

EM アルゴリズム

櫻井彰人

目次


- 多峰分布の最尤推定
- EMアルゴリズム

動機: 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

動機: 多峰分布

- 正規分布(ガウス分布)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、
 $p(x) = \sum \pi_j N(x; \mu_j, \sigma_j)$

課題: パラメータ推定


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

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

しかし、多峰分布の場合、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)。


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

解けるか?



できるかもしれない、続けてみよう。

$$\begin{aligned} \theta_{ML} &= \operatorname{argmax}_{\mu_j, \pi_j} LL(\mu_1, \dots, \pi_1, \dots) \\ LL(\mu_1, \dots, \pi_1, \dots) &= \sum_{i=1}^m \log \sum_{j=1}^3 \pi_j N(x_i; \mu_j) \end{aligned}$$



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

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


$$\frac{\partial L}{\partial \pi_j} = \sum_{i=1}^m \frac{N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} - \lambda$$

$$\begin{aligned} \frac{\partial L}{\partial \mu_j} &= \sum_{i=1}^m \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} \frac{\partial}{\partial \mu_j} \left\{ -\frac{1}{2} (x_i - \mu_j)^T \Sigma_j^{-1} (x_i - \mu_j) \right\} \\ &= \sum_{i=1}^m \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} \Sigma_j^{-1} (x_i - \mu_j) \end{aligned}$$

方程式は

$$0 = \sum_{i=1}^m \frac{N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} - \lambda$$

$$0 = \sum_{i=1}^m \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} - \sum_{j=1}^3 \pi_j^{-1} (x_i - \mu_j)$$

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


となる。とても解けるとは思えない

ここで、通常は、EMアルゴリズムに行く(e.g. Elements of Statistical Learning, 2nd ed. p.274)

ちよっと工夫をしてみよう。次のスライドで。

$$\tau_i^j = \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)}$$

と置く

$$\frac{\partial L}{\partial \pi_j} = \sum_{i=1}^m \frac{N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} - \lambda = \sum_{i=1}^m \tau_i^j / \pi_j - \lambda$$

$$\frac{\partial L}{\partial \mu_j} = \sum_{i=1}^m \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)} \sum_{j=1}^3 \pi_j^{-1} (x_i - \mu_j) = \sum_{i=1}^m \tau_i^j \sum_{j=1}^3 \pi_j^{-1} (x_i - \mu_j)$$

停留点を求めよう

$$\frac{\partial L}{\partial \pi_j} = \sum_{i=1}^m \tau_i^j / \pi_j - \lambda = 0, \sum_{i=1}^m \pi_j = 1, \sum_{j=1}^3 \sum_{i=1}^m \tau_i^j = m$$

より


$$\pi_j = \frac{1}{m} \sum_{i=1}^m \tau_i^j$$

$$\frac{\partial L}{\partial \mu_j} = \sum_{i=1}^m \tau_i^j \sum_{j=1}^3 \pi_j^{-1} (x_i - \mu_j) = 0$$

より

$$\mu_j = \frac{\sum_{i=1}^m \tau_i^j x_i}{\sum_{i=1}^m \tau_i^j}$$

解けているように見えるが、解けていない！
(ほぼ解いているともいえる。以下のスライドで)



補足

$$\tau_i^j \leftarrow \frac{\pi_j N(x_i; \mu_j)}{\sum_{j=1}^3 \pi_j N(x_i; \mu_j)}, \quad \pi_j \leftarrow \frac{1}{m} \sum_{i=1}^m \tau_i^j, \quad \mu_j \leftarrow \frac{\sum_{i=1}^m \tau_i^j x_i}{\sum_{i=1}^m \tau_i^j}$$

代入は、一斉に行うとする。
簡単にわかるが、どの変数値もある有界範囲内に入る。
 $\pi_j \geq 0$ は和が1、 μ_j は任意の値に対して、次の τ, π_j, μ_j が計算できる。
従って、上記式が定義する π_j, μ_j の変換(前頁)は、ユークリッド空間内のコンパクト凸部分集合からその上/中への連続写像となる。ブラウアーの不動点定理から、不動点が存在する。
また、ある初期点から初めて、上式により点列を生成すれば、当該コンパクト凸集合内に、それは集積点をもつ。もし一点に収束する列があるなら、当該集積点は、(方程式と考えた時の)解となる。
どうも、気持ちが悪い。もっとすっきりできないか。
縮小写像であればよいのだが、不明。

