

Introduction to Hierarchical Pitman-Yor Processes

Daichi Mochihashi

ATR SLC

`daichi.mochihashi@atr.jp`


“Ultraconservative” SVM 2006

Aug 5, 2006

NAIST

Overview

- Pitman-Yor processes
= Two-parameter Poisson-Dirichlet process $\text{PD}(d, \theta)$
(Pitman and Yor 1997)
 - ディリクレ過程 (有限次元の場合はディリクレ分布) の拡張
- n-gram 分布の階層的な生成モデル



Background


- 現状のトピックモデル (LDA, DM など) は unigram のみ
 - Trigram とのアドホックな混合が必要になる.
 - 計算量も大きい
 - 「トピックに特有な bigram, trigram, ...」が存在
 - “mixture of” → { Gaussians, cultures, flour }
 - “everyone” → { shall (法律), 's (口語) }
 - 適切にできれば, NE recognition の代わりになる
- n-gram の, きちんとした確率モデルが必要
 - 他のモデルに部品として組み込む
 - 例. トピックモデル / 統計翻訳
 - これまでの n-gram は, カウントの smoothing (\neq 確率モデル)
 - 無限語彙を自然に扱えるモデルが必要
 - 自然言語の語彙は本当は可算無限

Pitman-Yor and DP

- HPY (Hierarchical Pitman-Yor process, Teh 2006)
… HDP (Hierarchical Dirichlet process, Teh & Jordan 2004)
の拡張
- Pitman-Yor process … Dirichlet Process (DP) の拡張
- 以下、この順番で：
 1. Dirichlet process とは？
 2. Pitman-Yor process とは？
 3. 階層 Pitman-Yor process とは？
 4. Gibbs Sampling によるパラメータ推定

Dirichlet process (DP) (Ferguson 1973) とは?

- 自然言語処理の文脈では (=1 次元の場合),
無限次元の離散分布を生成する確率モデル
のこと.
- $G \sim DP(\alpha, G_0)$ とすると, 基になる連続分布 (測度) G_0 に対して




G はそれと少し異なる, 無限次元の離散分布.

- concentration パラメータ α によって, G の G_0 との違いを調整 ($\alpha=0$ とすると完全に一致)
- 無数の G がサンプルできるが, その期待値は $E[G] = G_0$.

Stick-breaking process

- どうやって具体的に $G \sim DP(\alpha, G_0)$ をサンプルすればいい?
→ Stick-breaking process (Sethuraman 1994)
- 長さ 1 (確率の総和) の棒を, 左から切っていく
 1. まず, $\beta_1 \sim Be(1, \alpha)$ の点で棒を分割
 - 左の切れ端 π_1 : 長さ β_1
 2. 残った方を, $\beta_2 \sim Be(1, \alpha)$ でまた分割
 - 左の切れ端 π_2 : 長さ $\beta_2(1 - \beta_1)$
 3. 残った方を, $\beta_3 \sim Be(1, \alpha)$ でまた分割
 - 左の切れ端 π_3 : 長さ $\beta_3(1 - \beta_2)(1 - \beta_1)$
 4. ...



Stick-breaking process (2)

- 一般に, $G \sim \text{DP}(\alpha, G_0)$ は

$$\pi_n = \beta_n \prod_{i=1}^{n-1} (1 - \beta_i) \quad (n = 1, \dots, \infty) \quad (1)$$

$$\beta_i \sim \text{Be}(1, \alpha) \quad (2)$$

のように棒を分割して,

$$G = \sum_{k=1}^{\infty} \pi_k \delta(\theta_k) \quad (3)$$

$$\theta_k \sim G_0 \quad (4)$$

のような δ 関数の無限和で表せる.

- 自然言語のような離散分布の場合は, G_0 は自然数上の(一様)分布.

Polya urn scheme of DP

- $G \sim \text{DP}(\alpha, G_0)$ からのサンプル $\mathbf{x} = x_1, x_2, \dots, x_n$ が得られる時, 次の x は何になるか?

$$p(x|\mathbf{x}, \text{DP}(\alpha, G_0)) = \int p(x|G)p(G|\mathbf{x}, \text{DP}(\alpha, G_0))dG \quad (5)$$

$$= \sum_{k=1}^K \frac{n_k}{n+\alpha} \delta(\theta_k) + \frac{\alpha}{n+\alpha} G_0. \quad (6)$$

- θ_k ($k = 1, \dots, K$) : x_1, \dots, x_n の中の異なり成分
- n_k ($k = 1, \dots, K$) : その頻度
- ベイズ的なスムージングが得られる
 - 頻度 0 のカテゴリの確率は, $\frac{\alpha}{n+\alpha} G_0$.

