

## 情報意味論(8) EM

櫻井彰人

慶應義塾大学理工学部

## 目次

- 動機と問題設定
- 簡単な例
- ちょっと複雑な例 – ガウス混合分布
- K-meansからのアプローチ
- EMアルゴリズム: 性質とまとめ

## EM の導入の動機(?)

### ■ 動機(?)

- 観測できないが、結果に関与している変数(属性)があるとき、(この変数を含む)パラメータの最尤推定をしたい。どうしたらよいか?
  - (パラメータ以外)すべて観測可能であれば、式は書ける

### ■ 経験(?)

- k-means クラスタリング

## 少し復習: 最尤推定


- 既知確率分布  $p(x; \theta)$  の独立サンプル  $x_1, \dots, x_N$  があるとき、パラメータ  $\theta$  を推定する方法の一つ
- 尤度  $\Pi_i p(x_i; \theta)$  を最大にする  $\theta$  を推定量とする

## 非観測変数があるときの最尤推定

- 既知確率分布  $p(x, z; \theta)$  の独立サンプル  $\langle x_1, z_1 \rangle, \dots, \langle x_N, z_N \rangle$  があるとき、パラメータ  $\theta$  を推定したい。ただし、 $x$  は計測されてデータがあるが、 $z$  は計測されていない。


- 尤度  $\Pi_i p(x_i, z_i; \theta)$  を最大にする  $\theta$  を推定量とすればよい、と思う。
- しかし、 $z_i$  が変量のまま残っているので、 $\theta$  に関する尤度最大化することができない。

## 例: クラスタリング




- クラスタリングは、「 $n$ 次元データを、クラスタに分けること。クラスタに分けるとは、データには、それが属するグループがあると仮定して
  - グループの発見と
  - 各データが属するグループの発見という二つの作業をすること
- 各データの座標（ $n$ 次元）を観測データ  $x_i$ 、属するグループを未観測データ  $z_i$  として、各グループの分布のパラメータ  $\theta$  を推定することと考えることができる。

## k-means 法



- クラスタリング方法の一つ
- 次の繰り返し
  - $z_i$  が同じ  $(=j)$   $\langle x_i, z_i \rangle$  を集め、各  $z_i (=j)$  ごとその  $x_i$  を用いて  $\theta_j$  を最尤推定する
  - $\theta_j$  ( $j=1, \dots, k$ ) を用いて、 $z_i$  を最尤推定する。
- 結構うまくいく
- これが使えないか？

## (EM) クラスタリング例



<http://jormungand.net/projects/em/>

## (K-means) クラスタリング例



<http://www.cs.washington.edu/research/imagedatabase/demo/kmcluster/>

## 背景

- EMアルゴリズムと名付けられて紹介されたのは、1977年の Dempster, Nan Laird, Donald Rubin による論文 Maximum Likelihood from Incomplete Data via the EM Algorithm においてである。
- 著者によれば "The EM algorithm has been proposed many times in special circumstances."
- EM は非観測量があるとき最尤推定量を求める方法である。
- EMアルゴリズムは、あるモデルのパラメータを、次の繰り返しで計算する。
  - 初期値を何等かの方法で定める。
  - 一回の計算は
    - E step - Expectation step
    - M step - Maximization step

Dempster, A.P. Laird, N.M. Rubin, D.B. (1977). "Maximum Likelihood from Incomplete Data via the EM Algorithm". *Journal of the Royal Statistical Society, Series B (Methodological)* 39 (1): 1-38.

## 応用

- 欠測値を補う
- 潜在変数の値を推定する
  - 隠れマルコフモデルのパラメータ推定
  - 有限混合モデルのパラメータ推定
  - クラスタリング
  - 半教師あり学習.

