

JAECS 2018 年度 春季研究会

**語の意味的粒度とコロケーションに関する試論  
word2vecを用いた概念ネットワーク構築**

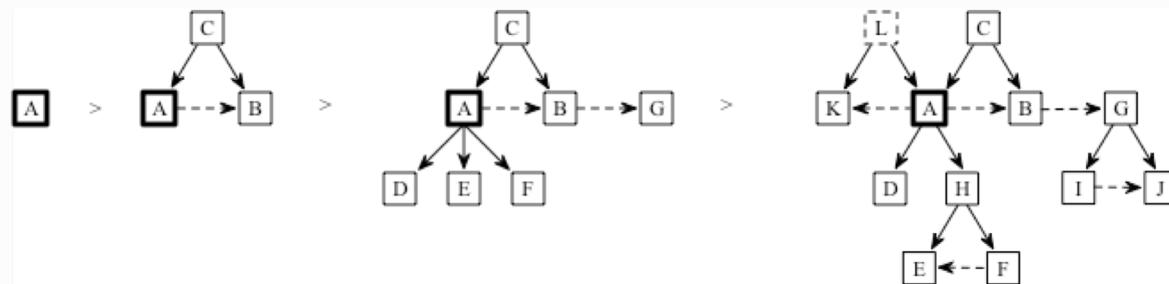
**長谷部 陽一郎**

**同志社大学**

# はじめに

## 本発表で扱う理論的な問い合わせ

- コロケーション情報に基づいて語彙概念ネットワークのモデルを構築するにはどうしたらよいか
- 言語使用者の直感に合致する結果を得るには語の意味的な粒度や階層性を考慮する必要があるのではないか



Langacker (1990: 271)

本発表では上記の問い合わせについて考えるべく進めている研究の途中経過を話します。

# はじめに

## 技術的な課題

- 大規模なコーパス・データから共起情報を抽出し、**語どうしで比較できる形**にするにはどうしたらよいか
- 意味の粒度を考慮できる（内容的・サイズ的に）**適切なデータセット**を用意するにはどうしたらよいか

## 本発表で提案する方法

- **Wikipedia**のダンプデータのカテゴリー情報から意味の領域を適切に切り分けたサブコーパスを作成して、**word2vec**を用いた分析を実施

# word2vecについて

## 特徴

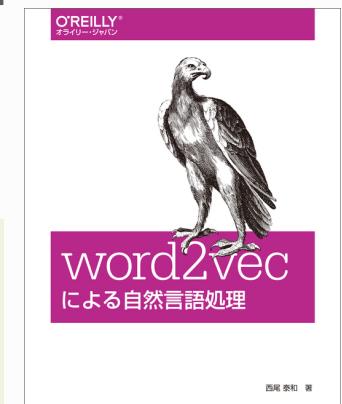
- 2層のニューラルネットを用いた、**分散表現**（word embeddings）を作成するための手法
- 語の意味を共起情報に基づいて**ベクトル化**
- 語どうしで意味を「**計算**」できる

