

# ガウス過程に基づく連続空間トピックモデル

持橋大地

統計数理研究所 数理・推論研究系 学習推論グループ

daichi@ism.ac.jp

## 1. 背景: トピックモデル

トピックモデル...文書(離散データ)の確率的生成モデル


代表的なもの: Latent Dirichlet Allocation (Blei+ 2003)

生成プロセス: 各文書ごとに,

1. 潜在トピック分布  $\theta \sim \text{Dir}(\alpha)$  を生成

2. 各語ごとに,

- (a) 潜在トピック  $z \sim \text{Mult}(\theta)$  を選択.
- (b) 単語  $w \sim p(w|z) = \beta_{zw}$  を生成.



- $\theta$ : 多項分布
- $\beta$ : 潜在トピック別 単語確率分布
- $w$ : 観測値(単語)

応用と拡張

- 非常に多くの分野で使われている
  - グラフィックス, ビジョン, バイオインフォマティクス, 推薦モデル, リンク解析, ネットワークモデル, ...
- 多数の改良の試み(sLDA, CTM, DHDP, Mixed Random Measures (Kim+ 2012), dHNRM (Chen+ 2012), ...)


## 2. 問題点

- 混合モデルのため,  $\beta = p(w|z)$  は一度決まると固定
  - 語彙の情報を細かく制御できない = ラベルがトピックにしか影響しない(sLDA, DHNRM等の拡張全て)

実際の例

- 女性特有の言い回し, 語彙選択
- 会話文の文体 (トピック / 内容とは独立)
- ひらがな / 漢字ばかりの文章
- 著者の語彙的な癖 (-eous や re- が多い, など)

- 単語Simplexの全領域をモデル化できない



↓  
単語Simplexの全領域をモデル化し, 語彙に柔軟に適応する統計モデル.

## 3. CSTM: Continuous Space Topic Model

基本的なアイデア: 潜在単語空間上のガウス過程  $f \sim \text{GP}(0, K)$  によって, 「この文書で言いたいこと」を表現: 単語確率を, 下の積で Modify.


$$p(w|d) = e^f G_0(w)$$

生成モデル

1. For  $w = 1 \dots W$ ,  $\phi(w) \sim \mathcal{N}(0, I_d)$ . ( $w$  の潜在座標)


2. for  $d = 1 \dots D$

- $f \sim \text{GP}(0, K)$  ;  $K(v, w) = \phi(v)^T \phi(w)$
- $\alpha(w|d) = \alpha_0 G_0(w) \exp(f)$
- $G \sim \text{DP}(\alpha(\cdot|d))$ ,  $w \stackrel{\text{iid}}{\sim} G$ . (Polya分布)



特徴:

- 語彙の確率を直接制御できる
  - 拡張: 文書ラベル  $\alpha(w|d) = \alpha_0 G_0(w) e^f e^{\theta^T c(d)}$
  - 拡張: 単語の特徴  $\alpha(w|d) = \alpha_0 G_0(w) e^f e^{\eta^T c(w)}$
- Product model ( $\leftrightarrow$  Mixture model)
- 単語 Simplex のほぼ全域をモデル化できる



## 4. 計算と推論

GP  $f$  は直接表現が難しい 補助変数  $u \sim \mathcal{N}(0, I_d)$  のとき,  $f = \Phi u$  の分布は  $u$  を消去して

$$f|\Phi \sim \mathcal{N}(0, \Phi^T \Phi) = \mathcal{N}(0, K).$$


よって, 文書  $d$  每に  $f = \Phi u_d$  として  $u_d$  と  $\Phi$  を MCMC で更新.  $\alpha_0 \sim \text{Ga}(a_0, b_0)$ ,  $\eta_{kv} \sim \mathcal{N}(0, I_d)$ ,  $\theta_{cv} \sim \text{Exp}(\beta)$ .

## 5. 実験結果

Perplexity

データ	CSTM	CSTM(+lex)	LDA
NIPS	1410.96	–	1648.3
KOS	1632.35	–	1730.7
毎日新聞	473.954	473.273	507.3855

Latent Embedding (NIPS,  $d=10$ )



Covariate modeling

$\eta$ (カタカナ)	テキスト 2364:	$\eta$ (ひらがな)	テキスト 4580:
文書 $e^\eta$		文書 $e^\eta$	
2364 1.498	#日 公開の映画ではウォン	4580 1.720	文 小森香折 こもりかおり 絵
4597 1.471	カーウェイ監督の花様年華	9961 1.501	広瀬絢 ひろせげん ゆうが沖
442 1.440	かようねんかがカンヌ国際	5238 1.494	おし人れをかたづけている
4633 1.433	映画祭最優秀男優賞トニー	7420 1.470	ところへどうぞという父と
1520 1.422	レオン高等技術院賞受賞の	8375 1.452	うさんの声こえがこえてき
	かくかくたる戦果をあげて		ました押し入れのむこうはう
	の香港凱旋がいせんだあま		らないの部屋へやすゆうは
	りにも古風な映画でカーウェ		押し入れにもぐりこんで耳み
	イ監督ファンはびっくりする		みをあてました女のお客や
	かも日本映画は連弾がはじ		くさんのが入はいってきて母か
	けるおもしろさ人間の肩をも		あさんとあいさしているの
	くっこう見せるデニーロの		がきこえていますあのうへび
	くせ者ぶりが楽しめるミー		がみさまはこれがおすきだと
	トザペアレンツ小粒でも…		うかがいまして…

## Future Work

Random Poisson intensity として, HDP/HPY の拡張 → PCFG,  $n$  グラムモデル等の潜在空間埋め込み拡張