

# EMアルゴリズム

( Expectation – Maximization )

渡辺澄夫

# 目標

$L(w) = \sum_{i=1}^n \log p(x_i|w)$  を最大にする  $w$  を求めたい

しかし、例えば、混合正規分布では解けない。


繰り返し法でさがす。

# 例：混合正規分布

$$w = (a_k, b_k, \sigma_k)$$

$$\left( \begin{array}{l} K \\ \sum_{k=1} a_k = 1 \end{array} \right)$$

$$p(x|w) = \sum_{k=1}^K a_k \frac{1}{(2\pi\sigma_k^2)^{N/2}} \exp\left(-\frac{\|x - b_k\|^2}{2\sigma_k^2}\right)$$



平均  $b_k$ , 分散  $\sigma_k^2$  の  
正規分布

# 隠れ変数(潜在変数)の導入

$$p(\mathbf{x}|\mathbf{w}) = \sum_{k=1}^K a_k \frac{1}{(2\pi\sigma_k^2)^{N/2}} \exp\left(-\frac{\|\mathbf{x} - \mathbf{b}_k\|^2}{2\sigma_k^2}\right)$$



y について周辺化

$$p(\mathbf{x}, \mathbf{y}|\mathbf{w}) = \prod_{k=1}^K \left[ a_k \frac{1}{(2\pi\sigma_k^2)^{N/2}} \exp\left(-\frac{\|\mathbf{x} - \mathbf{b}_k\|^2}{2\sigma_k^2}\right) \right]^{y_k}$$


$\mathbf{y} = (y_1, y_2, \dots, y_K)$  は、どれかひとつだけ1で残りは0

隠れ変数を使うと確率分布が簡単になる。

$$p(\mathbf{x}, \mathbf{y} | \mathbf{w}) = \prod_{k=1}^K \left[ a_k \frac{1}{(2\pi\sigma_k^2)^{N/2}} \exp\left(-\frac{\|\mathbf{x} - \mathbf{b}_k\|^2}{2\sigma_k^2}\right) \right]^{y_k}$$

$$= \exp\left[-\sum_{k=1}^K y_k \left\{ \|\mathbf{x} - \mathbf{b}_k\|^2 / 2\sigma_k^2 - N \log \sigma_k + \log a_k \right\}\right]$$

(定数項は省略)



$$(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_K) = (1, 0, \dots, 0), (0, 1, 0, \dots, 0), \dots, (0, 0, \dots, 1)$$

# 準備

任意の  $w_1, w_2$  について

$$\int p(y|w_1) \log p(y|w_2) dy \leq \int p(y|w_1) \log p(y|w_1) dy$$

(証明) カルバック情報量の性質からすぐ。

$$\int p(y|w_1) \log [p(y|w_1)/p(y|w_2)] dx \geq 0$$

(応用)  $\int p(y|w_1) \log p(y|w_2) dy$  の  $w_2$  に  $w_1$  を代入すると大きくなる。

# EM法のアプローチ

$$G(w_1, w_2) = \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log p(x_i, y | w_2)$$

- (1)  $w_1$  初期化
- (2)  $G(w_1, w_2)$ を  $w_2$  について最大化( $w_1$  固定)
- (3)  $w_1 := w_2$  として(2)に戻る。

以下で、なぜこれで尤度が単調非減少かを説明する。

# なぜEM法でよいのかの説明: $G^*(w_1, w_2)$ が必要

## 定義

$$G^*(w_1, w_2) \equiv G(w_1, w_2) - \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log p(y | x_i, w_1)$$

$$= \sum_{i=1}^n \sum_y p(y | x_i, w_1) \{ \log p(x_i, y | w_2) - \log p(y | x_i, w_1) \}$$

$$= \sum_{i=1}^n \sum_y p(y | x_i, w_1) \{ \log p(x_i | w_2) + \log p(y | x_i, w_2) - \log p(y | x_i, w_1) \}$$

$$= \sum_{i=1}^n \log p(x_i | w_2) - \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log \frac{p(y | x_i, w_1)}{p(y | x_i, w_2)}$$



関数  $G^*(w_1, w_2)$  は 対数尤度 - KL情報量

$$G^*(w_1, w_2)$$

$$= \underbrace{\sum_{i=1}^n \log p(x_i | w_2)}_{L(w_2)} - \underbrace{\sum_{i=1}^n \sum_y p(y | x_i, w_1) \log \frac{p(y | x_i, w_1)}{p(y | x_i, w_2)}}_{w_2=w_1 \text{ のとき最大値 } 0}$$

