

# Infinite SCAN:意味の数とその時間変化を同時に推定する統計モデル

持橋大地

情報・システム研究機構 統計数理研究所

[daichi@ism.ac.jp](mailto:daichi@ism.ac.jp)

日本英語学会 “深層学習時代の言語研究” シンポジウム  
2023-11-4 (土)

# 今日の話

- 自然言語処理の分野で、言語の分析のために開発した二つの統計モデル
- Infinite SCAN ([EMNLP 2022](#)):  
各単語の意味の数と、その時間変化を同時に推定する  
ことができる統計モデル  
(Inoue+ 2022)
- Holographic CCG ([ACL 2023](#)):  
潜在的なベクトル空間において、CCGの合成演算を  
二つのベクトルの再帰的な合成として表し、  
文の木構造をベクトル空間上のグラフとして表す  
研究  
(Yamaki+ 2023)

# 言語の時間的変化

“Language is a dynamic system, constantly evolving and adapting to the needs of its users and their environment”  
(Aitchison, 2001)

- 音韻変化: 単語の発音の変化
- 文法的変化: 使われる統語構造の変化
- 意味的変化: 単語の意味の時間的変化
  - “cute”: 賢い (18世紀) → 悪賢い (19世紀)  
→ かわいい (現在)
  - 意味の変化した単語は多数あり、その変化は未知
  - どうやって自動的にこうした変化を推定すればよい?

# 単語の意味とは

- 単語の「意味」とは何か?  
→ 分布仮説 (Harris 1954)に従うとする  
(単語の意味は、前後の文脈に同時に現れる単語の分布に反映される)
- 通時コーパスから、目的の単語を含むスニペットをまず抽出する

# スニペットの抽出

目標単語: “coach”



通時コーパス




タイムスタンプ+前後のスニペット

- 1853 The driver made room for the trunk on the top of the **coach**.
- 1900 The chair passed the **coach**, the horses proceeding at a walk.
- 1949 Tell him if I start **coaching**, it' ll be as a head **coach** at a top school.
- 1995 available for inspection, like the **Coach** bags offered on Canal Street
- 2003 Football **coach** and other top school officials have been interviewed.

# 単語の意味変化の既存研究

(Hamilton+ 2016)




- 単語の前後の文脈(スニペット)から、単語の埋め込みベクトルを計算 (word2vecなど)  
→ 時間的な変動を観察する
- 変化したことはわかるが、何がどう変化したかはわからない！

# 得られた“coach”的スニペット

$z$

1853	[driver, make, room, trunk]	→馬車
1900	[chair, pass, horse, proceed, walk]	→馬車
1949	[tell, start, coach, head, top, school]	→スポーツ
1995	[available, inspection, bags, offer]	→ブランド
2003	[football, top, school, official, interview]	→スポーツ

- 各スニペットは、いずれかの意味(トピック)  $z$  に対応していると考えられる
- 生成モデル：
  - ある確率分布  $\phi(z)$  に従って、 $z$  を選択
  - トピック  $z$  から、トピック毎の単語分布  $\psi(w|z)$  に従って実際のスニペットが生成される



# トピックの教師なし学習


- 各スニペットの意味(トピック)は書かれていない!  
→ 実は、自動的に学習できる
- アルゴリズム:
  - 各スニペットを、確率的に $K$ 個のトピック  $z$  の  
どれかに割り当てる ( $\phi(z)$  がわかる)
  - 各トピック  $z$  に割り当てられたスニペットの  
文章全体から、 $\psi(w|z)$  を更新
  - 以上を繰り返す
- スニペットのクラスタリングに相当している

# ただし...

- 単語の意味は変化する  
→ 時刻 $t$ での意味の割合  $\phi_t(z)$  は、少しずつ変化する  
時刻 $t$ でのトピック-単語確率  $\psi_t(w|z)$  も変化する
- 観測値がない年もあるので、うまく平滑化する  
必要がある
- 意味の総数 $K$ は、事前にはわからない  
→ 本研究で、ディリクレ過程によって自動推定