目次

- 多峰分布の最尤推定
- EMアルゴリズム

多峰分布に対し

- 混合(正規)分布と考える
 - 要素分布をサンプル毎に選択


隠れ変数(latent variable)を導入する

$$P(X; \mu, \pi) = \sum_{j=1}^3 \pi_j N(X; \mu_j)$$

$$P(X, Z; \mu, \pi) = P(X | Z; \mu, \pi) P(Z; \mu, \pi)$$

$$= N(X; \mu_Z) P(Z; \pi)$$

$$P(X; \mu, \pi) = \sum_{j=1}^3 N(X; \mu_j) P(Z = j; \pi)$$

$$\sum_Z P(X, Z; \mu, \pi) = \sum_Z N(X; \mu_Z) P(Z; \pi) = \sum_{j=1}^3 N(X; \mu_j) P(Z = j; \pi) = \sum_{j=1}^3 N(X; \mu_j) \pi_j$$


何をしたいか

- パラメータ推定
- 尤度を最大とするパラメータ値を求める

$$P(X; \mu, \pi) = \sum_{j=1}^3 N(X; \mu_j) P(Z = j; \pi)$$

$$P(x_1, \dots, x_m; \mu, \pi) = \prod_{i=1}^m \sum_{j=1}^3 N(x_i; \mu_j) P(Z_i = j; \pi)$$

$$= \prod_{i=1}^m \sum_{j=1}^3 P(x_i, Z_i = j; \mu, \pi)$$

式を短くするために
こちらで変形します

$$LL(\mu, \pi; x_1, \dots, x_m) = \log \prod_{i=1}^m \sum_{j=1}^3 P(x_i, Z_i = j; \mu, \pi)$$

$$= \sum_{i=1}^m \log \sum_{j=1}^3 P(x_i, Z_i = j; \mu, \pi)$$

$$\begin{aligned}
& LL(\mu, \pi; x_1, \dots, x_m) \\
&= \sum_{i=1}^m \log \sum_{j=1}^3 P(x_i, Z_i = j; \mu, \pi) \\
&= \sum_{i=1}^m \log \sum_{j=1}^3 P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)}) \frac{P(x_i, Z_i = j; \mu, \pi)}{P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)})} \\
&\quad \text{Note: } \sum_j P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)}) = 1 \\
&\geq \sum_{i=1}^m \sum_{j=1}^3 P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)}) \log \frac{P(x_i, Z_i = j; \mu, \pi)}{P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)})} \\
&\quad \text{Note: the equality holds when } \mu = \mu^{(t)}, \pi = \pi^{(t)} \\
&= \sum_{i=1}^m E_{Z_i | x_i; \mu^{(t)}, \pi^{(t)}} [P(x_i, Z_i = j; \mu, \pi)] + \sum_{i=1}^m H(P(Z_i | x_i; \mu^{(t)}, \pi^{(t)})) \\
&= Q(\mu, \pi | \mu^{(t)}, \pi^{(t)}) + \sum_{i=1}^m H(P(Z_i | x_i; \mu^{(t)}, \pi^{(t)})) \quad \rightarrow \text{E step} \\
&\text{そこで、} \quad \mu^{(t+1)}, \pi^{(t+1)} = \arg \max_{\mu, \pi} Q(\mu, \pi | \mu^{(t)}, \pi^{(t)}) \quad \rightarrow \text{M step}
\end{aligned}$$

$$\begin{aligned}
& \mu^{(t+1)}, \pi^{(t+1)} = \arg \max_{\mu, \pi} Q(\mu, \pi | \mu^{(t)}, \pi^{(t)}) \\
&\text{と置いたので、} \\
& LL(\mu^{(t+1)}, \pi^{(t+1)}; x_1, \dots, x_m) \geq Q(\mu^{(t+1)}, \pi^{(t+1)} | \mu^{(t)}, \pi^{(t)}) + \sum_i H(P(Z_i | x_i; \mu^{(t)}, \pi^{(t)})) \\
&\quad \geq Q(\mu^{(t)}, \pi^{(t)} | \mu^{(t)}, \pi^{(t)}) + \sum_i H(P(Z_i | x_i; \mu^{(t)}, \pi^{(t)})) \\
&\quad = LL(\mu^{(t)}, \pi^{(t)}; x_1, \dots, x_m) \\
& \mu^{(t+1)}, \pi^{(t+1)} = \arg \max_{\mu, \pi} Q(\mu, \pi | \mu^{(t)}, \pi^{(t)}) \\
&= \arg \max_{\mu, \pi} \sum_{i=1}^m \sum_{j=1}^3 P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)}) \log P(x_i, Z_i = j; \mu, \pi)
\end{aligned}$$

