

言語解析論

竹内孔一

内容

- 潜在意味解析(トピックモデルを意識して)
- これらに対する初歩的な事例の理解

潜在意味解析とは

- 文書や単語に対して隠れた意味(潜在トピック)を計算で求めて、類似文書をまとめたり、取り出したりすることができる
- 参考図書(1冊だけでは無理)
 - 言語処理のための機械学習入門 コロナ社(高村)
 - トピックモデル 講談社(岩田)
 - トピックモデルによる統計的潜在意味解析 コロナ社(佐藤)

歴史

- LSI (latent semantic indexing/latent semantic analysis)1988
- pLSI (probabilistic LSI) 1998
- LDA (Latent Dirichlet Allocation) 2003

LSIを例に潜在意味解析

- アイデア
 - 文書と単語の共起行列を低ランク行列分解
- 利点
 - 直接、単語がでてなくても、共起関係から文書が取り出せる

文章を文書(D)と単語(W)の共起行列と考えてみよう

文書-単語 行列	ピアノ	楽譜	演奏	ゲーム	遊ぶ
D1	3	0	2	0	0
D2	0	2	3	0	0
D3	0	0	0	3	2
D4	0	0	0	2	3

「ピアノ」と「楽譜」は1つの文書で同時に出ていないので関連が見えない
→でも共通の単語「演奏」を通してとても関連している

LSI

- 特異値分解し、低ランク行列に分解する
- 低ランクのK(トピック数)は人手で与える

$$\begin{matrix} M \\ 4 \end{matrix} \begin{matrix} V=5 \\ X \end{matrix} = \begin{matrix} 4 \\ D \end{matrix} \begin{matrix} 4 \\ Z \end{matrix} \begin{matrix} 5 \\ V^T \end{matrix}$$

Zを低ランクKxKにする

Zは対角行列

$$\begin{matrix} M \\ 4 \end{matrix} \begin{matrix} V=5 \\ \tilde{X} \end{matrix} = \begin{matrix} K \\ \tilde{D} \end{matrix} \begin{matrix} K \\ \tilde{Z} \end{matrix} \begin{matrix} 5 \\ \tilde{V}^T \end{matrix}$$

元の文書-単語行列Xも変わってしまう。Kがトピック数

LSI

- 低ランク行列分解後のXはトピックを考慮
- 元々相関の無かった「ピアノ」と「楽譜」が相関を持つようになる

\tilde{D}

	Top ic1	Top ic2
D1	0	値
D2	0	値
D3	値	0
D4	値	0

\tilde{V}^T

ここはPythonのgensimの計算結果

	ピアノ	楽譜	演奏	ゲーム	遊ぶ
topic1	0	0	0	0.763	0.646
topic2	0.487	0.324	0.811	0	0

(注)下記の値はイメージで正確ではない

	ピアノ	楽譜	演奏	ゲーム	遊ぶ
D1	2.1	0.9	1.5	0	0
D2	1.1	0.8	1.9	0	0
D3	0	0	0	2.5	1.4
D4	0	0	0	2.1	1.2

\tilde{X}

文書-単語
行列

Topic1 がゲームに関する単語分布
Topic2 がピアノに関する単語分布であることがわかる

LSIを使う

- 未知の文書aが、既存の文書 D1, D2, D3, D4のどれに近いか、cosine類似度で求める

$$Xa = \tilde{D}a\tilde{Z}\tilde{V}^T$$

$$\tilde{D}a = Xa \tilde{V}\tilde{Z}^{-1}$$

新しい文書aは文書-単語行列の最後に1行加えたとする
そのときのDa(つまりtopic分解ベクトル)を求める

D1からD4についてのトピックは \tilde{D} で求まっている
各 $\tilde{D}1, \tilde{D}2$ などと $\tilde{D}a$ とのcosineを求める

練習

- 「ピアノ 演奏 楽しい」という3単語の文書があったとする。下記の文書-単語行列の最後の行にXaとして書き加えよ
- この時、「楽しい」は辞書に無いので無視する

	ピアノ	楽譜	演奏	ゲーム	遊ぶ
D1	3	0	2	0	0
D2	0	2	3	0	0
D3	0	0	0	3	2
D4	0	0	0	2	3
Xa					

練習

- 先のXaベクトルに対してtopic分解した新たなベクトル $\tilde{D}a$ を求めよ

$$\tilde{D}a = Xa \tilde{V}\tilde{Z}$$

	ピアノ	楽譜	演奏	ゲーム	遊ぶ	topic1	topic2			
Xa						ピアノ	0	0.4	1.0	0
						楽譜	0	0.3	0	1.0
						演奏	0	0.8		
						ゲーム	0.7	0		
						遊ぶ	0.6	0		

文書aの単語の頻度を入力

答え Da = [0, 1.2]

文書aはtopic2に近い内容