

Mixture Models
&
The EM Algorithm

Toru Wakahara

[1] 確率密度関数の推定

- セミパラメトリックな方法

[2] 混合モデル

- 基本的な考え方
- 最尤法
- The EM algorithm
- The EM algorithm の適用例

確率密度関数推定の方法

[1] パラメトリックな方法

確率密度関数として特定の関数形を選択し、関数パラメータをデータセットに合うように最適化する。

[2] ノンパラメトリックな方法

自由度の大きな汎用関数を用いて、データセットを忠実に反映するように確率密度関数を構成する。

[3] セミパラメトリックな方法

特定の関数形の重ね合せ（混合モデル）でデータセットの分布を近似する。

セミパラメトリックな方法

特定の関数形の重ね合せにより
データを忠実に表現 → 混合モデル

(1) 最尤法

正規分布の混合モデルで、最尤推定により分布パラメータや混合比を決定する。

(2) The EM algorithm

学習データを用いて、expectation step → maximization stepを反復して、混合モデルの反復解法を与える。

混合モデルの基本的考え方(1)

カーネル法: N 点での核関数の重ね合せ

$$\tilde{p}(\mathbf{x}) = \frac{1}{N} \sum_{n=1}^N \frac{1}{(2\pi h^2)^{d/2}} \exp\left\{-\frac{\|\mathbf{x} - \mathbf{x}_n\|^2}{2h^2}\right\}$$

混合モデル: M 個の分布の重ね合せ

$$p(\mathbf{x}) = \sum_{j=1}^M p(\mathbf{x} | j) P(j)$$

$$\sum_{j=1}^M P(j) = 1, \quad 0 \leq P(j) \leq 1, \quad \int p(\mathbf{x} | j) d\mathbf{x} = 1$$

混合モデルの基本的考え方(2)

混合モデル: M 個の分布の重ね合せ

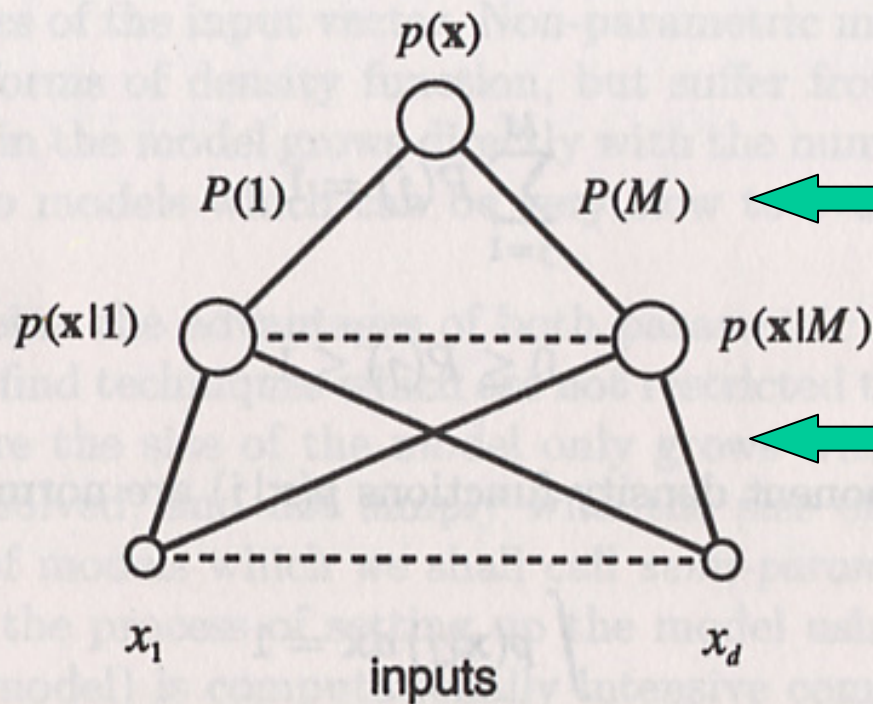
$$p(\mathbf{x}) = \sum_{j=1}^M p(\mathbf{x} | j) P(j)$$