## 文献

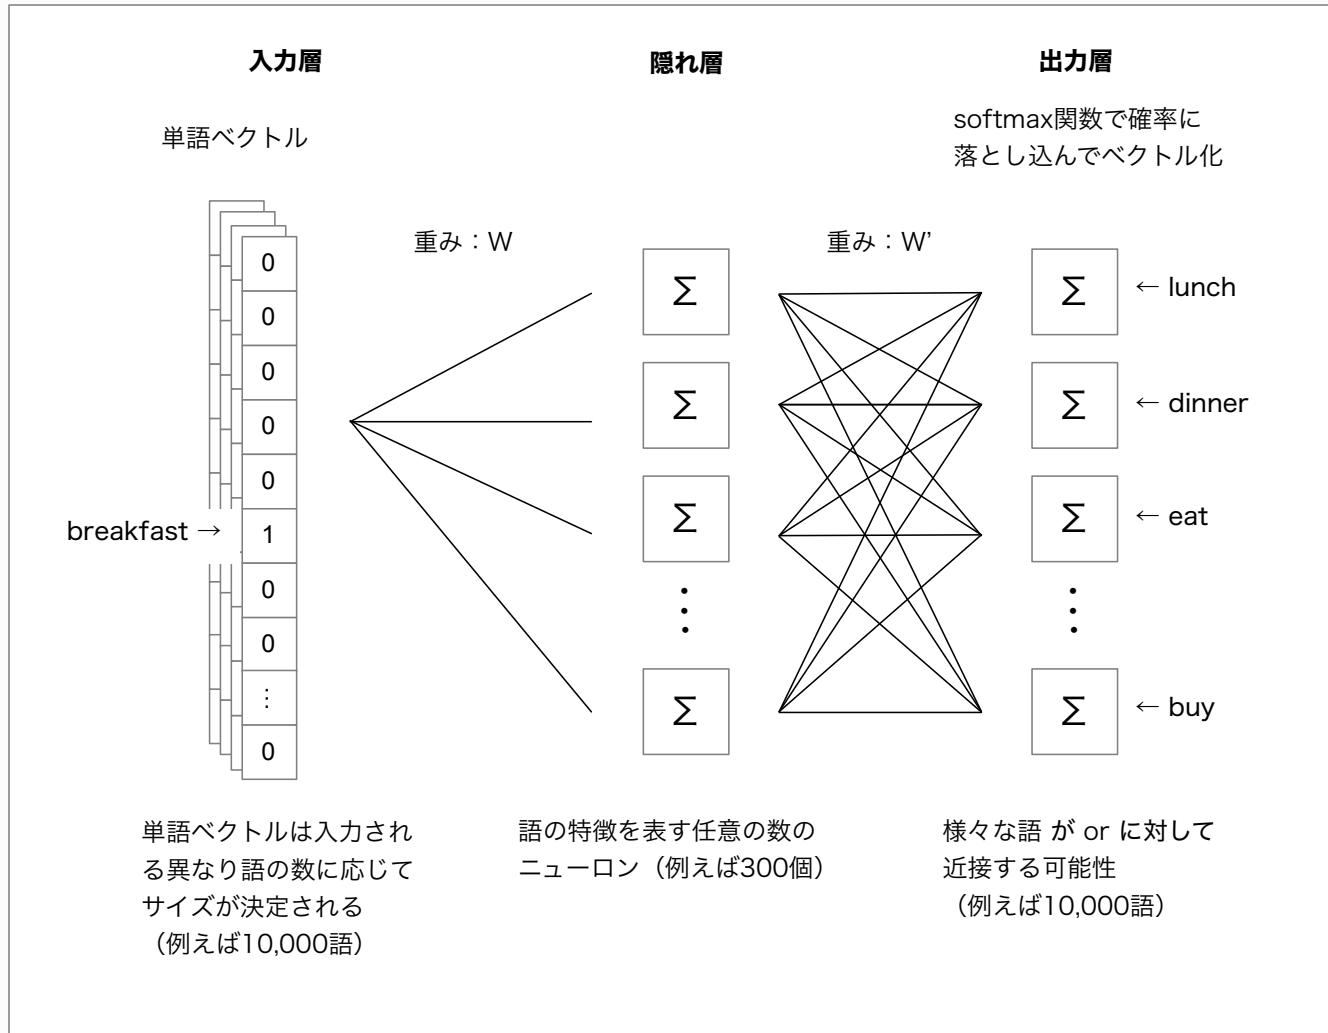
- **Mikolov, Tomas, et al. 2013.** Efficient Estimation of Word Representations in Vector Space. arXiv:1301.3781
- **西尾泰和. 2014** 『word2vecによる自然言語処理』  
オライリー.

など

拙作wp2txtを用いて  
日本語Wikipediaデータを抽出する  
方法も載っています。



# word2vecについて



McCormic (2016) を参考に作図

# Wikipedia (enwiki) テキストの抽出

## データの性質

- 公式サイトで定期的にスナップショットが配信されている  
2018年4月1日版・・・BZ圧縮ファイル約16GB  
[https://en.wikipedia.org/wiki/Wikipedia:Database\\_download](https://en.wikipedia.org/wiki/Wikipedia:Database_download)
- 約500万件の記事・約20億語・テキストファイル約14GB

## ダンプデータからテキストデータを得るには・・・

- wp2txt: Wikipedia dump file to text converter**  
<https://github.com/yohasebe/wp2txt>
- 上記ツールでは本文プレーンテキストの他、各記事の  
**カテゴリー属性**を取得することができる。 (長谷部 2006)

# Wikipedia (enwiki) テキストの抽出 [結果]

The screenshot shows a terminal window with the following interface elements:

- WindowTitle**: タイトル (Title)
- TabLabel**: 1. zsh
- TextContent**: The main text area contains the Wikipedia page for "Anarchism".
- Annotations**:
  - Category**: A red box highlights the "CATEGORIES" section at the top of the text content.
  - Intro**: A red box highlights the first three paragraphs of the main text content.
  - Etymology**: A red box highlights the section starting with "==Etymology and terminology==".
  - WordOrigin**: A red box highlights the detailed explanation of the word "anarchism" from paragraph 13.

