

# わかりやすいパターン認識

## 第12章 ディリクレ過程混合モデルによるクラスタリグ

河野 和平

# ディリクレ過程混合モデル

- 通常の混合モデル
  - 予め混合数(クラスタ数  $c$ )を設定
- ディリクレ過程混合モデル
  - ディリクレ過程により決定

$$\text{Step1. } G(\theta) | \alpha, G_0(\theta) \sim DP(\alpha, G_0(\theta))$$

$$\text{Step2. } \theta^k \sim G(\theta) \quad (k = 1, \dots, n)$$

$$\text{Step3. } x_k | \theta \sim p(x | \theta^k) \quad (k = 1, \dots, n)$$

# CRPに基づくディリクレ過程混合モデル

- クラスタリング応用

- 各パターンの所属クラスを表す潜在変数  $s_k$

Step1.  $s_1, \dots, s_n | \alpha \sim CRP(\alpha)$

Step2.  $\theta_i | \beta \sim G_0(\theta) \quad (i = 1, \dots, \infty)$

Step3.  $x_k | s_k, \theta \sim p(x | \theta_{s_k}) \quad (k = 1, \dots, n)$

$p(x | \theta_i) \rightarrow$  正規分布

$\theta_i \rightarrow$  平均ベクトル  $\mu_i$  , 共分散行列  $\Sigma_i$

# ギブスサンプリング(1)

- 生成モデル

$$p(\mathbf{s}, \theta | \mathbf{x}) = \frac{p(\mathbf{x} | \mathbf{s}, \theta) P(\mathbf{s}) p(\theta)}{p(\mathbf{x})} = \frac{p(\mathbf{x} | \mathbf{s}, \theta) P(\mathbf{s}) p(\theta)}{\sum_{\mathbf{s}} \int p(\mathbf{x} | \mathbf{s}, \theta) P(\mathbf{s}) p(\theta) d\theta} \quad (11.4)$$

$$(\hat{\mathbf{s}}, \hat{\theta}) = \operatorname{argmax}_{\mathbf{s}, \theta} \{P(\mathbf{s}, \theta | \mathbf{x})\} \quad (11.5)$$

$$P(\mathbf{s} | \mathbf{x}) = \frac{p(\mathbf{x} | \mathbf{s}) P(\mathbf{s})}{p(\mathbf{x})} = \frac{p(\mathbf{x} | \mathbf{s}) P(\mathbf{s})}{\sum_{\mathbf{s}} p(\mathbf{x} | \mathbf{s}) P(\mathbf{s})} \quad (11.6)$$

$$\hat{\mathbf{s}} = \operatorname{argmax}_{\mathbf{s}} \{P(\mathbf{s} | \mathbf{x})\} \quad (11.7)$$

– 組み合わせ数: 膨大

# ギブスサンプリング(2)

- $n$  個のパターンのうち任意の1個をとる。
  - 最後に入力されたパターン  $x_n$  とみなす。
  - 所属クラスを確率的に決定
  - いずれのパターンも最後のパターンとみなせる。
    - $n$  個すべてのパターンで繰り返す。

# 所属クラスタの確率的生成

- 事後確率

$$\begin{aligned} P(s_k = \omega_i | \mathbf{x}_k, \mathbf{s}_{-k}, \mathbf{x}_{-k}, \boldsymbol{\theta}) \\ = \frac{p(\mathbf{x}_k, s_k = \omega_i | \mathbf{s}_{-k}, \mathbf{x}_{-k}, \boldsymbol{\theta})}{p(\mathbf{x}_k | \mathbf{s}_{-k}, \mathbf{x}_{-k}, \boldsymbol{\theta})} \end{aligned} \quad (12.7)$$

$$\propto p(\mathbf{x}_k, s_k = \omega_i | \mathbf{s}_{-k}, \mathbf{x}_{-k}, \boldsymbol{\theta}) \quad (12.8)$$

$$= p(\mathbf{x}_k | s_k = \omega_i, \mathbf{x}_{-k}, \boldsymbol{\theta}) P(s_k = \omega_i | \mathbf{s}_{-k}, \mathbf{x}_{-k}, \boldsymbol{\theta}) \quad (12.9)$$

$$= p(\mathbf{x}_k | s_k = \omega_i, \boldsymbol{\theta}) P(s_k = \omega_i | \mathbf{s}_{-k}) \quad (12.10)$$

