

混合分布のパラメータ推定

本: わかりやすいパターン認識

菊池裕紀


混合分布に対するパラメトリックな手法

確率密度関数

$$p(x|\omega_i) \quad (x = \{v_1, v_2, \dots, v_m\})$$

↓ **正規分布**に従うとすると...

$$p(x|\omega_i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{1}{2}\frac{(x - \mu_i)^2}{\sigma_i^2}\right]$$



× $P(v_k|\omega_i)$ ($k = 1, 2, \dots, m$)を推定する

○ x の平均 μ_i と分散 σ_i^2 の2つのパラメータを求める (**パラメトリックな学習**)

観測データから直接識別関数を設計 (**ノンパラメトリックな学習**)

パラメトリック手法によるパラメータ推定

- クラス ω_i ($i = 1, 2, \dots, c$) がそれぞれ異なった確率密度比をもつ
- 観測結果が c 個の確率密度比による**混合分布**に従う
- 観測データは独立でマルコフ性はない

→ パラメトリックな手法によるパラメータ推定

ω_i の確率密度関数 $p(x|\omega_i; \theta_i)$

$\theta = (\theta_1, \theta_2, \dots, \theta_c, \pi_1, \pi_2, \dots, \pi_c)$

混合分布の確率密度関数 $p(x_k; \theta) = \sum_{i=1}^c \pi_i * p(x_k|\omega_i; \theta_i)$ ($k = 1, 2, \dots, n$)

パラメータ推定を「教師付き学習」「教師なし学習」で行っていく

教師付き学習によるパラメータ推定(1)

- 教師付き学習の場合:

データ: $(x_1, s_1), (x_2, s_2), \dots, (x_n, s_n)$ $s_k \in (w_1, w_2, \dots, w_c)$

観測結果と所属クラスが対の形のデータが得られる

尤度: $p(X, S; \theta) = \prod_{k=1}^n P(s_k) \prod_{k=1}^n p(x_k | s_k; \theta_1, \theta_2, \dots, \theta_c)$
($X = (x_1, x_2, \dots, x_n)$, $S = (s_1, s_2, \dots, s_n)$)

対数尤度: $\log p(X, S, \theta) = \sum_{k=1}^n \log P(s_k) + \sum_{k=1}^n \log p(x_k | s_k; \theta_1, \dots, \theta_c)$
 $= L_1 + L_2$

教師付き学習によるパラメータ推定(2)

$$\log p(\mathbf{X}, \mathbf{S}, \boldsymbol{\theta}) = L_1 + L_2$$

$$L_1 \stackrel{\text{def}}{=} \sum_{k=1}^n \log P(s_k):$$

π_i について最大化

$$L_2 \stackrel{\text{def}}{=} \sum_{k=1}^n \log p(x_k | s_k; \theta_1, \dots, \theta_c):$$

θ_i について最大化

L_1 の最大化:

$$\hat{\pi}_i = \frac{n_i}{n} \quad (n_i: \omega_i \text{ から発生した観測データの総数})$$

教師付き学習によるパラメータ推定(2)

- L_2 の最大化:

$$L_2 = \sum_{i=1}^c \sum_{x_k \in \omega_i} \log p(x_k | w_i; \theta_i)$$

これを最大化する θ_i は以下を満たす必要がある:

$$\nabla_{\theta_i} L_2 = \sum_{x_k \in \omega_i} \nabla_{\theta_i} \log p(x_k | w_i; \theta_i) = 0$$

教師なし学習によるパラメータ推定(1)

- 教師なし学習の場合:

データ: (x_1, x_2, \dots, x_n)

対数尤度: $\log p(X; \theta) = \sum_{k=1}^n \log p(x_k; \theta)$

制約条件: $\sum_{i=1}^c \pi_i = 1$

$$L = \log p(X; \theta) - \lambda(\sum_{i=1}^c \pi_i - 1)$$

$$\frac{\partial L}{\partial \pi_i} = 0, \quad \nabla_{\theta_i} L = 0$$

教師なし学習によるパラメータ推定(2)