# 先行研究: SCAN (Frermann+ TACL 2016)

- SCAN: Dynamic Bayesian Model of Sense ChANge
  - スニペット時系列の動的トピックモデル



# 意味分布の時間発展

- 意味分布  $\phi_t$  と意味-単語分布  $\psi_t$  は両方とも、時間に従って変化する
  - ガウス分布のマルコフ確率場




```
Draw  $\kappa^\phi \sim \text{Gamma}(a, b)$ 
for time interval  $t = 1..T$  do
    Draw sense distribution
     $\phi^t | \phi^{-t}, \kappa^\phi \sim \mathcal{N}(\frac{1}{2}(\phi^{t-1} + \phi^{t+1}), \kappa^\phi)$ 
    for sense  $k = 1..K$  do
        Draw word distribution
         $\psi^{t,k} | \psi^{-t}, \kappa^\psi \sim \mathcal{N}(\frac{1}{2}(\psi^{t-1,k} + \psi^{t+1,k}), \kappa^\psi)$ 
    for document  $d = 1..D$  do
        Draw sense  $z^d \sim \text{Mult}(\phi^t)$ 
        for context position  $i = 1..I$  do
            Draw word  $w^{d,i} \sim \text{Mult}(\psi^{t,z^d})$ 
```

# 意味の数の推定

- SCANでは、“意味の総数”  $K$  は単語ごとにあらかじめ指定する必要がある
  - 一般には未知！
- 時間によって変わる意味の総数を、どうやって推定するか？
  - 使えるデータは、下のようなスニペット集合だけ

```
1853 [driver, make, room, trunk]
1900 [chair, pass, horse, proceed, walk]
1949 [tell, start, coach, head, top, school]
2003 [football, top, school, official, interview]
```

# ロジスティック棒折り過程 (Ren+ 2011)



$$q_k = \frac{1}{1 + e^{-x_k}}$$

(シグモイド関数で確率に変換)

- 時間変化する意味の割合(の対数)  $x_k$  から、各時刻ごとに無限次元の分布を仮定して推定

# 推論

- All the inference is done by Gibbs sampling.
- Because Gaussian is not conjugate to multinomial, we employ Pólya-Gamma auxiliary variables  $\omega$  to sample  $\alpha_t$  (and transform into  $\phi_t$ ):

$$\begin{aligned} p(\alpha_t | z, \boldsymbol{\alpha}_{-t}, \omega) \\ \propto \mathcal{N}(\omega^{-1} f(c) | \alpha_t) \mathcal{N}(\alpha_t | \boldsymbol{\alpha}_{-t}, \kappa_\phi^{-1}) \\ \propto \mathcal{N}(\alpha_t | \tilde{\mu}, \tilde{\kappa}_\phi^{-1}). \end{aligned}$$

- Precision parameter  $\kappa_\phi^{(k)}$  should be estimated for each topic  $k$ :

$$\begin{aligned} p(\kappa_\phi^{(k)} | \alpha_k, a, b) \\ = \text{Ga}\left(a + \frac{T}{2}, b + \frac{1}{2} \sum_{t=1}^T (\alpha_{t,k} - \bar{\alpha}_k)\right) \end{aligned}$$

# 実際のテキストでの実験


- データ: Corpus of Historical American English (COHA)
  - 先行研究に基づいて、分析に使う単語を選択

Word	Years	Samples	#Vocab
coach	1811–2009	9,758	11,962
record	1815–2009	33,992	23,886
power	1810–2009	142,527	42,932


- 数値的評価:
  - ベースライン: SCAN, HDP-LDA, BERT
  - 時間変化するトピック分布のcoherenceとdiversityを調べて評価

# 実験結果 (1)

- “coach” : estimated senses=2





Semantic shift: “carriage” → “trainer”



# 実験結果 (2)

- “power” : estimated senses=6




Sense birth: “energy”

# 実験結果 (3)

- モデルは意味の数を正しく発見できているのか？
- OntoNotesデータセットからランダムに120語を選んでモデルを計算し、正解率を計算

Model	Accuracy	PCC
HDP-LDA	0.258	0.019
BERT + K-means	0.217	0.026
BERT + DBSCAN	0.125	-0.070
SCAN ( $K = 5$ )	0.158	0.141
SCAN ( $K = 8$ )	0.000	0.087
Infinite SCAN	<b>0.358</b>	<b>0.474</b>





Prediction results for the number of senses.