1. [[Anarchism]]

2. CATEGORIES: Anarchism, Anti-capitalism, Anti-fascism, Far-left politics, Libertarian socialism, Political culture, Political ideologies, Social theories

3. Anarchism is a political philosophy that advocates self-governed societies based on voluntary institutions. These are often described as stateless societies, although several authors have defined them more specifically as institutions based on non-hierarchical or free associations. Anarchism holds the state to be undesirable, unnecessary and harmful.

4. While opposition to the state is central, anarchism specifically entails opposing authority or hierarchical organisation in the conduct of all human relations. Anarchism is usually considered a far-left ideology and much of anarchist economics and anarchist legal philosophy reflects anti-authoritarian interpretations of communism, collectivism, syndicalism, mutualism or participatory economics.

5. Anarchism does not offer a fixed body of doctrine from a single particular world view, instead fluxing and flowing as a philosophy. Many types and traditions of anarchism exist, not all of which are mutually exclusive. Anarchist schools of thought can differ fundamentally, supporting anything from extreme individualism to complete collectivism. Strains of anarchism have often been divided into the categories of social and individualist anarchism or similar dual classifications.

6. ==Etymology and terminology==

7. The word "anarchism" is composed from the word "anarchy" and the suffix -ism, themselves derived respectively from the Greek ἀναρχία, i.e. anarchy (from ἀνάρχος, anarchos, meaning "one without rulers"; from the privative prefix ἀ- (an-, i.e. "without") and ἄρχος, archos, i.e. "leader", "ruler"; (cf. archon or ἄρχη, arkhe, i.e. "authority", "sovereignty", "realm", "magistracy")) and the suffix -ισμός or -ισμα (-ismos, -isma, from the verbal infinitive suffix -ίζειν, -izein). The first known use of this word was in 1539. Various factions within the French Revolution labelled opponents as anarchists (as Maximilien Robespierre did the

# Enwiki-Intro Corpusの作成

Wikipediaデータのどの部分を見るか・・・

- 各記事のイントロダクションのテキストを抽出  
→ データ量の削減・不要データの排除のため  
→ カテゴリーへの帰属度の高いデータを効率的に抽出  
**特定の事物や概念を「説明」するテキストのコーパスを得る**

得られたコーパス

- Enwiki-Intro Corpus**  
bz2圧縮ファイル約1.1GB・テキストファイル約3GB  
4,939,000記事・460,694,181語
- 公開の方法や時期は今のところ未定（圧縮データ or 構築ツール）

# Enwiki-intro Corpusの作成

## インターフェイスの作成

- 記事のカテゴリー、タイトル、本文（イントロ）をRDBに格納
- SQLでカテゴリー属性テキストの部分検索による絞り込み、領域を絞ったサブコーパスを作成できるように
- カテゴリーと記事タイトルは「多対多」の関係**  
部分検索を工夫することでかなり柔軟に絞り込みが可能

```
1 select categories.title as ctitle, articles.id as aid, articles.title as atitle,
2 articles.introduction as intro from categories
3 inner join articles_categories on categories.id = articles_categories.category_id
4 inner join articles on articles.id = articles_categories.article_id
5 where categories.title ~* 'language' or categories.title ~* 'linguistics'
6
```

< Load Query... Save Query... Cancel Execute Statement

ctitle	aid	atitle	intro
English-language idioms	397	Bootstrapping	In general, bootstrapping usually refers to a self-starting process that is...
C (programming language)	42	ANSI C	ANSI C, ISO C and Standard C refer to the successive standards for the C pro...
Programming language standards	42	ANSI C	ANSI C, ISO C and Standard C refer to the successive standards for the C pro...
English-language films	56	Army of Darkness	Army of Darkness is a 1992 American horror comedy film directed and co-writt...
English-language films	88	The Birth of a Nation	The Birth of a Nation is a 1915 American silent epic drama film directed and...
Member states of the Dutch Language Union	93	Belgium	Belgium ,België Nl-belgie.ogg; Belgique Fr-belgique.ogg; Belgien De-belgien...
17th-century Latin-language writers	112	Baruch Spinoza	Baruch Spinoza was a Dutch philosopher of Sephardi/Portuguese origin. ...
Regions of Europe with multiple official languages	201	Brussels	Brussels , officially the Brussels-Capital Region , is a region of Belgium c...
Agglutinative languages	209	Basque language	Basque is the language spoken in the Basque country. ...
Basque language	209	Basque language	Basque is the language spoken in the Basque country. ...
Languages of France	209	Basque language	Basque is the language spoken in the Basque country. ...
Synthetic languages	209	Basque language	Basque is the language spoken in the Basque country. ...
Subject-object-verb languages	209	Basque language	Basque is the language spoken in the Basque country. ...