Polya urn scheme of DP (2)

- これは、次の MacKay の Dirichlet smoothing とも本質的に同じ (SVM 2004)

$$p(w_i|w_j) = \frac{n_j}{n_j + \alpha} \hat{p}(i|j) + \frac{\alpha}{n_j + \alpha} \bar{\alpha}_i \quad (7)$$

$$= \frac{n_{i|j} + \alpha_i}{\sum_i (n_{i|j} + \alpha_i)} \quad (8)$$

- DM (山本 2003, Sjölander et al. 1996) とも同じ

$$p(v|\mathbf{h}) = \sum_m C_m \frac{n(v|\mathbf{h}) + \alpha_{mv}}{\sum_v (n(v|\mathbf{h}) + \alpha_{mv})} \quad (9)$$

$$C_m \propto \lambda_m \frac{\Gamma(\alpha_m)}{\Gamma(\alpha_m + h)} \prod_v \frac{\Gamma(n(v|\mathbf{h}) + \alpha_{mv})}{\Gamma(\alpha_{mv})} \quad (10)$$

Polya urn scheme of DP (3)

- 何がいけないか?

- 頻度 0 のとき,

$$p(w_i|w_j) = \frac{\alpha_i}{\sum_i(n_{i|j} + \alpha_i)} \quad (11)$$

- 頻度 1 のとき,

$$p(w_i|w_j) = \frac{1 + \alpha_i}{\sum_i(n_{i|j} + \alpha_i)} \quad (12)$$

- 通常, $\alpha \ll 1$ ($\alpha_i = 0.001$ くらい)
 - $3 + \alpha_i, 2 + \alpha_i, 1 + \alpha_i \iff \alpha_i$ … ものすごい差.

- 頻度 $(1, 2, 3, \dots)$ 自体をそのまま信用せず, ダンピングする必要があるのでは?

- - Kneser-Ney smoothing (Kneser and Ney 1995)
 - Pitman-Yor processes (Teh 2006, Pitman and Yor 1997).

Pitman-Yor process $\text{PD}(d, \theta)$

- Stick-breaking process:

- For $k = 1, 2, \dots, \infty$,

$$\beta_k \sim \text{Be}(1 - d, \theta + kd). \quad (13)$$


- k が増えるにつれ, 分割の平均位置が左に移動
 - より多くのコンポーネント (単語) に確率が割り振られる (heavy tail)
- Polya urn representation

$$p(x|\mathbf{x}, \text{PD}(d, \theta)) = \sum_{k=1}^t \frac{n_k - d}{n + \theta} \delta(\theta_k) + \frac{\theta + dt}{n + \theta} G_0 \quad (14)$$

- 前半で, カウントが常に d だけディスカウントされる
 - 後半のスムージングは DP と同じ

Hierarchical Pitman-Yor Processes

- Base measure G_0 が、また階層的に $\text{PD}(d', \theta')$ に従う
 - 3-gram : $G_3 \sim \text{PD}(d_3, \theta_3 | G_2)$
 - 2-gram : $G_2 \sim \text{PD}(d_2, \theta_2 | G_1)$
 - 1-gram : $G_1 \sim \text{PD}(d_1, \theta_1 | G_0)$
 - 0-gram : $G_0 \sim \text{uniform.} \quad (p(v) = 1/V)$



Polya Urn scheme of HPY

$$p(x|\mathbf{x}, \text{HPY}(d, \theta)) = \sum_{k=1}^t \frac{n_k - d}{c + \theta} \delta(\theta_k) + \frac{\theta + dt}{c + \theta} G_{n-1} \quad (15)$$

- n -gram 分布を, $(n-1)$ -gram 分布から生成する
- G_{n-1} は離散 … 新しい θ_{k+1} は他の θ と同じになる可能性
 - 単語 w が G_{n-1} から引かれた異なり数を $t(w)$ とすると, 上式は

$$p(x=w|\mathbf{x}, \text{HPY}(d, \theta)) = \frac{n(w) - d \cdot t(w)}{c + \theta} + \frac{\theta + dt}{c + \theta} G_{n-1}(w) \quad (16)$$

- これは, 言語モデルで最高性能といわれる Kneser-Ney スムージング (Kneser and Ney 1995)

$$p(w|h) = \frac{n(w|h) - d(n(w|h))}{n(h)} + \gamma(h)p(w) \quad (17)$$

で, $t(w)$ を常に 1 とした場合に相当する.