Correlation between actual and estimated number of senses by Infinite SCAN.

# 構文解析と自然言語処理


- 構文解析は、自然言語処理の中心的テーマの一つ
- 構文解析：文が与えられたとき、その木構造を可能な無数の組み合わせの中から自動的に求める



# 構文解析の難しさ


- 動的計画法を使っても、文長 $N$ について $O(N^3)$ の計算時間 (CYKアルゴリズム)
- 与えられた文に対して可能な膨大な木構造の中から、正解の一つだけを選ぶタスク

Book	the	flight	through	Houston
S, VP, Verb Nominal, Noun [0, 1]		S, VP, X2 [0, 3]		S, VP, X2 [0, 5]
Det [1, 2]		NP [1, 3]		NP [1, 5]
		Nominal, Noun [2, 3]		Nominal [2, 5]
		Prep [3, 4]	PP [3, 5]	
			NP, Proper- Noun [4, 5]	




詳しくは  
こうした  
教科書を  
参照

# 組み合わせ範疇文法 (CCG)



- 語を構文木に沿って組み合わせることで、句構造に対応する表現を生成
- 最終的に、Sが得られれば解析終了
- 途中の句構造に、その下にある単語の情報が反映されている

# CCGの問題点



- 単語につけられた  $(S \setminus N)/N$  のようなタグが離散的  
→ 埋め込みベクトル化したい
  - 上位の句構造のベクトルが、合成された単語のベクトルを反映できる
- すべての単語に、あらかじめ人手でこうしたタグを付与する必要がある (教師なし学習; 今回は範囲外)

# Holographic CCG

- 基本的なアイデア: CCGをベクトル合成と組み合わせられないか?
- CVGのように合成毎にパラメータがあると、膨大なパラメータが必要で過学習してしまう



- 何か、2つのベクトルを合成する見通しのよい数学的な方法はないか?  
→ [Holographic composition \(Plate 1995\)](#)


# Holographic composition

- 知識グラフの埋め込み手法として、Nickel+(AAAI 2016)で提案 (最初の提案はPlate(1995))
- Circular correlation (巡回相関)

$$\mathbf{c} = \mathbf{a} \star \mathbf{b}$$

- 定義:

$$[c]_k = \sum_{i=0}^{d-1} a_i b_{(k+i) \bmod d}$$



# Holographic composition (3)

- 性質:

- Non-commutative: 方向を保存

$$a \star b \neq b \star a$$

- Non-associative: 構造を保存

$$(a \star b) \star c \neq a \star (b \star c)$$


- 構文構造を保存: たとえば “loves to eat” のベクトルは

$$\mathbf{v}^{\text{"loves to eat"}} = \mathbf{v}_{\text{loves}} \star \mathbf{v}^{\text{"to eat"}} = \mathbf{v}_{\text{loves}} \star (\mathbf{v}_{\text{to}} \star \mathbf{v}_{\text{eat}})$$

- これは  $(\mathbf{v}_{\text{loves}} \star \mathbf{v}_{\text{to}}) \star \mathbf{v}_{\text{eat}}$  とは異なる