# 作成できるサブコーパスの例

## 芸術・メディア

- art または media を含むカテゴリー → 約40MB • 6,556,683語

## ビジネス

- business\_ を含むカテゴリー → 約31MB • 4,980,842語

## コンピュータ・ソフトウェア

- computer\_ または softwareを含むカテゴリー → 約26MB • 4,103,806語

## 動物・植物

- plantsまたはanimal\_ を含むカテゴリー → 約23.5MB • 3,803,610語

## 政治

- politic\_ を含むカテゴリー → 約110MB • 18,017,634語

## 社会

- social\_ またはsocietyを含むカテゴリー → 約34MB • 5,530,901語

# word2vecによる分析処理

## Gensim (3.4.0) word2vec モジュール

以下の「例」では次の設定を使用

```
from gensim.models import Word2Vec
min_count = 5
size = 300
window = 5
model = Word2Vec(sentences,
                  min_count = min_count,
                  size = size,
                  window = window)
```

- 生起頻度 5 以上の語を対象とする
- 隠れ層の次元は 300
- 近接語は左右各 5 語

# word2vecの使用例 1

芸術・メディア サブコーパス

処理対象異なり語数：48,618

“idea” の意味的近接語

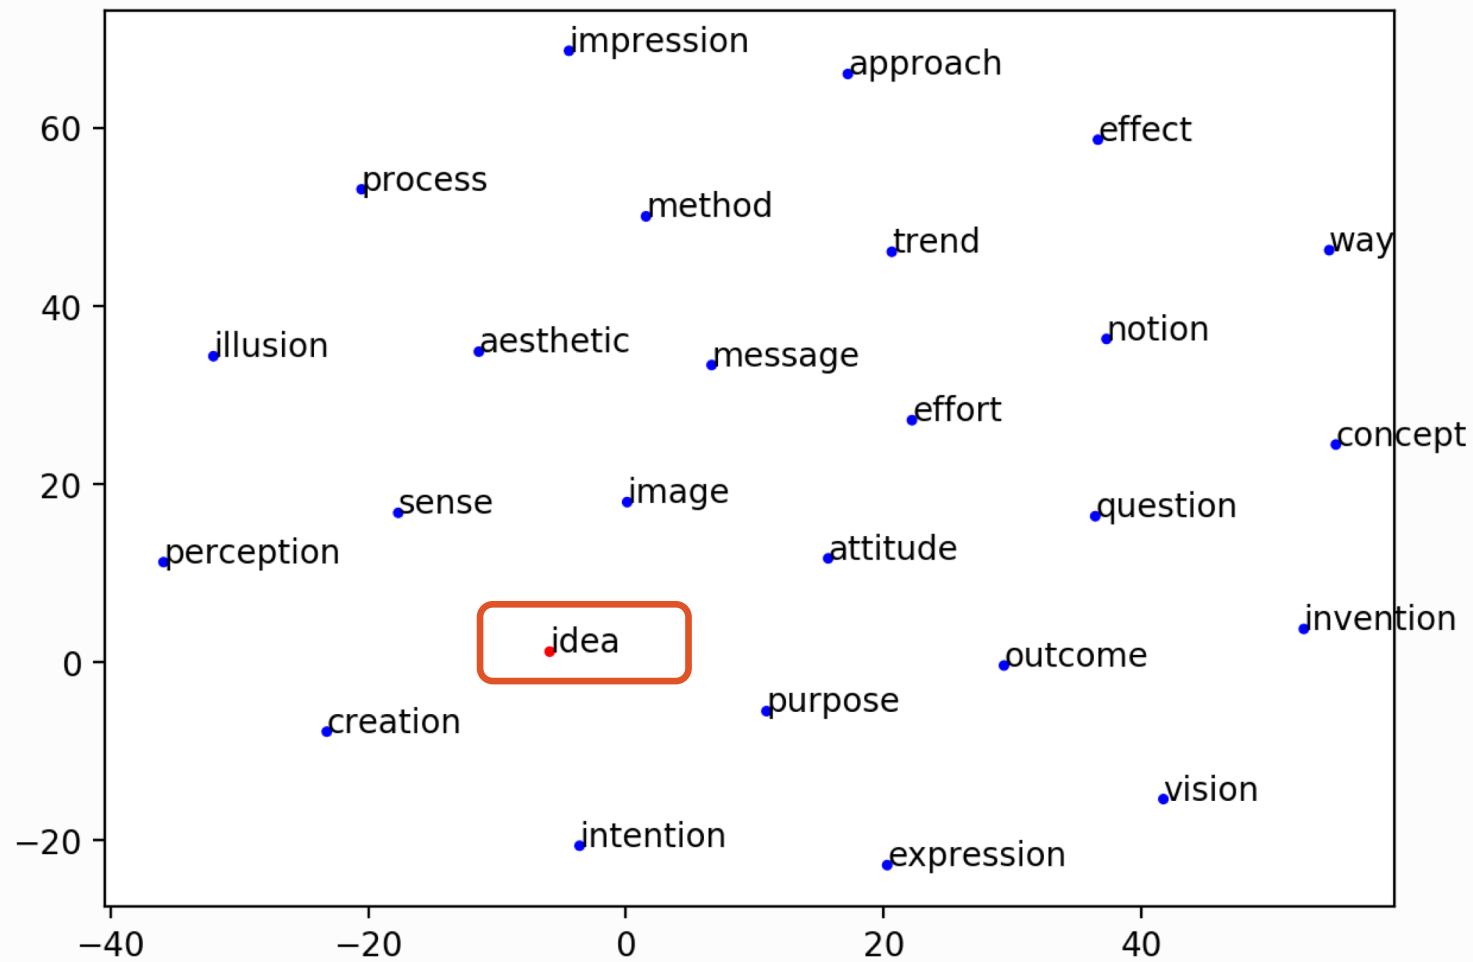
```
model.wv.similar_by_word ('idea', topn = 25)
```

```
[('concept', 0.7832673192024231),  
 ('process', 0.6979352831840515),  
 ('expression', 0.6963064670562744),  
 ('effect', 0.694710910320282),  
 ('invention', 0.688177227973938),  
 ('sense', 0.6801007390022278),  
 ... ]
```

