

# *Nonparametric Bayes for Non-Bayesians*

IBIS 2008 企画セッション  
「ノンパラメトリックベイズ」

持橋大地

NTT コミュニケーション科学基礎研究所

daichi@cslab.kecl.ntt.co.jp

2008-10-29 (木)

仙台


# チュートリアル

- ノンパラメトリックベイズって何?
- 混合モデルとディリクレ過程混合モデル
- 階層ディリクレ過程
- ノンパラメトリックベイズのポイント:  
... Stick-breaking process (SBP)
- Infinite Tree, Indian Buffet, The Mondrian Process, ...
- ノンパラメトリックベイズと測度論
- まとめ

# ノンパラメトリックベイズとは

---


- モデルをデータの複雑さに応じて増やす生成モデル
  - クラスタリング (クラスタ)
  - グラフマイニング (木, グラフ)
  - 自然言語処理 (カテゴリ, 単語)
- 理論的に可算無限個まで増やせる
  - “Infinite Models” とも呼ばれている
  - 実際には,  $n$  個のデータに対して  $O(\log n)$  前後
    - データの複雑さによって変わる




# ノンパラメトリックベイズとは

---

- モデルをデータの複雑さに応じて増やす生成モデル
  - クラスタリング (クラスタ)
  - グラフマイニング (木, グラフ)
  - 自然言語処理 (カテゴリ, 単語)
- 理論的に可算無限個まで増やせる
  - “Infinite Models” とも呼ばれている
  - 実際には,  $n$  個のデータに対して  $O(\log n)$  前後
    - データの複雑さによって変わる
- 注: 「ノンパラメトリック」
  - パラメータがないという意味ではない
  - 少数パラメータの連続分布の推測ではない, という意味



# 簡単な例: 混合モデル




- データ  $\mathbf{x}$  は確率分布  $1 \dots K$  のどれかから生成
- EM アルゴリズム:  $\mathbf{x}$  が  $1 \dots K$  のどの分布から生成されたか?

$$p(k|\mathbf{x}) \propto p(\mathbf{x}|k) p(k) \quad (k = 1 \dots K) \quad (1)$$

を計算する

## 混合モデルの推定 (2): 問題



- 問題: 外れ値の場合はどうするか?
  - $K$  が有限の場合,  $p(k|\mathbf{x})$  が比較的大きいものに無理矢理割り当てる
- ↓
- $p(K+1|\mathbf{x})$  (新しいクラス) を考えた方がいいのでは?
  - $p(K+1|\mathbf{x}) \propto p(\mathbf{x}|K+1) p(K+1)$  に従って, 新しいクラスに帰属させる

## 混合モデルの推定 (3)

- ちょっと待った: 新しいクラスは,  $K+1, K+2, K+3, \dots$  と無限にあるのでは?
  - EM で  $p(K+1|\mathbf{x}), p(K+2|\mathbf{x}), \dots$  を全部持っておくのは無理



- MCMC 法で, 確率的にランダムにクラス番号を決めよう
  - “現在のクラス数の最大値 +1” まで考えればよい


```
1: for  $n = 1 \dots N$  do  
2:   for  $k = 1 \dots K + 1$  do  
3:      $p(k|\mathbf{x}_n) \propto p(\mathbf{x}_n|k) p(k)$   
4:   end for  
5:    $z_n \sim p(\cdot|\mathbf{x}_n)$   
6:   if  $z_n = K + 1$  then  
7:      $K = K + 1$   
8:   end if  
9: end for
```

# ディリクレ過程混合モデル (DPM)

- 今のアルゴリズムを行うためには,  $p(k)$  ( $k = 1, 2, \dots, \infty$ ) が必要



- GEM 分布, Stick-breaking process (SBP)



$$w_k \sim \text{Be}(1, \alpha) \quad (k = 1 \dots \infty) \quad (2)$$

$$p(k) = w_k \prod_{i=1}^{k-1} (1 - w_i) \quad (3)$$

- 幾何分布

$$\text{Geo}(k) = \lambda (1 - \lambda)^{k-1} \quad (4)$$


のソフト化.

# Stick-breaking process: 事前分布 事後分布

- Stick-breaking prior:

$$w_k \sim \text{Be}(1, \alpha), \quad p(k) = w_k \prod_{i=1}^{k-1} (1 - w_i) \quad (5)$$

- 事前分布は最初は指数減衰 データによって変化
  - 「事前分布の事前分布」





$$w_k \sim \text{Be}(1, \alpha) \quad (6)$$

$$\Downarrow$$



$$w_k \sim \text{Be}(1 + \#(k \text{ で止まったデータ数}), \alpha + \#(k \text{ より右のデータ数})) \quad (7)$$

# 振り返ってみると

有限混合モデル:




DPM:



$p(\mu) = G_0$

- ディリクレ過程とは... 「元」となる分布 (基底測度) に似た, 無限離散分布を生成するモデル  
データをフィッティングする
  - データが多く複雑なほど, より多くの「クラスタ」が現れる


# HDP (Hierarchical Dirichlet Process) (Teh+ 2004)



- DP の基底測度を, 親 DP から引いた無限離散分布にする  
↓
- ある離散分布に似た, 多数のランダムな離散分布
  - 「ある混合比に似た, 多数のランダムな混合比」
  - 技術的には:  $\{G_n\}$  の中で, アトムが共有される
    - $H$  から直接  $\{G_n\}$  を引くと,  $\perp$  の立っている位置が共有されない

