


さくっと

テーマ

単語ベクトル



「さくっと」とは？

興味のある分野について、さくさくと勉強が進むように作成された調べ方ガイド(パスファインダー)です。みなさんの学習支援を行う図書館学生サポーターが作成しました。

ぜひ学習の際に参考にしてください。

図書館学生サポーター 上野

1-1) 単語ベクトルとは？

単語ベクトルとはその名の通り、単語の意味をコンピュータが理解しやすいように数値(ベクトル)で表現したものです。大まかなイメージとしては、下図のような感じです。(値は適当です)

	リンゴ	犬	プログラム
知性	0.00	0.78	0.99
癒し	0.13	0.96	0.08
赤色	1.00	0.36	0.00
...	...	...	...

単語ベクトルに関連するキーワード

自然言語処理(NLP), 生成AI, Semantic Search, 機械翻訳, チャットボット, コサイン類似度, Word2Vec, Transformer

リンゴ, 犬, プログラムはベクトル化したい単語です。知性, 癒し, 赤色 は、意味的な軸(**特徴次元**)と呼ばれるものになります。実際には、数百～数千もの高次元ベクトルになります。

1-2) 単語をベクトル化するメリット

一般的にコンピュータは、文字を認識しても**単なる字面の解釈に過ぎず**, **意味や文脈(コンテキスト)**まで理解することはできません。

そこで、単語をベクトル化することで、似た意味の単語が近い位置関係で表されるようになり、コンピュータが「意味の近さ」や「文の構造」を数学的に扱えるようになります。

これにより、翻訳や要約、質問応答などの自然言語処理タスクで、より柔軟かつ人間らしい理解や出力が可能になります。

従来の検索クエリ

- 「柴犬」と「秋田犬」のような部分一致検索は可能

```
SELECT * FROM animals WHERE name LIKE '%犬';
```

- 「犬」と「ワンちゃん」は、別物とみなされる。

単語ベクトル

- 意味に着目するため、「犬」と「ワンちゃん」を同義とみなせる



1-3) コサイン類似度 ～意味が似ている度合いの定量化～

英単語のDog(犬)とPuppy(子犬)の意味が似ているのは自明ですが、「どのくらい似ているのか？」と問われると、答えに困るかと思います。そこで登場するのが単語ベクトルです。

単語ベクトルなら、「似ている度合い」を定量化できます！
実際に計算してみると…

🔄 'dog' と 'puppy' のコサイン類似度: 0.8072

コサイン類似度は、
$$-1 \leq \cos(x, y) = \frac{\langle x, y \rangle}{||x|| ||y||} \leq 1$$

という式で計算され、-1が真逆の意味、1が同一の意味となりますので、DogとPuppyはかなり高い度合いで意味が似ていることが定量的に分かります。

1-4) 言葉の足し算・引き算

単語ベクトルもベクトルの一種なので、高校数学で習ったように加減算ができます。

例えば、「パリ」-「フランス」+「日本」=「東京」といった具合です。

この演算は、パリ - フランスで『フランスに対する首都』という意味成分を抽出し、それを日本に加えることで『日本の首都』にあたる単語(=東京)を推論するイメージです。

実際に演算してみると…

```
paris - france + japan =  
tokyo: 0.6345
```

「東京」が出てきました！

2. 学習のために

一般向けに書かれた本

- ・Pythonで動かして学ぶ自然言語処理入門. 柳井孝介, 庄司美沙.
飯塚分館, 閲覧3階 548.96 Y-100, 006080151

理解を深めるための本

- ・ゼロから作るDeep Learning ②—自然言語処理編. 斎藤 康毅.
飯塚分館, 閲覧3階 548.91 Sa252, 006078615

3. 付録 実行したソースコード（Google Colabで実行できます）

```
!pip install gensim numpy scipy

# Gensimのモデルローダーを使う
from gensim.models import KeyedVectors

# 事前学習済みモデルをダウンロード
import gensim.downloader as api

print("Downloading model (これには数分かかります)...")

model = api.load('fasttext-wiki-news-subwords-300')

print("Download complete.")

# 単語ベクトルの演算を実行
result = model.most_similar(positive=["paris", "japan"], negative=["france"], topn=2)

# 結果の表示
print("paris - france + japan =")
for word, score in result:
    print(f" {word}: {score:.4f}")

def calculate_cosine_similarity(model, word1, word2):
    try:
        similarity = model.similarity(word1, word2)
        return similarity
    except KeyError:
        print(f"'{word1}' または '{word2}' はモデルに存在しません。")
        return None

# DogとPuppyのコサイン類似度を計算
word_a = "dog"
word_b = "puppy"

similarity_ab = calculate_cosine_similarity(model, word_a, word_b)

if similarity_ab is not None:
    print(f"'{word_a}' と '{word_b}' のコサイン類似度: {similarity_ab:.4f}")
```

4. 参考資料

[1] 株式会社Spot. DeepAge. “Word2Vec:発明した本人も驚く単語ベクトルの驚異的な力”. 2016-09-2.
https://deepage.net/bigdata/machine_learning/2016/09/02/word2vec_power_of_word_vector.html, (参照 2025-07-03)

コードの作成には, 生成AI(ChatGPT)を使用しています.