t-SNE (t-Distributed Stochastic Neighbor Embedding) により  
300次元を2次元に圧縮して可視化



## word2vecの使用例1



芸術・メディアの領域において特徴的な語・概念のネットワークをいわゆる放射状カテゴリーを思わせる形状で得ることができている

# word2vecの使用例2

“accept” の意味的近接語のネットワークを異なる領域でモデル化して比較

## 教育 サブコーパス

処理対象異なり語数： 41,269

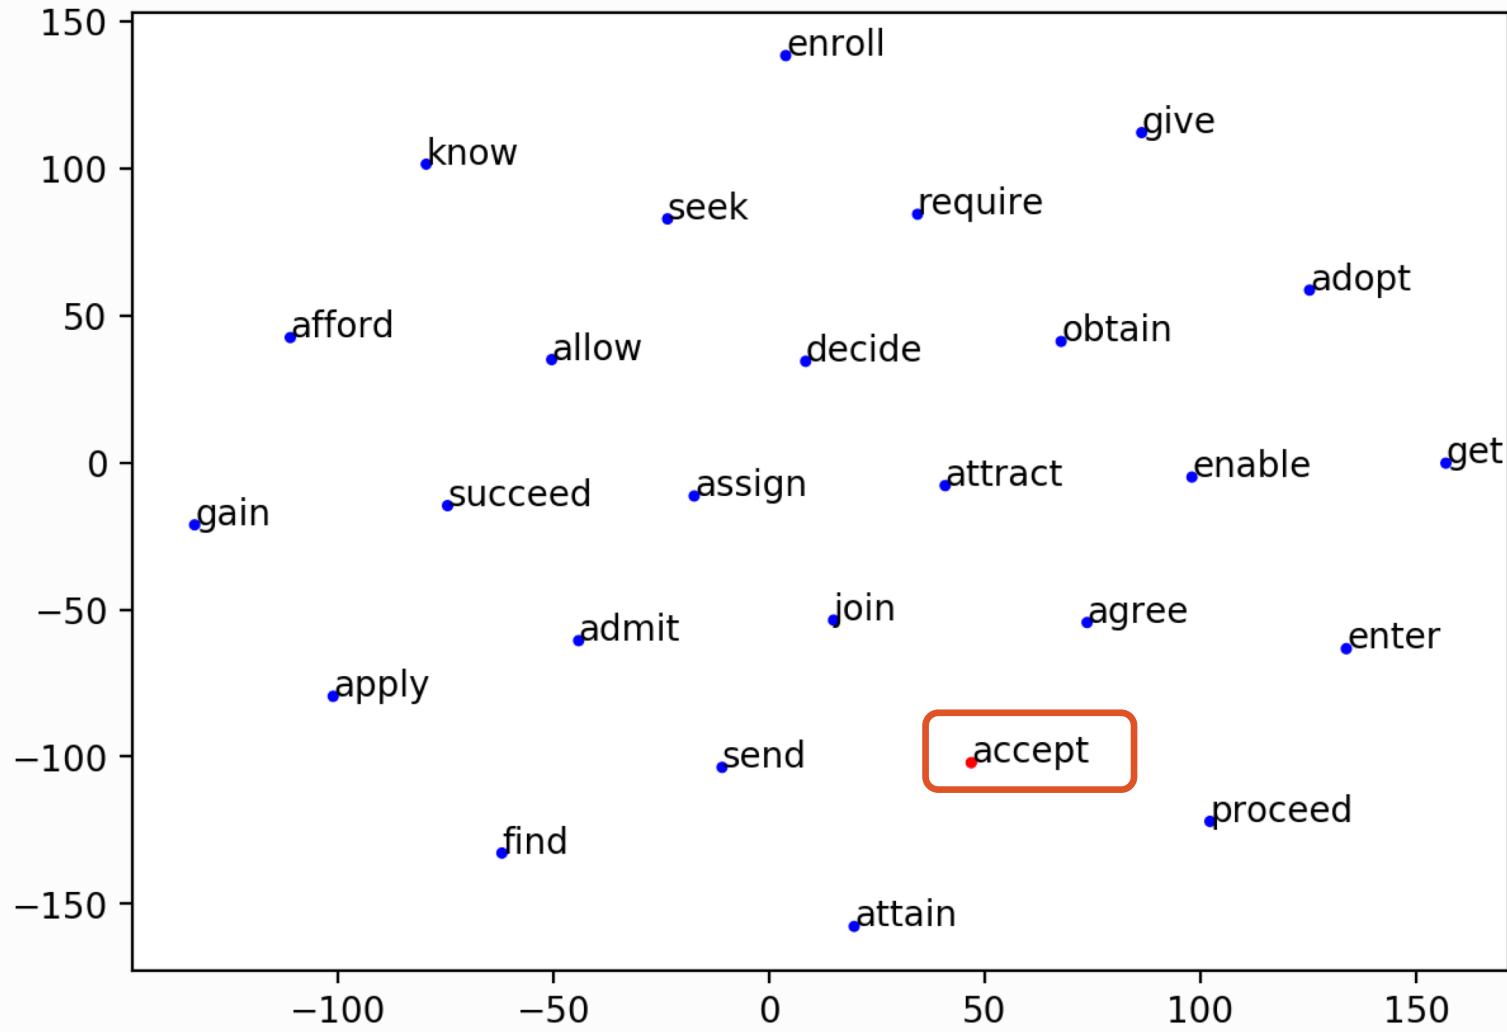
## 政治 サブコーパス

処理対象異なり語数： 85,442

t-SNE (t-Distributed Stochastic Neighbor Embedding) により  