## 目次

- 動機と問題設定
- 簡単な例
- ちょっと複雑な例 – ガウス混合分布
- K-meansからのアプローチ
- EMアルゴリズム: 性質とまとめ

## 簡単な例

あるクラスでの成績分布を考える。  
 事象A = Aをとる  $P(A)=1/2$   
 事象B = Bをとる  $P(B)=\mu/4$   
 事象C = Cをとる  $P(C)=1/2-\mu/2$   
 事象D = Dをとる  $P(D)=\mu/4$   
 (ただし、 $0 \leq \mu \leq 1$ )

パラメータ  $\mu$  をデータから推定したい。  
 Aは  $a$  人、Bは  $b$  人、Cは  $c$  人、Dは  $d$  人いたとする。

$a, b, c, d$  が与えられた時、 $\mu$  を最尤推定しよう

Dempster et al 1977 の例題を簡単にしたもの

## 簡単な計算

$$\begin{aligned} P(A) &= 1/2 \\ P(B) &= \mu/4 \\ P(C) &= 1/2 - \mu/2 \\ P(D) &= \mu/4 \end{aligned}$$

$$P(A)=1/2 \quad P(B)=\mu/4 \quad P(C)=1/2-\mu/2 \quad P(D)=\mu/4$$

$$P(a,b,c,d|\mu) = C (1/2)^a (\mu/4)^b (1/2-\mu/2)^c ((\mu/4)^d) \quad \text{ただし、} C = \frac{(a+b+c+d)!}{a!b!c!d!}$$

$$\log P(a,b,c,d|\mu) = a \log(1/2) + b \log(\mu/4) + c \log(1/2-\mu/2) + d \log(\mu/4) + \log C$$

これを  $L(\mu)$  としよう

$$\frac{\partial L(\mu)}{\partial \mu} = \frac{b}{\mu} - \frac{c}{1-\mu} + \frac{d}{\mu} = 0$$

$$\text{最尤推定量 } \hat{\mu} \text{ は } \hat{\mu} = \frac{b+d}{b+c+d}$$

## 隠れ変数がある場合

$$\begin{aligned} P(A) &= 1/2 \\ P(B) &= \mu/4 \\ P(C) &= 1/2 - \mu/2 \\ P(D) &= \mu/4 \end{aligned}$$

仮に、Aを取った人とBを取った人は、合計  $u$  人、Cをとった人は  $c$  人、Dをとった人は  $d$  人であるとわかったとしよう。  
 $\mu$  の最尤推定量は何であろうか？

この場合、不完全データ  $(u, c, d)$  を観測していることになる。  
 完全データの対数尤度は前ページと同じであり、最尤推定量は  
 $\mu = (b + d) / (b + c + d)$

しかし、 $b$  は可観測ではないので、上記問題には適用できない  
 EMアルゴリズムは、これに、次のように対処する

手順は、次の通り。

- 初期設定。  
 パラメータ  $\mu$  の値を適宜決める。  
 以下を繰り返す
- パラメータ  $\mu$  の次の値を決める準備をする(ただし、非観測変数  $B$  の期待値を求ることになる)  
 パラメータ  $\mu$  の現在値を用いて、 $B$  の分布を求める。これを用いて、対数尤度の( $B$  の分布に基づく)期待値を求める。  
 なお、この過程で  $B$  の期待値を求ることになる。
- パラメータ  $\mu$  の値を決める。  
 上記「対数尤度の期待値」を最大化する、パラメータ  $\mu$  の値を求める。  
 なお、この時、上記「 $B$  の期待値」を用いることになる。

## ステップ2

$$\begin{aligned} P(A) &= 1/2 \\ P(B) &= \mu/4 \\ P(C) &= 1/2 - \mu/2 \\ P(D) &= \mu/4 \end{aligned}$$

確率変数  $B$  は、サンプルサイズ  $u$  の二項分布をしていると考えることができる。そのパラメータは、 $(\mu_k/4)/(1/2 + \mu_k/4)$   
 つまり、 $B$  の条件付期待値は、 $E\{B|H\} = u(\mu_k/4)/(1/2 + \mu_k/4)$   
 従って、 $b_k = u(\mu_k/4)/(1/2 + \mu_k/4)$   
 また、 $a_k = u - u(\mu_k/4)/(1/2 + \mu_k/4) = u(1/2)/(1/2 + \mu_k/4)$   
 より正確には  
 ステップ2に現れる期待尤度を  $Q(\mu; \mu_k)$  と書くことにする。すなわち  
 $Q(\mu; \mu_k) = E_B\{L(\mu)|\mu_k, u, c, d\}$  ( $L(\mu)$  は対数尤度)  
 さて、  
 $L(\mu) = a \log(1/2) + b \log(\mu/4) + c \log(1/2 - \mu/2) + d \log(\mu/4) + \log C$   
 である。なお、 $a = u - b, b$  の分布が  $\mu_k$  に依存している( $c, d$  は定数)