# HDP の応用

- HDP-LDA : 無限トピックの潜在意味モデル
  - 混合モデルの混合モデル



$$p(\mathbf{w}|\eta, H) = \int \prod_{n=1}^N \sum_{k=1}^{\infty} p(w_n|k) \underbrace{G[k]}_{\text{無限離散分布の第 } k \text{ 要素}} dG \quad (8)$$


- 実装には Gibbs sampling を用いる

- <http://www.gatsby.ucl.ac.uk/~ywteh/research/npbayes/npbayes-r21.tgz>


# The Trinity of Nonparametric Bayes

- ノンパラメトリックベイズの本質 (機械学習として)  
... Stick-Breaking Process (SBP)

ノンパラメトリック  
ベイズ法




- Stick-Breaking Process の拡張



$$w_k \sim \text{Be}(1, \alpha) \quad (9)$$


- $\text{Be}(1, \alpha)$  でなくともよい
  - $\text{Be}(1 - \alpha, \beta + k\alpha) \dots$  Pitman-Yor process (Pitman and Yor 1997)
  - $\text{Be}(\alpha, \beta) \dots$  Beta two-parameter process (Ishwaran and Zarepour 2000)

# Infinite Stochastic Tree




- 木の各ノードに,  $w \sim \text{Be}(\alpha, \beta)$  がある
- 木の各 Branch が, 一つの SBP
  - SBP の構造化
  - 深いノードほど, 到達しにくい (木が「薄い」)
- 有限のデータでの近似
  - The Infinite Markov Model : Gibbs
  - NTR (Neutral-To-Right) process と関係が深いらしい
  - 一般のグラフにも同様の無限化を考えるとできそう


# The Mondrian Process (Roy and Teh, NIPS 2008 to appear)



Mondrian Process



Mondrian (3D)




IRM

- Infinite Relational Model の最先端...確率的階層分割
  - Poisson process の階層化
  - Blockmodel IRM (Kemp+ 2006) Annotated Hierarchy (Roy+ 2006) Mondrian
- 再帰的な定義

$$\begin{aligned} \text{MP}(\lambda, \mu, \Theta) &\equiv \\ &\lambda' = \lambda - E, E \sim \text{Exp}(\mu(\Theta)), \dots \\ &\text{return } \langle \lambda', d, x, \text{MP}(\lambda', \mu, \Theta^{<d^x}), \text{MP}(\lambda', \mu, \Theta^{>d^x}) \rangle \end{aligned}$$

## その他の新しい話題


- The Infinite Hidden Markov Model (Beal+ 2002)



- HMM の隠れ状態数が推測できる (!)
- HDP を使って, 可算無限個の隠れ状態を生成
  - 動的計画法も提案された (ICML 2008)
  - HDP-PCFG もこの一種

- Indian Buffet Process (Griffiths and Ghahramani 2005)  
= Beta Process (Hjort 1990)

- 複数の隠れ素性を持つ無限マトリクス  
の生成モデル



- 階層化と HBP (Thibaux+ 2007...難解)
- 時系列化: The Infinite Factorial HMM (NIPS 2008 to appear)

# ノンパラメトリックベイズと測度論


- ノンパラメトリックベイズの学習に測度論は必要か?  
必要.
  - 全く基礎知識がないと, 研究のレベルが大きく制限される
  - ただし, 全部知る必要は (とりあえず) ない
  - 知らなくても,  $DPM+\alpha$  程度の実装は可能

- お薦め書籍:

“Measure, Integral and Probability”  
Capinski and Kopp, Springer 2004.  
(Springer Undergraduate Mathematics series)

ISBN 1852337818

- ~ p70 くらいまで読めばよい
- a.e. や  $M$  を見ても固まらなくて済む!



# まとめ

---

- ノンパラメトリックベイズ...モデルを動的に増やす生成モデル
  - 複雑なデータほど, 複雑なモデル
  - クラスタリングに限らず, 木やグラフへも拡張可能
- DP, HDP, HPY, IBP, HBP, Mondrian, ...
  - 確率論として見ても深いモデル
  - 測度論の初歩は, 適切な本を使えば難しくない
  - NPBayes stat だけで, ご飯 20 杯くらい食べられる  
(ex. Newton Institute 2007, “Construction and Properties of Bayesian Nonparametric Regression Models”  
<http://www.newton.ac.uk/programmes/BNR/bnrw01p.html>)
- 機械学習における多くの応用
  - 自然言語処理, バイオインフォマティクス
  - クラスタリング, データマイニング, ネットワーク分析
  - 画像処理, 音声処理, 音楽情報処理, ...

# 注意

- ノンパラベイズに、汎用の「パッケージ」はない
  - 一応存在するが、理論がわかっていないと使えない
  - ベイズ哲学...データを注意深く観察してモデル化する
  - 相手に応じて自分の振舞いを変える (動的: N. Wiener)



- どんな入力に対しても、一定の性能を保障するミニマックス最適化 (静的: v. Neumann)
  - 入力分布を仮定しないので、パッケージ化できる (例: SVM)
  - ただし、ノンパラベイズのような柔軟性は難しい

## 参考文献 (チュートリアル類)

---

- NIPS 2005, Michael Jordan  
<http://www.cs.berkeley.edu/~jordan/nips-tutorial05.ps>
- UAI 2005, Zoubin Ghahramani  
<http://learning.eng.cam.ac.uk/zoubin/talks/uai05tutorial-b.pdf>
- MLSS 2007, Yee Whye Teh  
<http://www.gatsby.ucl.ac.uk/~ywteh/research/npbayes/mlss2007.pdf>
- 日本語:
  - 上田&山田, 「応用数理」 2007
  - 佐藤, 中川研機械学習勉強会 2007
  - 栗原, MIRU 2008