300次元を2次元に圧縮して可視化

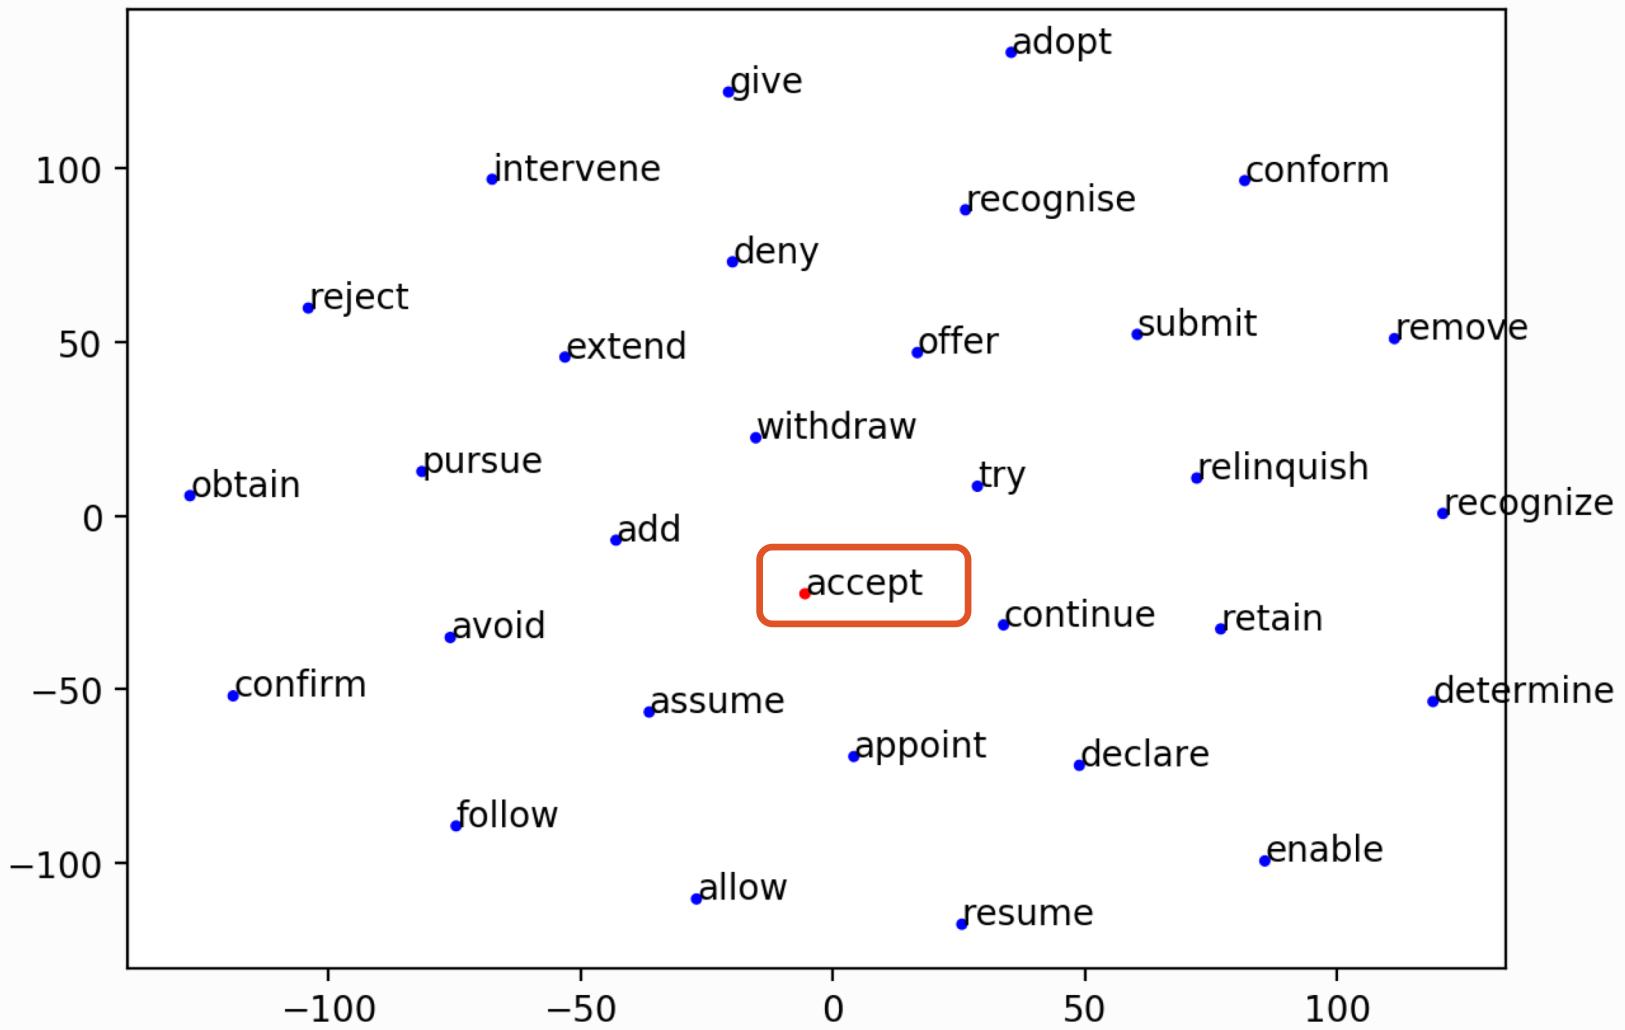


# word2vecの使用例2



**教育分野：**学校関連の“accept”にまつわる事象を表す語が確認できる

# word2vecの使用例2



**政治分野**：条約や法案を扱う厳格な手続きを思わせるような語が観察される

# word2vecの使用例3

## ビジネス サブコーパス

処理対象異なり語数： 39,338

## コンピュータ・ソフトウェア サブコーパス

処理対象異なり語数： 31,932

```
model.wv.similar_by_word ('send')
```

### ビジネス

```
[('give', 0.88),  
 ('find', 0.88),  
 ('allow', 0.87),  
 ('deliver', 0.86),  
 ('add', 0.86),  
 ('keep', 0.85),  
 ('overcome', 0.85),  
 ('collect', 0.85),  
 ('handle', 0.85),  
 ('retain', 0.84)]
```

### コンピュータ・ソフトウェア

```
[('receive', 0.87),  
 ('upload', 0.85),  
 ('listen', 0.82),  
 ('transmit', 0.81),  
 ('browse', 0.79),  
 ('scan', 0.79),  
 ('incoming', 0.79),  
 ('synchronize', 0.78),  
 ('securely', 0.78),  
 ('retrieve', 0.78)]
```