## ステップ2（続）

従って、 $Q(\mu; \mu_k) = E_B\{L(\mu)|\mu_k, u, c, d\}$  は、 $a, b$  の期待値を  $a_k = E_B\{a|\mu_k, u, c, d\}, b_k = E_B\{b|\mu_k, u, c, d\}$  とすれば

$$a_k \log(1/2) + b_k \log(\mu/4) + c \log(1/2 - \mu/2) + d \log(\mu/4) + E_B\{\log C|\mu_k, u, c, d\}$$

なお、 $b_k = u(\mu_k/4)/(1/2 + \mu_k/4), a_k = u(1/2)/(1/2 + \mu_k/4)$  である。それは、次から得られる

$$\begin{aligned} P(a, b, c, d; \mu) &= \frac{(a+b+c+d)!}{a!b!c!d!} \left(\frac{1}{2}\right)^a \left(\frac{\mu}{4}\right)^b \left(\frac{1}{2} - \frac{\mu}{2}\right)^c \left(\frac{\mu}{4}\right)^d \\ &= \frac{u!}{(u-b)!b!} \left(\frac{1}{2}\right)^{u-b} \left(\frac{\mu}{4}\right)^b \frac{(u+c+d)!}{u!c!d!} \left(\frac{1}{2} - \frac{\mu}{2}\right)^c \left(\frac{\mu}{4}\right)^d \end{aligned}$$

より

$$P(b; \mu_k, u, c, d) = \frac{u!}{(u-b)!b!} \left(\frac{1}{2}\right)^{u-b} \left(\frac{\mu_k}{4}\right)^b \left(\frac{1}{2} + \frac{\mu_k}{4}\right)^u$$

## ステップ3

ステップ3

$Q(\mu; \mu_k)$  を最大化する  $\mu$  は  
 $\mu_{k+1} = (b_k + d) / (b_k + c + d)$

P(A)=1/2  
P(B)=μ/4  
P(C)=1/2-μ/2  
P(D)=μ/4

結果を書き直せば

Expectation step  
仮に  $\mu$  の値を知っているなら、 $a$  と  $b$  の期待値を計算  $a \leftarrow \frac{1/2}{1/2 + \mu/4} u, b \leftarrow \frac{\mu/4}{1/2 + \mu/4} u$  することができる。

Maximization step  
最尤推定量を計算することができる。  
 $\mu \leftarrow \frac{b + d}{b + c + d}$

## 計算してみると

P(A)=1/2  
P(B)=μ/4  
P(C)=1/2-μ/2  
P(D)=μ/4

```

u <- 25
c <- 10
d <- 10
mu <- 0
for ( i in 1:8 ) {
  b <- (mu/4)*u/(1/2+mu/4)
  mu <- (b+d)/(b+c+d)
  print( c(b,mu) )
}

```

## 目次


- 動機と問題設定
- 簡単な例
- ちょっと複雑な例 – ガウス混合分布
- K-meansからのアプローチ
- EMアルゴリズム: 性質とまとめ

## より複雑なモデル

- 確率モデルであって、一個の著名(?)な分布で表せないもの、…で表せそうもないもの、…ではなさそうなものが、世の中にはたくさんある。
  - 例えば、多峰分布

## 例: 混合正規分布

- 正規分布(ガウス混合)の線形和



線形和(重みの和は1)  
 $p(x) = \sum \pi_j p_j(x)$

正規分布の線形和であるなら  
 $p_j(x) = N(x; \mu_j, \sigma_j)$   
として、  
 $p(x) = \sum \pi_j N(x; \mu_j, \sigma_j)$