$P(j)$: j 番目の分布の事前確率

$p(\mathbf{x} | j)$: j 番目の分布の確率密度関数

$$p(\mathbf{x} | j) = \frac{1}{(2\pi\sigma_j^2)^{d/2}} \exp\left\{-\frac{\|\mathbf{x} - \boldsymbol{\mu}_j\|^2}{2\sigma_j^2}\right\}$$

混合モデルの基本的考え方(3)



$P(j)$: 混合パラメータ

μ_j, σ_j : 分布パラメータ

混合モデル: $P(j), \mu_j, \sigma_j$ をデータセットを用いてどう決定するか

最尤法の適用

「尤度＝データセット X の生起確率」の最大化

➡ マイナス対数尤度 E の最小化

$$\begin{aligned} E &= -\ln L = -\ln \prod_{n=1}^N p(\mathbf{x}_n) = -\sum_{n=1}^N \ln p(\mathbf{x}_n) \\ &= -\sum_{n=1}^N \ln \left\{ \sum_{j=1}^M p(\mathbf{x}_n | j) P(j) \right\} \end{aligned}$$

→ min for $\mu_j, \sigma_j, P(j)$

μ_j の最尤推定

$$\begin{aligned}\frac{\partial E}{\partial \mu_j} &= -\sum_{n=1}^N \frac{P(j)}{p(\mathbf{x}_n)} \frac{\partial p(\mathbf{x}_n | j)}{\partial \mu_j} \\ &= \sum_{n=1}^N \frac{P(j) p(\mathbf{x}_n | j) (\mu_j - \mathbf{x}_n)}{p(\mathbf{x}_n) \sigma_j^2} \\ &= \sum_{n=1}^N P(j | \mathbf{x}_n) \frac{(\mu_j - \mathbf{x}_n)}{\sigma_j^2} = \mathbf{0} \\ \therefore \hat{\mu}_j &= \frac{\sum_n P(j | \mathbf{x}_n) \mathbf{x}_n}{\sum_n P(j | \mathbf{x}_n)}\end{aligned}$$

σ_j の最尤推定

$$\begin{aligned}\frac{\partial E}{\partial \sigma_j} &= -\sum_{n=1}^N \frac{P(j)}{p(\mathbf{x}_n)} \frac{\partial p(\mathbf{x}_n | j)}{\partial \sigma_j} \\ &= \sum_{n=1}^N P(j | \mathbf{x}_n) \left\{ \frac{d}{\sigma_j} - \frac{\|\mathbf{x}_n - \boldsymbol{\mu}_j\|^2}{\sigma_j^3} \right\} = 0\end{aligned}$$

$$\therefore \hat{\sigma}_j^2 = \frac{1}{d} \frac{\sum_n P(j | \mathbf{x}_n) \|\mathbf{x}_n - \hat{\boldsymbol{\mu}}_j\|^2}{\sum_n P(j | \mathbf{x}_n)}$$

$P(j)$ の最尤推定

$$P(j) = \frac{\exp(\gamma_j)}{\sum_{k=1}^M \exp(\gamma_k)} \left(0 \leq P(j) \leq 1, \sum_{j=1}^M P(j) = 1 \right)$$

と $P(j)$ を the softmax function で巧妙に表現すると

$$\frac{\partial E}{\partial \gamma_j} = \sum_{k=1}^M \frac{\partial E}{\partial P(k)} \frac{\partial P(k)}{\partial \gamma_j} = - \sum_{n=1}^N \{ P(j | \mathbf{x}_n) - P(j) \} = 0$$

$$\therefore \hat{P}(j) = \frac{1}{N} \sum_{n=1}^N P(j | \mathbf{x}_n)$$

最尤法の解

$$\hat{\boldsymbol{\mu}}_j = \frac{\sum_n P(j | \mathbf{x}_n) \mathbf{x}_n}{\sum_n P(j | \mathbf{x}_n)} \quad \hat{\sigma}_j^2 = \frac{1}{d} \frac{\sum_n P(j | \mathbf{x}_n) \|\mathbf{x}_n - \hat{\boldsymbol{\mu}}_j\|^2}{\sum_n P(j | \mathbf{x}_n)}$$

$$\hat{P}(j) = \frac{1}{N} \sum_{n=1}^N P(j | \mathbf{x}_n) \quad P(j | \mathbf{x}_n) = \frac{p(\mathbf{x}_n | j) P(j)}{p(\mathbf{x}_n)}$$