# word2vecの使用例3

word2vecでは語の意味を「計算」できる」とはどういうことか

## 定番の例

father + daughter – mother = son

france + tokyo - japan = paris

## 2つのサブコーパスを使って実験

```
model.wv.most_similar(positive = ['ios', 'google', 'mobile'],
                      negative = ['apple'])
```

### ビジネス

```
[('android', 0.89),
 ('server', 0.87),
 ('sql', 0.85),
 ('linux', 0.85),
 ('windows', 0.84), ...]
```

### コンピュータ・ソフトウェア

```
[('android', 0.70),
 ('apps', 0.68),
 ('skype', 0.68),
 ('messenger', 0.64),
 ('bing', 0.64), ...]
```

# word2vecの使用例3

領域が異なると語どうしの距離も異なることがある（仲間はずれ検知）

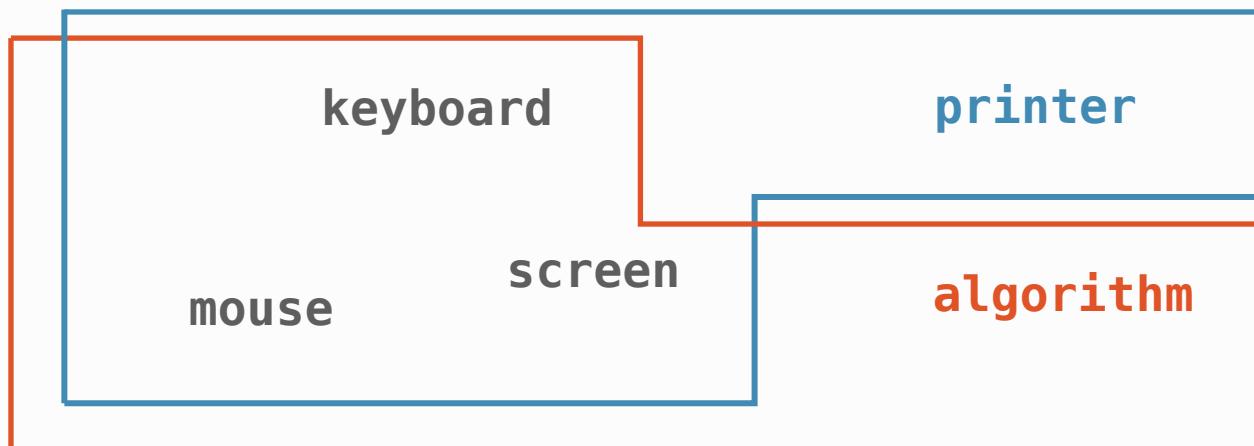
```
model.wv.doesnt_match(['keyboard',
                       'mouse',
                       'screen',
                       'printer',
                       'algorithm'])
```

ビジネス

'printer'

コンピュータ・ソフトウェア

'algorithm'



# word2vecの制約・課題

- 多義語の扱いが難しい
- 反義語を区別させるのが難しい
- 連語の扱いが難しい
- 語の意味の類似度に影響する要因をつかむことが難しい

Cf. Desagulier (2017)

# まとめ

## word2vec

- 語どうしの近接性を知る／語の意味を「計算」できる
- 大規模データから高速に語彙ネットワーク構築

## Enwiki-Intro Corpus

- 特定の事物や概念を「説明」したテキストのコーパス
- 特定のカテゴリーに属するテキストでサブコーパスを構築

制約はあるが、上記の2つを組み合わせることは、特定領域の語彙の概念ネットワークを構築するための有望な方法と思われる。

サブコーパスを階層的に構築して、サブコーパス間にみられる差異や共通点に着目することで、将来的には**語の意味的粒度** (e.g. 抽象カテゴリー、基本レベルカテゴリー、細別カテゴリー) の違いを射程に入れた立体的な語彙ネットワークのモデル構築につながるかもしれない

# 言及文献

Desagulier, Guillaume. 2017. Can word vectors help corpus linguists? <halshs-01657591>

長谷部陽一郎. 2006. Wikipedia 日本語版をコーパスとして用いた言語研究の手法. 『言語文化』 9-2: 373-403.

Langacker, Ronald W. 1990. *Concept, Image, and Symbol: The Cognitive Basis of Grammar*. Mouton de Gruyter.

McCormick, Chris. 2016. Word2Vec Tutorial: The Skip-Gram Model. <<http://mccormickml.com/2016/04/19/word2vec-tutorial-the-skip-gram-model/>>

Mikolov, Tomas, et al. 2013. Efficient Estimation of Word Representations in Vector Space. <arXiv:1301.3781>

西尾泰和. 2014 『word2vecによる自然言語処理』 オライリー.