## 問題: パラメータが推定できない


データが一個の正規分布から生成されているなら、そのパラメータ(平均と分散)の推定は容易である。例えば、平均値の最尤推定量は

$$\mu_{\text{ML}} = \underset{\mu}{\operatorname{argmin}} \sum_{i=1}^m (x_i - \mu)^2 = \frac{1}{m} \sum_{i=1}^m x_i$$

しかし、混合分布の場合、最尤推定をしようと思うと、次の最大化問題を解かなければいけない(簡単にするため標準偏差は既知)。

$$\begin{aligned}\mu_{\text{ML}} &= \underset{(\mu_1, \mu_2, \mu_3)}{\operatorname{argmax}} \prod_{i=1}^m \sum_{j=1}^3 \pi_j N(x_i; \mu_j) \\ &= \underset{(\mu_1, \mu_2, \mu_3)}{\operatorname{argmax}} \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j)\end{aligned}$$

これは解けない



## しかし近似計算なら

できるかもしれない。続けてみよう。


$$\theta_{\text{ML}} = \underset{\mu_j, \pi_j}{\operatorname{argmax}} LL(\mu_1, \dots, \pi_1, \dots)$$

$$LL(\mu_1, \dots, \pi_1, \dots) = \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j)$$

とりあえず、停留点が求まるかどうか、Lagrange関数を微分してみよう

$$\text{Lagrange関数は } L = \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j) + \lambda \left( 1 - \sum_{i=1}^3 \pi_j \right)$$

$$\begin{aligned}\frac{\partial L}{\partial \pi_j} &= \sum_{i=1}^m \frac{N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} - \lambda \\ &= \sum_{i=1}^m \tau_i^j / \sum_{j=1}^3 \pi_j N(x_i; \mu_j) - \lambda \\ \frac{\partial L}{\partial \mu_j} &= \sum_{i=1}^m \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} \frac{\partial}{\partial \mu_j} \left\{ -\frac{1}{2} (x_i - \mu_j)^T \Sigma_j^{-1} (x_i - \mu_j) \right\} \\ &= \sum_{i=1}^m \tau_i^j \Sigma_j^{-1} (x_i - \mu_j) \\ \tau_i^j &= p(z_i = j | x_i, \theta) \\ &= \frac{p(x_i, z_i = j | \theta)}{p(x_i | \theta)} \\ &= \frac{p(x_i | z_i = j, \theta) p(z_i = j | \theta)}{p(x_i | \theta)} \\ &= \frac{\pi_j N(x_i; \mu_j)}{\sum_j \pi_j N(x_i; \mu_j)}\end{aligned}$$



## 方程式

$$L = \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j) + \lambda \left( 1 - \sum_{i=1}^3 \pi_j \right) \quad \tau_i^j = \frac{\pi_j N(x_i; \mu_j)}{\sum_j \pi_j N(x_i; \mu_j)}$$

$$\begin{aligned}\frac{\partial L}{\partial \pi_j} &= \sum_{i=1}^m \tau_i^j / \pi_j - \lambda = 0, \sum_{i=1}^m \pi_j = 1, \sum_{j=1}^3 \sum_{i=1}^m \tau_i^j = m \quad \text{より} \quad \pi_j = \frac{1}{m} \sum_{i=1}^m \tau_i^j \\ \frac{\partial L}{\partial \mu_j} &= \sum_{i=1}^m \tau_i^j / \Sigma_j^{-1} (x_i - \mu_j) = 0 \quad \text{より} \quad \mu_j = \frac{\sum_{i=1}^m \tau_i^j x_i}{\sum_{i=1}^m \tau_i^j}\end{aligned}$$

非線形連立方程式だが、これは解けない。

ヒューリスティックスにより、下記のようにすればよさそうだが、果して収束するのだろうか

$$\tau_i^j \leftarrow \frac{\pi_j N(x_i; \mu_j)}{\sum_j \pi_j N(x_i; \mu_j)} \quad \pi_j \leftarrow \frac{1}{m} \sum_{i=1}^m \tau_i^j \quad \mu_j \leftarrow \frac{\sum_{i=1}^m \tau_i^j x_i}{\sum_{i=1}^m \tau_i^j}$$