- π_i の推定

$$\hat{\pi}_i = \frac{1}{n} \sum_{k=1}^n P(\omega_i | x_k; \theta)$$

- θ_i の推定

$$\begin{aligned} \nabla_{\theta_i} L &= \nabla_{\theta_i} \log p(\mathbf{X}; \theta) \\ &= \sum_{k=1}^n \frac{1}{p(x_k; \theta)} \nabla_{\theta_i} p(x_k; \theta) \\ &= \sum_{k=1}^n \frac{1}{p(x_k; \theta)} \nabla_{\theta_i} \left(\sum_{j=1}^c \pi_j * p(x_k | w_j; \theta_j) \right) \\ &= \sum_{k=1}^n \frac{\pi_i}{p(x_k; \theta)} \nabla_{\theta_i} p(x_k | \omega_i; \theta_i) = 0 \end{aligned}$$

教師なし学習によるパラメータ推定(3)

ベイズ推定を利用:

$$P(\omega_i|x_k; \theta) = \frac{\pi_i * p(x_k|\omega_i; \theta_i)}{p(x_k; \theta)}$$

$$\begin{aligned}\nabla_{\theta_i} L &= \sum_{k=1}^n P(\omega_i|x_k; \theta) * \frac{\nabla_{\theta_i} p(x_k|\omega_i; \theta)}{p(x_k|\omega_i; \theta_i)} \\ &= \sum_{k=1}^n P(\omega_i|x_k; \theta) \nabla_{\theta_i} \log p(x_k|\omega_i; \theta_i) = 0\end{aligned}$$

推定手順

1. 事前確率 π_i およびパラメータ θ_i に初期値を与える
2. ベイズの定理より、各 x_k に対して $P(\omega_i|x_k; \theta)$ を計算する
3. 以下の式により π_i, θ_i を更新し、新しい値を得る

$$\square \hat{\pi}_i = \frac{1}{n} \sum_{k=1}^n P(\omega_i|x_k; \theta)$$

$$\square \sum_{k=1}^n P(\omega_i|x_k; \theta) \nabla_{\theta_i} \log p(x_k|\omega_i; \theta_i) = 0$$

4. 新しい値で対数尤度を計算し、その増分が閾値以下なら終了し、違えば Step2に戻る

混合正規分布のパラメータ推定

- 混合分布の確率密度関数に正規分布を考える
- パラメータを教師なし学習で推定

$$p(X_k | \omega_i; \theta_i) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|} \exp \left[-\frac{1}{2} (X_k - \mu_i)^t \Sigma_i^{-1} (X_k - \mu_i) \right]$$

$(\theta_i = (\mu_i, \Sigma_i))$

$$\hat{\mu}_i = \frac{\sum_{k=1}^n P(\omega_i | X_k; \theta) X_k}{\sum_{k=1}^n P(\omega_i | X_k; \theta)}, \quad \hat{\Sigma}_i = \frac{\sum_{k=1}^n P(\omega_i | X_k; \theta) (X_k - \hat{\mu}_i)(X_k - \hat{\mu}_i)^t}{\sum_{k=1}^n P(\omega_i | X_k; \theta)}$$

$$\hat{\pi}_i = \frac{1}{n} \sum_{k=1}^n P(\omega_i | X_k; \theta)$$

推定手順

1. 事前確率 π_i および μ_i, Σ_i の初期値を与える
2. ベイズの定理より、各 X_k に対して $P(\omega_i|X_k; \theta)$ を計算
3. 以下より新しい値を求める

$$\square \hat{\pi}_i = \frac{1}{n} \sum_{k=1}^n P(\omega_i|X_k; \theta), \quad \hat{\mu}_i = \frac{\sum_{k=1}^n P(\omega_i|X_k; \theta) X_k}{\sum_{k=1}^n P(\omega_i|X_k; \theta)}$$

$$\square \hat{\Sigma}_i = \frac{\sum_{k=1}^n P(\omega_i|X_k; \theta) (X_k - \hat{\mu}_i)(X_k - \hat{\mu}_i)^t}{\sum_{k=1}^n P(\omega_i|X_k; \theta)}$$

4. 対数尤度を求め、増分が設定した閾値以下なら終了し、違うならばStep2へ