を Mnih らによって提案された vLBL(vector Log-Bilinear Language model)[3]を用いて、同一文内の単語の共起に関する学習を行う。これにより、一文で同時に出現する単語の情報を学習し、その単語同士のベクトルの類似度を高めることができる。そしてその特徴ベクトルを利用した回帰モデルを構築し、犯人推定を行う。

#### 4.1 vLBL

vLBL では、各単語を決められた次元数のベクトルで表現し、文中の1つの単語を対象として、その単語のベクトルと文脈内の各単語のベクトルの類似度が高くなるように学習を行う。

一文の  $t$  番目の対象単語  $w_t$  のベクトルを  $\mathbf{w}_t$ 、 $\mathbf{w}_t$  から相対的に  $i$  語離れた位置にある周辺単語  $w_{t+i}$  のベクトル  $\mathbf{w}_{t+i}$ 、周辺単語  $c$  を  $\mathbf{w}_t$  の前後  $n$  単語として、vLBL における  $c$  と  $\mathbf{w}_t$  の類似度を示すスコア関数  $s_{vLBL}(c, \mathbf{w}_t)$  を次式で表す。

$$s_{vLBL}(c, \mathbf{w}_t) = \mathbf{c} \cdot \mathbf{w}_t \quad (1)$$

$$\mathbf{c} = \frac{1}{2n} \sum_{-n \leq i \leq n, i \neq 0} \mathbf{w}_{t+i}$$

ここで、 $n$  は周辺ベクトルを獲得するために参照する前後の単語数、 $\cdot$  は内積を表す。スコア関数は、ベクトルの内積を計算し、値が高いほど類似度が高いことを示す。(1)で定義したスコア関数を利用した損失関数  $g_t$  を次式で表す。

$$g_t = - \left( \log \sigma(s(c, \mathbf{w}_t)) + \sum_{w'_i \sim P_n} \log(1 - \sigma(s(c, w'_i))) \right) \quad (2)$$

ここで、 $\sigma(x)$  はシグモイド関数、 $k$  は学習を進めるためにサンプリングする負例の単語  $w'_i$  の生成数、 $P_n$  は単語の頻度分布、第二項は確率分布  $P_n$  によって  $k$  単語サンプルすることを示す。ランダムに選択された対象単語の(2)式に対する勾配を求めて対象単語のベクトルの更新を行い、それをすべての単語に対して行うようにエポックを重ねることで、文脈内の単語のベクトルと対象単語は類似し、文脈外の単語とは相違するようにする。

### 4.2 主成分回帰分析

#### 4.2.1 主成分分析の入力

入力データとして、マルチホットベクトルを用いる。具体的には、小説に出てくる単語の種類数分の次元のベクトルを用意し、一文に対して登場する単語の要素を1とした文章ベクトルを生成する。

#### 4.2.2 回帰分析の目的変数

前項の入力に対し、主成分分析を行う事により得られた主成分が、単語“kill”に対して与える影響度を調べるための目的変数  $L$  を以下に定義する。

$$L = \mathbf{w}_{kill} \cdot \mathbf{sv} \quad (3)$$

$$\mathbf{sv} = \frac{1}{n} \sum_{i=0}^n \mathbf{w}_i$$

ここで、 $\mathbf{w}_{kill}$  は単語“kill”のベクトル、 $n$  は入力となる一文の単語数、 $\cdot$  は内積を表す。 $L$  は一文の文ベクトルと単語“kill”との類似度が高いほど大きい値となる。

### 5. 結果

実験に用いたパラメータを表1に示す。

表1 実験に用いたパラメータ等

使用単語数	1026	エポック数	1000
使用文章数	1184	バッチサイズ	32
ウィンドウサイズ	10	最適化	Adam
サンプルサイズ	10	次元数	100
学習率	0.01	初期値	Xavier

得られた回帰モデルの偏回帰係数の最も高かった第18主成分の因子負荷量値を表2に示す。

表2 第18主成分の因子負荷量(上位10個)

equalTo	0.52324
money	0.347543
death_day_of_mother_of_Helen	0.140126
price_of_asset_of_mother_of_Helen	0.139821
bedroom_of_Helen	0.120667
corridor	0.120589
smell	0.114758
go	0.104965
mansion_of_Roylott	0.086882
take	0.085447

表2にある通り、「まだらの紐」における殺害動機である金銭を示す因子を抽出した。

実験結果の詳細については、発表にて報告を行う。

### 参考文献

- [1] 川村 隆浩, 江上 周作, 松下 京群, “第1回ナレッジグラフ推論チャレンジ2018 開催報告~説明性のある人工知能システムを目指して~”, 人工知能学会研究会報告, Vol.34, No.3 (2019)
- [2] Antoine Bordes, Nicolas Usunier, Alberto Garcia-Duran “Translating Embeddings for Modeling Multi-relational Data”, In Proceedings of the 26th International Conference on Neural Information Processing Systems(NIPS'13) (2013)
- [3] Andriy Mnih, Koray Kavukcuoglu, Learning word Embeddings efficiently with noise contrastive estimation, In NIPS 26, pp. 2265-2273 (2013)