## 参考: EMとの対応

$$\theta_{\text{ML}} = \underset{\mu_j, \pi_j}{\operatorname{argmax}} LL(\mu_1, \dots, \pi_1, \dots)$$

勿論、対応するのですが、それは後講釈

$$LL(\mu_1, \dots, \pi_1, \dots) = \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j)$$

$$\text{Lagrange関数は } L = \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j) + \lambda \left( 1 - \sum_{i=1}^3 \pi_j \right)$$

$$\begin{aligned}\mu_j &\leftarrow \frac{\sum_{i=1}^m \tau_i^j x_i}{\sum_{i=1}^m \tau_i^j} & \tau_i^j &\leftarrow \frac{\pi_j N(x_i; \mu_j)}{\sum_j \pi_j N(x_i; \mu_j)} \\ \pi_j &\leftarrow \frac{1}{m} \sum_{i=1}^m \tau_i^j & \text{M step} &\quad \text{E step}\end{aligned}$$

## EM 一般的な定義

- $X = \{x_1, \dots, x_N\}$  観測データ
- $Z = \{z_1, \dots, z_N\}$  非観測データ(隠れ変数)
- $Y = X \cup Z$



- $h$ : 分布のパラメータ( $\theta$  とも)

注: 混合分布のときの考え方

$$P(x; \mu) = \prod_{i=1}^m \sum_{j=1}^3 \pi_j N(x_i; \mu_j)$$

$$P(x, z; \mu) = \prod_{i=1}^m \prod_{j=1}^3 (\pi_j N(x_i; \mu_j))^{\delta_{i,j}} = \prod_{i=1}^m \pi_{z_i} N(x_i; \mu_{z_i})$$

$$\begin{aligned}z_{i,j} &= 1 \text{ or } 0. z_{i,j} = 1 \text{ iff } x_i \text{ はクラスタ } j \text{ に属する} \\ z_i &= j \text{ iff } x_i \text{ はクラスタ } j \text{ に属する}\end{aligned}$$



## EM 一般的な定義(続)

$X = \{x_1, \dots, x_N\}$  観測データ  
 $Z = \{z_1, \dots, z_N\}$  非観測データ  
 $Y = X \cup Z$

- E-Step: 次の仮説  $h'$  の対数尤度の期待値を求める(式で表す)。ただし、現在の仮説  $h$  と観測データ  $X$  は既知とする(目標:  $\ln P(X | h)$  の最大化であった)

$$\begin{aligned}Q(h' | h) &= E[\ln P(Y | h') | h, X] \\ &= \int (\ln P(X, z | h')) P(z | h, X) dz\end{aligned}$$

- M-Step:  $Q$  を最大化する  $h'$  を次の  $h$  とする  
 $h \leftarrow \operatorname{argmax}_h Q(h' | h)$

$h$  を決めるときに決めているのはクラスタのパラメータ  
 $Q$  を決めるときに決めているのはクラスタのメンバーランク

## EM E-step

$$\begin{aligned}
Q(h'|h) &= E[\ln P(Y|h')|h, X] \\
&= E[\ln \prod_{i=1}^N P(y_i|h')|h, X] \\
&= E\left[\sum_{i=1}^N \ln P(y_i|h')|h, X\right] \\
&= E\left[\sum_{i=1}^N \left(\ln \prod_{j=1}^k (\pi'_j N(x_i|\mu'_j, \Sigma'_j))^{\tau_i^j}\right)|h, X\right] \\
&= E\left[\sum_{i=1}^N \left(\sum_{j=1}^k \tau_i^j \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j)\right)|h, X\right] \\
&= \sum_{i=1}^N \left(\sum_{j=1}^k E[\tau_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j)\right)
\end{aligned}$$

## EM M-Step

$$\begin{aligned}
h &\leftarrow \arg \max_{h'} Q(h'|h) \\
&= \operatorname{argmax}_{h'} \sum_{i=1}^N \left( \sum_{j=1}^k E[z_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j) \right)
\end{aligned}$$

$h$  は  $\pi, \mu, \Sigma$  の組、 $h'$  は  $\pi', \mu', \Sigma'$  の組である。  
最小化は  $\pi', \mu', \Sigma'$  による偏微分が 0 とおいて達成できる。