Chinese Restaurant Process of HPY

- 客が、無限個のテーブルがあるレストランに入って食事をする
 - 同じテーブルに座った人は、同じ料理を食べる
- どのテーブルに座るか?
 - 各テーブル k の客数 $c_k - d$ に比例した確率で選ぶ [人気順]
 - テーブルの総数 t に対して、 $\theta + dt$ に比例した確率で新しいテーブルを選ぶ
 - 新しいテーブルでは新しい料理を頼む
- レストラン = n-gram 文脈、料理 = 単語、客 = 頻度
 - ある n-gram 文脈では、Pitman-Yor process に従って料理(単語)の頻度が分布する
 - 新しいテーブルでの料理はどうやって選ぶ?

Chinese Restaurant Process of HPY (2)

- 新しいテーブルの料理は何にする?
 - 親レストランに代理の客を行かせて, そこで同様に座って出た料理と同じにする
 - 親レストランでも新しいテーブルになったら, さらに親レストランに代理の客を行かせる
- 親レストラン = $(n-1)$ -gram 文脈
 - ある文脈で, 同じ単語が複数のテーブルでサーブされている可能性がある
 - 親レストランに行ったとき, 同じ料理を出される可能性が高い [人気順]
 - $t(w)$ に相当する
- これ以上親レストランがない =0-gram 文脈
 - 仕方がないので, 厨房が新しく考える (Base measure)
 - 新しく作った単語の確率は, 文字 HMM などで計算

Inference of seating arrangements

$$p(\mathbf{s}) = \prod_w G_0(w)^{c_{0w}} \cdot \prod_u \frac{(\theta_{|u|})^{(t_{u..})} d_{|u|}}{(\theta_{|u|})^{(c_{u..})}} \prod_w \prod_{k=1}^{t_{u..}} (1 - d_{|u|})^{(c_{uwk} - 1)} \quad (18)$$

- c_{uwk} : Frequency of word w at table k in the n-gram context u
- t_{uw} : Number of tables with word w in the n-gram context u
- Gibbs sampling:

For $t = 1 \dots T$,

For $w \in \text{randperm}(\{\text{all counts in the model}\})$,

1. Remove a customer w from the restaurant.
2. Add w to the restaurant at a random table following the Pitman-Yor process.
 - When a new table is selected, choose a dish by sending a proxy customer to the parent restaurant.

Inference of hyperparameters

- Through Data augmentation (adding auxiliary variables x_u , y_{ui} , and z_{uwkj}),

$$p(\mathbf{s}) = \prod_w G_0(w)^{c_{0w}} \cdot \prod_u \frac{\int_0^1 x_u^{\theta_{|u|}} (1-x_u)^{c_{u..}-2} dx}{\Gamma(c_{u..}-1)} \prod_{i=1}^{t_{u..}-1} \sum_{y_{ui}} \theta_{|u|}^{y_{ui}} (d_{|u|} i)^{1-y_{ui}} \\ \prod_w \prod_{k=1}^{t_{u..}} \prod_{j=1}^{c_{uwk..}-1} \prod_{z_{uwkj}} (j-1)^{z_{uwkj}} (1-d_{|u|})^{1-z_{uwkj}} \quad (19)$$

- Therefore, posterior for hyperparameters are

$$d_n \sim \text{Be}\left(1 + \sum_{|u|=n} \sum_{i=1}^{t_{u..}-1} (1 - y_{ui}), 1 + \sum_{|u|=n} \sum_w \sum_{k=1}^{t_{u..}} \sum_{j=1}^{c_{uwk..}-1} (1 - z_{uwkj})\right), \quad (20)$$

$$\theta_n \sim \text{Ga}\left(\alpha_n + \sum_{|u|=n} \sum_{i=1}^{t_{u..}-1} y_{ui}, \beta_n + \sum_{|u|=n} \log x_u\right). \quad (21)$$

Implementation

```
~$ ./hpylm -h [ 9:20AM]
usage: hpylm [-n [order] -t [iteration] [-i interval] [-d] train.dat [test.dat]
$Id: hpylm.c,v 1.7 2006/07/14 13:49:48 dmochiha Exp $ [ 9:20AM]
~$
```

```
struct ngram { /* c_uxx */
    ngram *parent;
    ngram **children;
    restaurant **words;
    int nchildren;
    int nwords;
    int ncounts;
    int ntables;
    int level;
    int id;
};

struct restaurant { /* c_uwx */
    int id;
    int ntables;
    int maxtables;
    int ncounts;
    int *tables;
    ngram *context;
};
```

