

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)

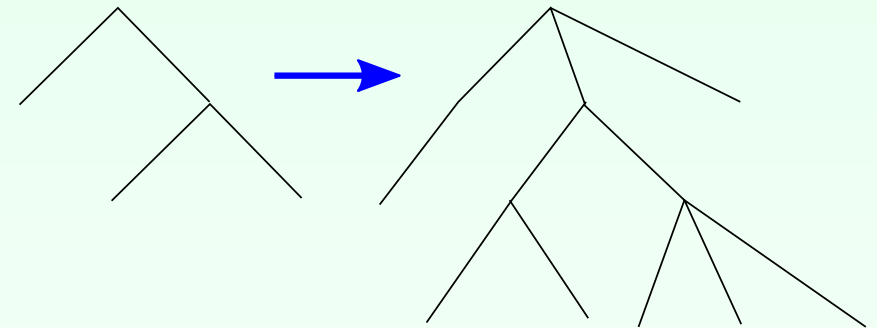
仙台

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

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

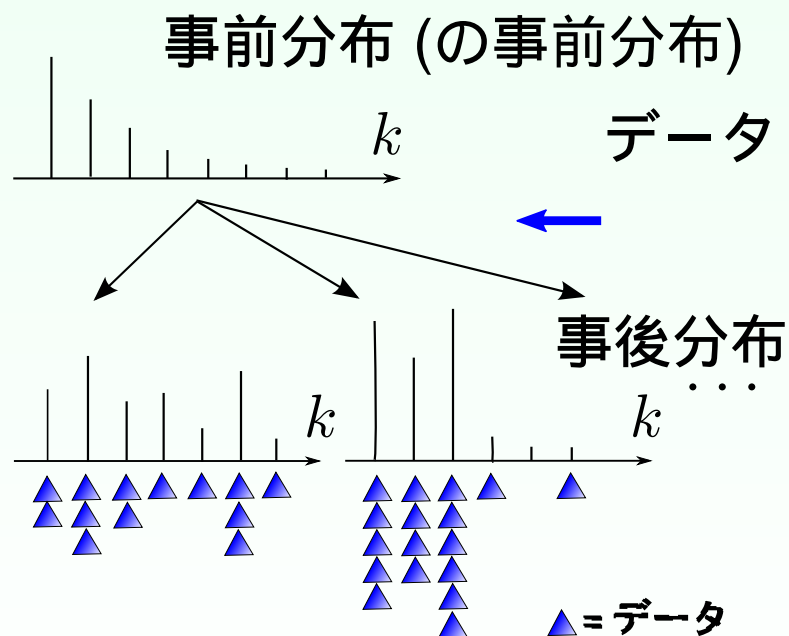
のソフト化.

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:



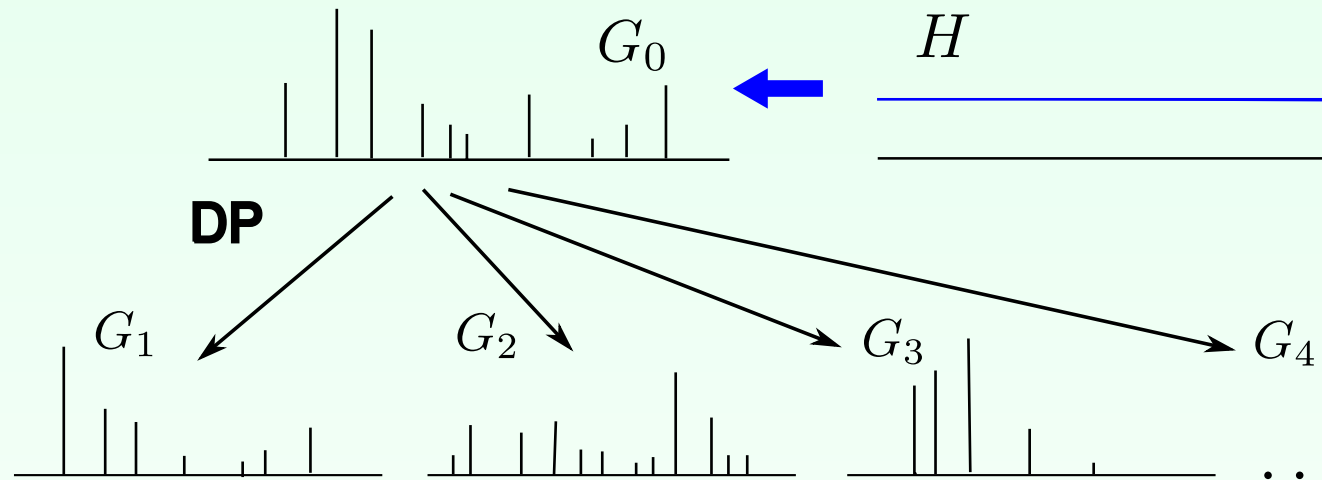
DPM:



$p(\mu) = G_0$

- 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

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

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