混合正規分布 (続)

$$\begin{aligned}
& \mu^{(t+1)}, \pi^{(t+1)} = \arg \max_{(\mu, \pi)} \sum_{i=1}^m \sum_{j=1}^3 P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)}) \log \pi_j N(x_i; \mu_j) \\
&\text{ところで} \\
& P(Z_i = j | x_i; \mu^{(t)}, \pi^{(t)}) = \frac{\pi_j N(x_i | \mu_j^{(t)})}{\sum_j \pi_j N(x_i | \mu_j^{(t)})} \\
&\text{ゆえ、} \quad \tau_{i,j}^{(t)} = \frac{\pi_j N(x_i | \mu_j^{(t)})}{\sum_j \pi_j N(x_i | \mu_j^{(t)})} \\
&\text{とおくと、} \\
& \mu^{(t+1)}, \pi^{(t+1)} = \arg \max_{(\mu, \pi)} \sum_{i=1}^m \sum_{j=1}^3 \tau_{i,j}^{(t)} \log \pi_j N(x_i; \mu_j)
\end{aligned}$$

混合正規分布 (続々)

$$\begin{aligned}
& \mu^{(t+1)}, \pi^{(t+1)} = \arg \max_{(\mu, \pi)} \sum_{i=1}^m \sum_{j=1}^3 \tau_{i,j}^{(t)} \log \pi_j N(x_i; \mu_j) \\
&\text{が問題であつた。これを解こう} \\
&\text{Lagrange関数は } L = \sum_{i=1}^m \sum_{j=1}^3 \tau_{i,j}^{(t)} \log \pi_j N(x_i; \mu_j) + \lambda(1 - \sum_{j=1}^3 \pi_j) \\
& \frac{\partial L}{\partial \pi_j} = \sum_{i=1}^m \tau_{i,j}^{(t)} / \pi_j - \lambda \quad \quad \frac{\partial L}{\partial \mu_j} = \sum_{i=1}^m \tau_{i,j}^{(t)} \Sigma_j^{-1} (x_i - \mu_j) \\
& \sum_{i=1}^m \tau_{i,j}^{(t)} / \pi_j - \lambda = 0 \quad \sum_{j=1}^3 \pi_j = 1, \sum_{j=1}^3 \sum_{i=1}^m \tau_{i,j}^{(t)} = m \quad \text{よ} \pi_j = \frac{1}{m} \sum_{i=1}^m \tau_{i,j}^{(t)} \\
& \sum_{i=1}^m \tau_{i,j}^{(t)} \Sigma_j^{-1} (x_i - \mu_j) = 0 \quad \text{よ} \mu_j = \frac{\sum_{i=1}^m \tau_{i,j}^{(t)} x_i}{\sum_{i=1}^m \tau_{i,j}^{(t)}}
\end{aligned}$$

混合正規分布 (続々々)

$$\begin{aligned}
& \tau_{i,j}^{(t)} = \frac{\pi_j N(x_i | \mu_j^{(t)})}{\sum_j \pi_j N(x_i | \mu_j^{(t)})} \\
& \pi_j^{(t+1)} = \frac{1}{m} \sum_{i=1}^m \tau_{i,j}^{(t)} \\
& \mu_j^{(t+1)} = \frac{\sum_{i=1}^m \tau_{i,j}^{(t)} x_i}{\sum_{i=1}^m \tau_{i,j}^{(t)}} \\
& \text{できた!}
\end{aligned}$$

あれ?

$$\begin{aligned}
& \tau_{i,j}^{(t+1)} = \frac{\pi_j N(x_i | \mu_j^{(t)})}{\sum_j \pi_j N(x_i | \mu_j^{(t)})} \quad \tau_j^i = \frac{\pi_j N(x_i; \mu_j)}{\sum_j \pi_j N(x_i; \mu_j)} \\
& \pi_j^{(t+1)} = \frac{1}{m} \sum_{i=1}^m \tau_{i,j}^{(t)} \quad \text{VS.} \quad \pi_j = \frac{1}{m} \sum_{i=1}^m \tau_j^i \\
& \mu_j^{(t+1)} = \frac{\sum_{i=1}^m \tau_{i,j}^{(t)} x_i}{\sum_{i=1}^m \tau_{i,j}^{(t)}} \quad \mu_j = \frac{\sum_{i=1}^m \tau_j^i x_i}{\sum_{i=1}^m \tau_j^i}
\end{aligned}$$

EMアルゴリズム

目標

$$LL(\theta; \mathbf{x}) = \sum_i \log p(x_i; \theta) = \sum_i \left(\log \sum_{z_i} p(x_i, z_i; \theta) \right)$$