## $\pi'_j$ の推定

- 変数  $\pi'_j$  に関する  $Q(h'|h)$  の偏微分（言い忘れたが、Lagrange 関数を用いている）
 
$$\begin{aligned}
 \frac{\partial}{\partial \pi'_j} \{Q(h'|h) + \lambda(1 - \sum_j \pi'_j)\} \\
 &= \frac{\partial}{\partial \pi'_j} \left\{ \sum_{i=1}^N \left( \sum_{j=1}^k E[z_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j) \right) \right\} - \lambda \\
 &= \sum_{i=1}^N \frac{E[z_i^j|h, X]}{\pi'_j} - \lambda \quad E[z_i^j|x_i, h] = p(z_i^j = 1|x_i, h) \\
 &= \frac{\pi_j N(x_i|\mu_j, \Sigma_j)}{\sum_i \pi_j N(x_i|\mu_j, \Sigma_j)}
 \end{aligned}$$
- これらを 0 とおく方程式をとけば
 
$$\pi'_j = \frac{\sum_i E[z_i^j|h, X]}{N} = \frac{\sum_i \tau_i^j}{N} \quad \tau_i^j = \frac{\pi_j N(x_i|\mu_j, \Sigma_j)}{\sum_i \pi_j N(x_i|\mu_j, \Sigma_j)}$$

## $\mu'_j$ の推定

- 変数  $\mu'_j$  に関する  $Q(h'|h)$  の偏微分
 
$$\begin{aligned}
 \frac{\partial Q(h'|h)}{\partial \mu'_j} &= \frac{\partial}{\partial \mu'_j} \left\{ \sum_{i=1}^N \left( \sum_{j=1}^k E[z_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j) \right) \right\} \\
 &= \sum_{i=1}^N E[z_i^j|h, X] \frac{\partial}{\partial \mu'_j} \ln N(x_i|\mu'_j, \Sigma'_j) \\
 &= \sum_i \tau_i^j / \Sigma_j^{-1} (x_i - \mu'_j)
 \end{aligned}$$
- これを 0 とおけば、次式が得られる
 
$$\mu'_j = \frac{\sum_i \tau_i^j x_i}{\sum_i \tau_i^j}$$

## $\Sigma'_j$ の推定

- 変数  $\Sigma'_j$  に関する  $l$  の偏微分
 
$$\begin{aligned}
 \frac{\partial Q(h'|h)}{\partial \Sigma'_j} &= \frac{\partial}{\partial \Sigma'_j} \left\{ \sum_{i=1}^N \left( \sum_{j=1}^k E[z_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j) \right) \right\} \\
 &= \sum_{i=1}^N E[z_i^j|h, X] \frac{\partial}{\partial \Sigma'_j} \ln N(x_i|\mu'_j, \Sigma'_j) \\
 &= \sum_{i=1}^N \tau_i^j \left\{ -\frac{1}{2} \Sigma_j'^{-1} + \frac{1}{2} \Sigma_j'^{-1} (x_i - \mu'_j)(x_i - \mu'_j)^T \Sigma_j'^{-1} \right\}
 \end{aligned}$$
- これを 0 とおくと次式が得られる
 
$$\Sigma'_j = \frac{\sum_i \tau_i^j (x_i - \mu'_j)(x_i - \mu'_j)^T}{\sum_i \tau_i^j}$$

## EM 混合正規分布

### E-Step:

$$\begin{aligned}
Q(h'|h) &\leftarrow \sum_{i=1}^N \left( \sum_{j=1}^k E[z_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j) \right) \\
\text{すなわち} \\
E[z_i^j|x_i, h] &= p(z_i^j = 1|x_i, h) = \frac{\pi_j N(x_i|\mu_j, \Sigma_j)}{\sum_j \pi_j N(x_i|\mu_j, \Sigma_j)} \rightarrow \tau_i^j
\end{aligned}$$

