


文脈化された単語ベクトルからの単語領域表現

山内崇史* 梶原智之** 荒瀬由紀***

*大阪大学電子情報工学科 **大阪大学データビリティフロンティア機構 ***大阪大学大学院情報科学研究科

研究背景

- 包含関係、上位下位関係は単語の重要な意味的関係である
 - 検索や応答生成などの分野に応用される
- 静的な単語分散表現 (Word2Vec, GloVe, etc.) [1, 2]
 - 1 単語に対して 1 ベクトルを割り当てる
 - ✗ 多義性を表現できない
 - ✗ 意味の包含関係や上位下位関係の表現が困難
- 動的な単語分散表現 (ELMo, BERT) [3, 4]
 - 文脈ごとに分散表現を生成する
 - 多義性に対応
 - ✗ 意味の包含関係や上位下位関係の表現が困難
- 既存の領域表現 [5, 6]
 - 混合ガウス分布により多義性に対応
 - ✗ モデルの訓練時に規定の窓幅の文脈しか考慮できない
 - ✗ 語義数を動的に決定しない



提案手法

- BERTで得られる文脈化された単語ベクトルを混合ガウスモデルに当てはめる
 - 意味的に近いベクトルが同じ領域に含まれることを期待
 - 文全体を考慮した単語表現を得られる
- 各ガウス分布が単語の意味に対応
 - 多義性に対応
- ガウス分布の分散によって領域の広がりを表現
 - 単語間の意味の包含関係や上位下位関係を表現



実験

● 意味的に近いものが同じ領域に属するかを可視化

- English Wikipedia 内の10万記事から得た‘soft’、‘bank’の単語ベクトルをプロット、混合ガウス分布を当てはめ

soft

bank



文番号	原文 (一部抜粋)
610	has two coats - a harsh, wiry topcoat and a soft warm undercoat.
718	In contrast to southern Dutch cuisine, which tends to be soft and moist,
665	Todd claimed Coleman was soft on crime and
1012	appeared in advertising campaigns for batteries, a soft drink ,
1273	Eunicella cavolini is a much-branched soft coral growing to a height of about

文番号	原文 (一部抜粋)
3407	, and lies on The southern bank of The River Clyde.
1410	While elements moved south to protect the north bank of the Loire River,
2842	several small creek running in different Directions bank generally high and dry
3163	It was at the time the largest bank failure in the history of the country,
3893	by debit or credit cards or online bank transfers.

今後の課題

- 語義数を自動で決定
- 領域表現を活かした新しい類似度尺度の提案 : Stanford Contextual Word Similarity データセットで評価
- 包含関係、上位下位関係の表現 : Lexical Entailment のタスクにより評価