$L(w)$  が  $w^*$  で最大  $\Leftrightarrow G^*(w_1, w_2)$  が  $w_1=w_2=w^*$  で最大

$L(w)$  を最大化したい  $\rightarrow G^*(w_1, w_2)$  を最大化すればよい

# EM法でなぜ尤度は大きくなるかの説明

$$\begin{aligned} G^*(w_1, w_2) &= G(w_1, w_2) - \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log p(y | x_i, w_1) \\ &= \sum_{i=1}^n \log p(x_i | w_2) - \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log \frac{p(y | x_i, w_1)}{p(y | x_i, w_2)} \end{aligned}$$

(1)  $w_1$  初期化

(2)  $G(w_1, w_2)$  を  $w_2$  について最大化  $G^*(w_1, w_2)$  増加

(3)  $w_1 := w_2$  として(2)に戻る。  $G^*(w_1, w_2)$  増加

$G^*(w_1, w_2)$  は増加  $\rightarrow L(w_1)$  が大きくなっていく。

ステップ(2)の最大化の計算を次ページ以下で説明。<sub>90</sub>

## ステップ2で最大化する量

$$G(w_1, w_2) = \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log p(x_i, y | w_2)$$

を $w_2$ について最大化する。ここで

$$\log p(x_i, \mathbf{y} | \mathbf{w}) = - \sum_{k=1}^K \mathbf{y}_k \left\{ \|x_i - \mathbf{b}_k\|^2 / 2\sigma_k^2 - N \log \sigma_k + \log a_k \right\}$$

これの  $p(y | x_i, w_1)$  による平均が必要。

$p(y | x_i, w_1)$  による平均は計算できる。

$$\sum_y y_k p(y | x_i, w)$$

$$= \sum_y y_k p(x_i, y | w) / p(x_i | w)$$

$$= \frac{a_k \frac{1}{(2\pi\sigma_k^2)^{N/2}} \exp\left(-\frac{\|x_i - b_k\|^2}{2\sigma_k^2}\right)}{p(x_i | w_1)}$$

$$= E[y_k | x_i, w_1] \quad \text{とかく}$$

## ステップ2で最大化する関数を書く

$$G(w_1, w_2) = \sum_{i=1}^n \sum_y p(y | x_i, w_1) \log p(x_i, y | w_2)$$

$$= - \sum_{i=1}^n \sum_{k=1}^K E[y_k | x_i, w_1] \{ \|x_i - b_k\|^2 / 2\sigma_k^2 - N \log \sigma_k + \log a_k \}$$

$w_1$  が与えられたもとで

これを  $w_2 = (a_k, b_k, \sigma_k)$  について最大化。解ける。

# 結局、EM法のステップ2は

$\Sigma$ はすべて $i=1, \dots, n$  の和を表す

$$a_k = \frac{\Sigma E[y_k | x_i, w_1]}{\Sigma 1}$$

$$b_k = \frac{\Sigma E[y_k | x_i, w_1] x_i}{\Sigma E[y_k | x_i, w_1]}$$

$$\sigma_k^2 = \frac{\Sigma E[y_k | x_i, w_1] \| x_i - b_k \|^2}{N \Sigma E[y_k | x_i, w_1]}$$

$w_1 \rightarrow w_2$  が  
計算できる

# EM法

(1)  $w_1$  初期化

(2)  $w_2=(a_k, b_k, \sigma_k)$ を次式で計算


$$\left\{ \begin{array}{l} a_k = \frac{\sum E[y_k | x_i, w_1]}{n} \\ b_k = \frac{\sum E[y_k | x_i, w_1] x_i}{\sum E[y_k | x_i, w_1]} \\ \sigma_k^2 = \frac{\sum E[y_k | x_i, w_1] \| x_i - b_k \|^2}{N \sum E[y_k | x_i, w_1]} \end{array} \right.$$

(3)  $w_1 := w_2$  として(2)に戻る。

# 混合正規分布の対数尤度関数の形状

良い局所解を判定することができるだろうか。

- (1) 実は混合正規分布では最尤推定量は発散している。 $(x_i=b_k, \sigma_k \rightarrow 0)$ 。
- (2) 局所最適解はとてたくさんあると思われる。
- (3) 尤度が大きい局所解が汎化の意味で良いのではないので、尤度で局所解の良さの比較はできない。AIC, TIC, BIC は使えない。クロスバリデーション(k-fold)も使えない。  
→ 最尤法やEM法は「ダマシダマシ使う」必要がある。  
安心して使いたい場合はVBに変更する。EMをVBに変更して損失になることは何もない(演算量も)。ただし数式は少し難しくなる。





# 実験例

データ:  $[0,2]^2$  上の一様分布から発生( $n=360$ )。

混合正規分布 ( $K=9$ ) で学習 (EM法)。

初期値

$$a_k = 1/K,$$

$$b_k = \text{全体平均} + \text{乱数}$$

$$\sigma_k = \text{全体標準偏差}$$

から初めて1000回繰り返す

初期値を変えて11回学習した。尤度が大きい解は、 $\sigma_k$  が小さくなっている。