### M-Step:


$$\begin{aligned}
h &\leftarrow \operatorname{argmax}_{h'} \sum_{i=1}^N \left( \sum_{j=1}^k E[z_i^j|h, X] \ln \pi'_j N(x_i|\mu'_j, \Sigma'_j) \right) \\
\text{すなわち} \\
\pi'_j &\leftarrow \frac{\sum_i \tau_i^j}{N} \quad \mu_j \leftarrow \frac{\sum_{i=1}^N \tau_i^j x_i}{\sum_{i=1}^N \tau_i^j} \quad \Sigma'_j \leftarrow \frac{\sum_i \tau_i^j (x_i - \mu'_j)(x_i - \mu'_j)^T}{\sum_i \tau_i^j}
\end{aligned}$$

## 目次

- 動機と問題設定
- 簡単な例
- ちょっと複雑な例 – ガウス混合分布
- K-meansからのアプローチ
- EMアルゴリズム: 性質とまとめ

## 分布推定は「教師なし学習」

- 教師付き学習: データ  $\langle x, z \rangle$
- 教師なし学習: データ  $x$



## 補足: 教師なし学習が必要となるところ


- 分布関数(確率密度関数)の推定
- クラスタリング
- 外れ値/新規点の検出
- データ圧縮
- 可視化

## 分布推定とクラスタリング


- クラスタリング: 混合分布から生成されたデータに対し、どの分布から生成されたかを推定する
- 混合分布  
 $p(x) = \sum \pi_j p_j(x)$


混合分布  
 $p(x,z) = \prod (\pi_j p_j(x))^{\gamma_j}$
- 各クラスターは混合分布の個々の分布に 対応すると考える
- 隠れ変数: データ点がどのガウス分布から生成されたか
  - すなわち、観測データ  $\langle x \rangle$ , 全データ  $\langle x, z \rangle$ .
  - 課題:  $\langle x \rangle$  から  $\langle x, z \rangle$  を推定する

## クラスタリング/密度推定付き




## ある方法: k-means クラスタリング






- ## K-means の行っていること
- 前提(「動作だけ」を記述するには不要)
    - (各正規分布)分散共分散は同じとする
    - 分散共分散行列は、対角かつ各軸で等分散とする
  - 初期値
    - クラスタ中心  $\mathbf{o}_j$  をランダムに定め、推定を開始する
  - 繰り返し
    - 分類: 各観測点ごと、その(産みの親である)クラスタを推定する各クラスターのメンバーを推定するといつてもよい
      - 各  $\langle x \rangle \rightarrow \langle x, j \rangle$ , ただし  $j = \arg \min |x - o_j|$ .
      - i.e. 最近傍のクラスタ中心を選び、そのクラスタ番号を  $j$  とする
    - 中心の再設定: クラスタごと、同一クラスタの点のみを用いて、その重心(平均値)を新たにクラスタ中心とする
      - 各  $j$  につき、 $\mathbf{o}_j = \text{center of } \{x | \langle x, j \rangle\}$

- ## K-means原理
- ポテンシャル関数の最小化
 
$$\min_{\mu} \min_C F(\mu, C) = \min_{\mu} \min_C \sum_{i=1}^k \sum_{j: c(j)=i} \|\mu_i - x_j\|^2$$
  - 次の2つのステップからなる
    - 分類:  $C$  に関する  $F(\mu, C)$  の最小化
      - $C$  のメンバーを決める
    - 中心の再設定:  $\mu$  に関する  $F(\mu, C)$  の最小化
      - $F(\mu, C)$  を最小化する  $\mu$  を求める



- ## K-means の欠点
- Spherical な場合しか扱えない
    - 分散共分散行列が、 $\sigma I$  ( $I$ は単位行列)
  - 各クラスタの重みが等しいときしか扱えない
  - 混合正規分布から生成されたデータに適用すると、推定値(例えば、平均値)にbiasが発生する。