最尤解を求めるには $P(j | \mathbf{x}_n)$ が必要である。
しかし、 $P(j | \mathbf{x}_n)$ はベイズの定理により
 $p(\mathbf{x}_n | j)$, $P(j)$ が分からないと求まらない！

最尤法 (E 最小化) の反復解法へ

パラメータの更新による尤度の変化に注目

$$\begin{aligned} E^{\text{new}} - E^{\text{old}} &= -\sum_{n=1}^N \ln p^{\text{new}}(\mathbf{x}_n) + \sum_{n=1}^N \ln p^{\text{old}}(\mathbf{x}_n) \\ &= -\sum_n \ln \left\{ \frac{p^{\text{new}}(\mathbf{x}_n)}{p^{\text{old}}(\mathbf{x}_n)} \right\} \\ &= -\sum_n \ln \left\{ \frac{\sum_j P^{\text{new}}(j) p^{\text{new}}(\mathbf{x}_n | j)}{p^{\text{old}}(\mathbf{x}_n)} \frac{P^{\text{old}}(j | \mathbf{x}_n)}{P^{\text{old}}(j | \mathbf{x}_n)} \right\} \end{aligned}$$

The EM algorithm (1)

$$E^{\text{new}} - E^{\text{old}} = -\sum_n \ln \left\{ \frac{\sum_j P^{\text{new}}(j) p^{\text{new}}(\mathbf{x}_n | j) P^{\text{old}}(j | \mathbf{x}_n)}{p^{\text{old}}(\mathbf{x}_n) P^{\text{old}}(j | \mathbf{x}_n)} \right\}$$

上式で Jensen 不等式を用いると

$$\lambda_j \geq 0, \sum_j \lambda_j = 1 \rightarrow \ln \left(\sum_j \lambda_j x_j \right) \geq \sum_j \lambda_j \ln x_j$$


$$E^{\text{new}} - E^{\text{old}} \leq -\sum_n \sum_j P^{\text{old}}(j | \mathbf{x}_n) \ln \left\{ \frac{P^{\text{new}}(j) p^{\text{new}}(\mathbf{x}_n | j)}{p^{\text{old}}(\mathbf{x}_n) P^{\text{old}}(j | \mathbf{x}_n)} \right\} \equiv Q$$

Q の最小化 $\rightarrow E^{\text{new}}$ の上限の最小化


The EM algorithm (2)

Expectation step: E^{new} の上限値を評価

$$\tilde{Q} = -\sum_n \sum_j P^{\text{old}}(j | \mathbf{x}_n) \ln \left\{ P^{\text{new}}(j) p^{\text{new}}(\mathbf{x}_n | j) \right\}$$




反復解法



Maximization step: E^{new} の上限値の最小化

$$\tilde{Q} + \lambda \left(\sum_j P^{\text{new}}(j) - 1 \right) \rightarrow \min \text{ for } \theta^{\text{new}}$$

The EM algorithm (3)




$$E^{\text{new}} \leq E^{\text{old}} + Q(\theta^{\text{new}})$$

$Q(\theta^{\text{new}})$ の最小化 $\rightarrow E^{\text{new}}$ の上限の最小化

The EM algorithm (4)

正規分布の場合:

$$\tilde{Q} = - \sum_n \sum_j P^{\text{old}}(j | \mathbf{x}_n) \times \left\{ \ln P^{\text{new}}(j) - d \ln \sigma_j^{\text{new}} - \frac{\|\mathbf{x}_n - \boldsymbol{\mu}_j^{\text{new}}\|^2}{2(\sigma_j^{\text{new}})^2} \right\} + \text{const.}$$



Lagrange の未定乗数法

$$\tilde{Q} + \lambda \left(\sum_j P^{\text{new}}(j) - 1 \right) \rightarrow \min \text{ for } \boldsymbol{\mu}_j^{\text{new}}, \sigma_j^{\text{new}}, P^{\text{new}}(j)$$

The EM algorithm (5)