# Holographic CCG

- Hol-CCGのイメージ




- 単語ベクトル 자체を最適化して、合成して最終的に文Sのベクトルが得られるようにする

# 実際の学習の様子 “My sister loves to eat”



- 单語のベクトルを構文構造に従って合成して、句構造のベクトルを再帰的に計算する
- 最終的に、文全体を表すベクトルが得られる


# 実際の学習の様子 “My sister loves to eat”



- 合成した結果ベクトルがそれぞれの句に正しく分類されるよう、逆伝播で最初の単語ベクトルを最適化
- 最終的には、文Sとなればよい

# Transformer(深層学習)から始める場合

- 各単語の入力埋め込みとしてRoBERTaを使用




# 実験結果

- CCGBankというWall Street Journalのデータで評価
- 現在、ヒューリスティックな方法を抜いて世界最高性能

Model	Super-Tagger	Parser	Acc	LF
Lewis et al. (2016)	LSTM	A*	94.7	88.1
Vaswani et al. (2016)	LSTM	C&C	94.5	88.32
Yoshikawa et al. (2017)	LSTM	A* (LSTM)	–	88.8
Stanojević and Steedman (2020)	LSTM	Shift-Reduce (LSTM)	–	90.6
Tian et al. (2020)	Attentive-GCNN	EasyCCG	96.25	90.58
Bhargava and Penn (2020)	LSTM decoder	C&C	96.00	90.9
Liu et al. (2021)	Category Generator	C&C	96.05	90.87
Prange et al. (2021)	Tree-Structured decoder	C&C	96.22	90.91
Kogkalidis and Moortgat (2022)	Heterogeneous Dynamic Convolutions	–	96.29	–
Clark (2021)	Tian et al. (2020)	C&C Span-based	– –	91.9 92.9
Ours ( $\mathcal{L}_w + \mathcal{L}_p + \mathcal{L}_s$ , Real)	Holographic	C&C Span-based	<b>96.60</b> –	<b>92.12</b> 92.67

Table 2: Comparison of the proposed model and existing methods; best results are shown in bold.

# 実際のベクトルの合成の様子



- 768次元のベクトル空間をPCAで3次元に可視化

# 文法に即した穴埋め

- 「句」のベクトルから、ランダムに単語に戻すことが可能 → 文法に準拠した穴埋めが可能に

ID	Sentence	Replacement Candidate	Sim.	NPMI
1	<i>Mr. Vinken is chairman of Elsevier N.V., the Dutch publishing group.</i>	<i>Mr. Baris</i>	1.00	0.19
		<i>Dr. Novello</i>	1.00	0.10
		<i>Ms. Ensrud</i>	1.00	0.11
2	<i>When Scoring High first <u>came out</u> in 1979, it was a publication of Random House.</i>	<i>turned up</i>	0.94	0.27
		<i>sold out</i>	0.91	0.29
		<i>sells out</i>	0.90	0.24
3	<i>In early trading in Hong Kong Thursday, gold was quoted at \$ 374.19 an ounce.</i>	<i>for \$ 25.50 a share</i>	0.94	0.33
		<i>for \$ 60 a bottle</i>	0.94	0.29
		<i>at \$ 51.25 a share</i>	0.93	0.34
4	<i>Judges are not getting <u>what they deserve</u>.</i>	<i>what she did</i>	0.96	0.28
		<i>what they do</i>	0.96	0.36
		<i>what we do</i>	0.89	0.35
5	<i>Despite recent declines in yields, investors continue to pour cash into money funds.</i>	<i>Despite the flap over transplants</i>	0.89	0.22
		<i>In a victory for environmentalists</i>	0.86	0.22
		<i>On the issue of abortion</i>	0.82	0.27
6	<i>Despite recent declines in yields, investors continue to pour cash into money funds.</i>	<i>to provide maintenance for other manufacturers</i>	0.83	0.27
		<i>to share data via the telephone</i>	0.79	0.21
		<i>to cut costs throughout the organization</i>	0.77	0.26

# まとめ

- 言語の意味と文法に関する、講演者の最新の研究を一つずつ紹介
- 適切な統計モデルを立てることで、従来は自動的にはできないと思われていた分析が可能になる
- 計算機でモデル化することで、網羅的なモデル化が可能  
→ どんな言葉や文に、どんな特徴があるのかをデータから抽出することができる
- 言語学と自然言語処理の境目は、どんどん縮まりつつある

# 統計的テキストモデル(教科書)

## 統計的テキストモデル


持橋 大地

統計数理研究所 数理・推論研究系

daichi@ism.ac.jp

2022年9月1日

\$Id: textmodel.tex,v 1.14 2022/01/22 14:26:11 daichi Exp \$

A large grid of English words, likely a sample of the dataset used for training a statistical text model. The words are arranged in a grid pattern, showing various common English words like 'the', 'and', 'is', 'a', etc., interspersed with more specific terms.

- 岩波書店より、2024年頃に発売予定
- 言語の統計モデル化の基礎について、丁寧に説明
- 類書と異なり、パッケージに頼らず、数学的背景もその場で説明しています
- <http://chasen.org/~daiti-m/textmodel/>  
で原稿の一部を公開中