Small Experiments

- “Austen” language modeling in FSNLP
 - <http://nlp.stanford.edu/fsnlp/>
 - 6. “Statistical inference: n-gram models over sparse data” p.191–



- Modified Kneser-Ney smoothing, SRI LM Toolkit

```
% ngram -order 3 -lm austen3.arpa -ppl austen.test.dat  
0 zeroprobs, logprob= -186076 ppl= 135.906 ppl1= 167.651
```

- HPY Language model, Gibbs

```
% hpylm -h
```

hpylm, Hierarchical Pitman-Yor language model.

```
$Id: hpylm.c,v 1.17 2007/03/19 09:11:05 dmochiha Exp $
```

usage: hpylm -n [order] -N [iteration] train model

```
% hpylm -n 3 -N 50 austen.dat austen.n3
```

Gibbs 50 : iteration 725242 / 725242.. ETA: 0:00:00 (6 sec/sweep)
done.

```
% hpypl -N 50 austen.n3 austen.test.dat
```

loading language model from austen.n3 ..

Gibbs 50 : iteration 725242 / 725242.. PPL = 130.936

perplexity = 130.936

Seatings integrated out

- c_{uwk} 人の客(単語)が t_{uw} 個のテーブルに座る場合の数の総和を考えると,

$$p(\mathbf{s}) = \prod_w G_0(w)^{c_{0w}} \cdot \prod_u \frac{(\theta_{|u|})^{(t_{u..})}_{d_{|u|}}}{(\theta_{|u|})^{(c_{u..})}} \prod_w s_{d_{|u|}}(c_{uw..}, t_{uw}) \quad (22)$$

- テーブルごとの c_{uwk} が必要なく, その総和 c_{uw} だけですむ
- $s_d(c, t)$ は type $(-1, -d, 0)$ の一般化 Stirling 数で
 1. $s_d(0, 0) = s_d(1, 1) = 1$
 2. $s_d(c, 0) = s_d(0, t) = 0$
 3. $s_d(c, t) = s_d(c-1, t-1) + (c-1-d)t s_d(c-1, t)$
 $(0 < t \leq c)$をみたす.
- Polya 分布との類似に注意

$$p(\mathbf{x}|\boldsymbol{\alpha}) = \int p(\mathbf{x}|\mathbf{p})p(\mathbf{p}|\boldsymbol{\alpha})d\mathbf{p} = \frac{\Gamma(\sum_k \alpha_k)}{\Gamma(\sum_k \alpha_k + n_k)} \prod_k \frac{\Gamma(n_k + \alpha_k)}{\Gamma(\alpha_k)}$$

Prediction and Inference with seatings integrated out

- モデル全体がハイパーパラメータおよびカウント c_{uw}, t_{uw} の推定値で記述できる時,

$$p(w|u) = \sum_{c_{uw}} \sum_{t_{uw}} p(w, c_{uw}, t_{uw} | u) \quad (24)$$

$$= \sum_{c_{uw}} \sum_{t_{uw}} p(w|u, c_{uw}, t_{uw}) p(t_{uw}|u, c_{uw}) p(c_{uw}|u) \quad (25)$$

$$= \sum_{c_{uw}} p(c_{uw}|u) \sum_{t_{uw}} p(w|u, c_{uw}, t_{uw}) p(t_{uw}|u, c_{uw}). \quad (26)$$

- $p(c_{uw}|u)$ 及び $p(t_{uw}|u, c_{uw})$ を推定 \rightarrow LBP で行けるらしい
 - 実際には, $p(c_{uw}, t_{uw}|u)$ の同時分布が必要 (行列)
 - カウント c_{uw} が大きいとき, パラメータ量膨大
 - Gibbs では, (c_{uwk}, t_{uw}) の確率の高い組だけを確定的にサンプリングして取り出している.

Future Works

- Topic modeling with HPY n-gram.
 - How to combine HPY n-gram with EM? (HMM)
 - 計算量の多い $s_d(c, t)$ の近似
- Mittag-Leffler distribution, Gamma process, Lévy measure, ..など、知らないことが沢山
- Dependent Dirichlet process (DDP) (Griffin & Steel 2004)
 - レストランで「客がしばらくすると席を立つ」ことを許す.