正規分布の混合モデルでの EM 解:

$$\boldsymbol{\mu}_j^{\text{new}} = \frac{\sum_n P^{\text{old}}(j | \mathbf{x}_n) \mathbf{x}_n}{\sum_n P^{\text{old}}(j | \mathbf{x}_n)} \quad P^{\text{new}}(j) = \frac{1}{N} \sum_{n=1}^N P^{\text{old}}(j | \mathbf{x}_n)$$

$$(\sigma_j^{\text{new}})^2 = \frac{1}{d} \frac{\sum_n P^{\text{old}}(j | \mathbf{x}_n) \|\mathbf{x}_n - \boldsymbol{\mu}_j^{\text{new}}\|^2}{\sum_n P^{\text{old}}(j | \mathbf{x}_n)}$$

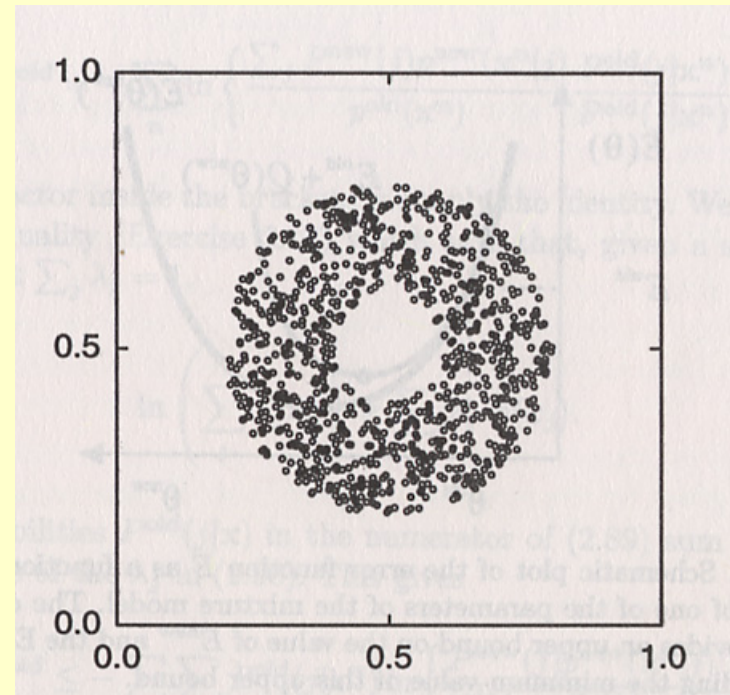
$$\text{where } P^{\text{old}}(j | \mathbf{x}_n) = \frac{p^{\text{old}}(\mathbf{x}_n | j) P^{\text{old}}(j)}{\sum_k p^{\text{old}}(\mathbf{x}_n | k) P^{\text{old}}(k)}$$

課題3

混合モデルのEM解を体験してみよう.

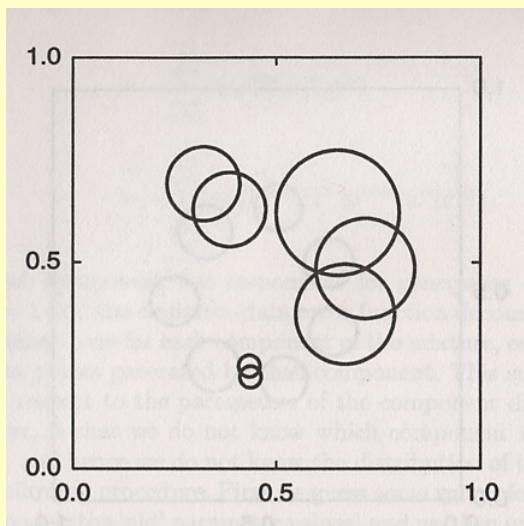
具体例として, 下図のように, 中心 $(0.5, 0.5)$ の環状(内径:0.1, 外径:0.3)内に分布するデータ1000点を一様乱数を用いて発生しなさい.

この分布を正規分布の混合モデルで近似してみる.





課題3 (続き)

モデルセンタはランダムに M 点選択して,
 $P(j) = 1/M$, $\sigma_j =$ 最近傍センタまでの距離,
で初期化し, EM 解を求めてみなさい.



正規分布の
初期配置 ($M = 7$)



正規分布の最終配置
(反復20回)