## K-means の欠点の解消に向けて

- 前二者への対応
  - 混合(多項)正規分布でモデル化する
  - 分類実行時に、生起確率が最大となるクラスタを選ぶ
    - K-means: 中心(=分布の中心=平均値)からの距離が最小のクラスタを選ぶ
- 後二者への対応
  - bias の原因是、「生起確率最大のクラスタを選ぶ」故、属しうるクラスタの確率に従い、複数のクラスタに属するとする


$$\begin{aligned}
 \min_{\mu} \min_{C} F(\mu, C) &= \min_{\mu} \min_{C} \sum_{j=1}^k \sum_{i: C(i)=j} \|\mu_j - x_i\|^2 \\
 &= \min_{\mu} \min_{C} \sum_{j=1}^k \sum_{i: C(i)=j} -\log \exp\left(-\frac{\|x_i - \mu_j\|^2}{2}\right) \\
 &= \max_{\mu} \max_{C} \sum_{j=1}^k \sum_{i: C(i)=j} \log N(x_i; \mu_j, 1) \\
 &\Rightarrow \max_{\mu} \max_{z} \sum_{j=1}^k \sum_{i: z_i=j} \log \pi_j N(x_i; \mu_j, \Sigma_j) \Rightarrow \max_{\mu} \max_{z} \sum_{j=1}^k \sum_{i: z_i=j} \log \pi_j P(x_i; \theta_j)
 \end{aligned}$$

課題:  $z_i$  をどう推定するか。次はうまくない  $\Rightarrow$  そこで、  
 $z_i = j$  iff  $j = \arg \max \pi_j P(x_i; \theta_j)$  EMへ

## EM と k-means との対応

- |  |   |
|--|---|
| <ul style="list-style-type: none"> <li>■ E-Step: 非観測データは期待値を推定<br/> <math display="block">Q(h'   h) = E[\ln P(Y   h')   h, X] = \int (\ln P(X, z   h')) P(z   h, X) dz</math> </li> <li>■ M-Step: <math>Q</math> を最大化する <math>h'</math> を次の <math>h</math> とする。最尤推定<br/> <math>h \leftarrow \operatorname{argmax}_{h'} Q(h'   h)</math></li> </ul> | <ul style="list-style-type: none"> <li>■ 分類: <math>C</math> に関する <math>F(\mu, C)</math> の最小化           <ul style="list-style-type: none"> <li>▪ <math>C</math> のメンバーを決める</li> </ul> </li> <li>■ 中心の再設定: <math>\mu</math> に関する <math>F(\mu, C)</math> の最小化           <ul style="list-style-type: none"> <li>▪ <math>F(\mu, C)</math> を最小化する <math>\mu</math> を求める</li> </ul> <p>(coordinate descent)</p> </li> </ul> |
|--|---|

## K-means をソフトにしたイメージ



## 目次


- 動機と問題設定
- 簡単な例
- ちょっと複雑な例 – ガウス混合分布
- K-meansからのアプローチ
- EMアルゴリズム: 性質とまとめ

## EMアルゴリズムの性質

$$L(X; \theta) = \log(X = \{X_i\}_{i=1}^n \text{ の結合確率}; \theta)$$

定理

$\theta_k$  をEMアルゴリズムでされる  $k$  番目のパラメータ  $\theta$  とする。この時、 $L(X; \theta_{k+1}) \geq L(X; \theta_k)$  が成立する。また、適当な条件のもと、 $\theta_k$  は、最尤推定量  $\arg \max L(X; \theta)$  に収束する。



## EMまとめ1

- $X = \{x_1, \dots, x_N\}$  観測データ
- $Z = \{z_1, \dots, z_N\}$  非観測データ (隠れ変数)
  - $Y = X \cup Z$
- $h$ : 分布のパラメータ ( $\theta$  とも)
- 次を繰り返す
  - E-Step: 非観測データは期待値を推定
$$Q(h' | h) = E[\ln P(Y | h') | h, X] \\ = \int (\ln P(X, z | h')) P(z | h, X) dz$$
  - M-Step:  $Q$  を最大化する  $h'$  を次の  $h$  とする。最尤推定
$$h \leftarrow \operatorname{argmax}_{h'} Q(h' | h)$$

## EMまとめ2

- 混合分布の推定に用いる
  - 生成された元の分布を表す非観測変数を導入
  - EMを適用
    - 結果はソフトクラスタリングみたい
- クラスタリングに適用
  - 混合分布の推定として定式化
  - 結果中に、各サンプルのクラスタへの所属確率
  - サンプルを生成する事後確率が最大のクラスタを、それが属するクラスタとする