# 所属クラスとパラメータ(1)

- 既存クラス:  $\omega_i$
- 新規クラス:  $\omega_{new}$

$$P(s_k = \omega_i | x_k, s_{-k}, x_{-k}, \theta) \\ \propto p(x_k | s_k = \omega_i, \theta) P(s_k = \omega_i | s_{-k})$$

$$p(x_k | s_k = \omega_i, \theta) = \begin{cases} p(x_k | \theta_i) \\ \int p(x_k | \theta_{new}) G_0(\theta_{new}) d\theta_{new} \end{cases}$$

$$p(s_k | s_{-k}) = \begin{cases} \frac{n'_i}{n-1+\alpha} \\ \frac{\alpha}{n-1+\alpha} \end{cases}$$

# 所属クラスとパラメータ(2)

$$P(s_k | \mathbf{x}_k, \mathbf{s}_{-k}, \mathbf{x}_{-k}, \theta)$$
$$\propto \begin{cases} \frac{n'_i}{n-1+\alpha} \cdot p(\mathbf{x}_k | \theta_i) & (s_k = \omega_i \text{ のとき}) \\ \frac{\alpha}{n-1+\alpha} \cdot \int p(\mathbf{x}_k | \theta_{new}) G_0(\theta_{new}) d\theta_{new} & (s_k = \omega_{new} \text{ のとき}) \end{cases} \quad (12.14)$$

$$p(\theta_i | \{\mathbf{x}_k; \mathbf{x}_k \in \omega_i\}) = \frac{p(\{\mathbf{x}_k; \mathbf{x}_k \in \omega_i\} | \theta_i) \cdot G_0(\theta_i)}{p(\{\mathbf{x}_k; \mathbf{x}_k \in \omega_i\})}$$
$$= \frac{G_0(\theta_i) \cdot \prod_{\mathbf{x}_k \in \omega_i} p(\mathbf{x}_k | \theta_i)}{\int G_0(\theta_i) \cdot \prod_{\mathbf{x}_k \in \omega_i} p(\mathbf{x}_k | \theta_i) d\theta_i} \quad (12.15)$$

# 所属クラスのみ

$$P(s_k | \mathbf{x}_k, \mathbf{s}_{-k}, \mathbf{x}_{-k}) \propto \begin{cases} \frac{n'_i}{n-1+\alpha} \int p(\mathbf{x}_k | \theta_i) p(\theta_i | \mathbf{x}_{-k}) d\theta_i \\ \quad (s_k = \omega_i \text{ のとき}) \\ \frac{\alpha}{n-1+\alpha} \int p(\mathbf{x}_k | \theta_{new}) G_0(\theta_{new}) d\theta_{new} \\ \quad (s_k = \omega_{new} \text{ のとき}) \end{cases} \quad (12.23)$$

- $\theta$  が積分消去・・・崩壊型ギブスサンプリング

# 実験

- 正規分布

$$\begin{aligned}\mathcal{N}(\mathbf{x}_k; \boldsymbol{\mu}, \boldsymbol{\Sigma}) &= \mathcal{N}(\mathbf{x}_k; \boldsymbol{\mu}, \boldsymbol{\Lambda}^{-1}) \\ &= \frac{|\boldsymbol{\Lambda}|^{1/2}}{(2\pi)^{d/2}} \exp \left[ -\frac{1}{2} (\mathbf{x}_k - \boldsymbol{\mu})^t \boldsymbol{\Lambda} (\mathbf{x}_k - \boldsymbol{\mu}) \right]\end{aligned}$$

- 基底分布

- 精度行列  $\boldsymbol{\Lambda}$  , 平均ベクトル  $\boldsymbol{\mu}$  が未知
- 共役事前分布: 正規-ウィーシャート分布



$$G_0(\boldsymbol{\theta}) = G_0(\boldsymbol{\mu}, \boldsymbol{\Lambda}) = \mathcal{N}(\boldsymbol{\mu}; \boldsymbol{\mu}_0, (\beta\boldsymbol{\Lambda})^{-1}) \cdot \mathcal{W}(\boldsymbol{\Lambda}; \nu, \mathbf{S})$$

$$\alpha = 1.0$$

$$\boldsymbol{\mu}_0 = \boldsymbol{\mu}_{all}, \quad \beta = 1/3, \quad \nu = 15, \quad \mathbf{S} = \begin{pmatrix} 0.1 & 0 \\ 0 & 0.1 \end{pmatrix}$$

# 実験結果

- 所属クラスとパラメータ



# 実験結果

- 所属クラスのみ