Eステップ

$$Q(\theta | \theta^{(t)}) = E_{Z_i, \theta^{(t)}} \sum \log p(x_i, Z_i; \theta)$$

とおき、
対数尤度

Mステップ


$$\theta^{(t+1)} = \arg \max_{\theta} Q(\theta | \theta^{(t)})$$

とすると、

$$LL(\theta^{(t+1)}; \mathbf{x}) = \sum_i \log p(x_i; \theta^{(t+1)}) \rightarrow \text{極大値}$$

となる

$$\begin{aligned} \theta^{(t+1)} &= \arg \max_{\theta} Q(\theta | \theta^{(t)}) \\ &= \arg \max_{\theta} \sum_{i=1}^n \sum_j P(Z_i = j | x_i; \theta^{(t)}) \log P(x_i, Z_i = j; \theta) \end{aligned}$$



別の簡単な例

まず、隠れ変数がない場合

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)=μ/4

事象C = Cをとる P(C)=1/2-μ/2

事象D = Dをとる P(D)=μ/4

(ただし、0 ≤ μ ≤ 1)

パラメータ μ 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、μ を最尤推定しよう

Dempster et al 1977 の例題を簡単にしたもの

全て可観測なら

事象	確率	観測数
A	1/2	a
B	μ/4	b
C	1/2-μ/2	c
D	μ/4	d

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

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

$$\log P(a, b, c, d | \mu) =$$

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

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

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。

μ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、次のように対処する

ただし、bを隠れ変数とする

事象	確率	観測数
A	1/2	u
B	μ/4	
C	1/2-μ/2	c
D	μ/4	d

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

$$\log P(u, c, d, b; \mu)$$

$$= \log \frac{u!}{(u-b)!b!} + (u-b) \log \frac{1}{2} + b \log \frac{\mu}{4} + \log \frac{(u+c+d)!}{u!c!d!} + \log \left(\frac{1-\mu}{2}\right)^c + d \log \frac{\mu}{4}$$

bの分布を、現在のパラメータ μ^(t) を使って(可観測変数値も使って)表現する

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

$$P(b; \mu^{(t)}, u, c, d) \text{ は } \tau_{ij}^{(t)} = p(z_i(\mu^{(t)}) = j) \text{ に相当}$$

$$b^{(t)} = E_{b|u, c, d, \mu^{(t)}}[b] = u \frac{\mu^{(t)}/4}{1/2 + \mu^{(t)}/4} \text{ となり}$$

$$z_i^{(t)} = E_{z_i|\theta^{(t)}}[z_i] \text{ は定義しなかった。ほぼ意味がないためである}$$

更新式

事象	確率	観測数
A	1/2	u
B	μ/4	
C	1/2-μ/2	c
D	μ/4	d

$$Q(\mu | \mu^{(t)})$$

$$= E_{b|u, c, d, \mu^{(t)}} \log P(u, c, d, b; \mu^{(t)})$$

$$= E_{b|u, c, d, \mu^{(t)}} \left[\log \frac{u!}{(u-b)!b!} + (u-b) \log \frac{1}{2} + b \log \frac{\mu}{4} + \log \frac{(u+c+d)!}{u!c!d!} + c \log \left(\frac{1-\mu}{2}\right) + d \log \frac{\mu}{4} \right]$$

$$\frac{\partial}{\partial \mu} Q(\mu | \mu^{(t)}) = E_{b|u, c, d, \mu^{(t)}} \left[b \frac{1}{\mu} - c \frac{1}{1-\mu} + d \frac{1}{\mu} \right] \quad Q \text{ は、その微分さえ求めればよい}$$

$$= b^{(t)} \frac{1}{\mu} - c \frac{1}{1-\mu} + d \frac{1}{\mu}$$

$$b^{(t)} = E_{b|u, c, d, \mu^{(t)}}[b] = u \frac{\mu^{(t)}/4}{1/2 + \mu^{(t)}/4} \text{ と置いて}$$

停留点を求める

$$(b^{(t)} + d)(1-\mu) = c\mu$$

$$b^{(t)} + d = (c + b^{(t)} + d)\mu$$

$$\mu = \frac{b^{(t)} + d}{b^{(t)} + c + d} \quad \text{すなわち、} \mu^{(t+1)} = \frac{b^{(t)} + d}{b^{(t)} + c + d}$$

$$\begin{aligned} b^{(t)} &= u \frac{\mu^{(t)}/4}{1/2 + \mu^{(t)}/4} \\ \mu^{(t+1)} &= \frac{b^{(t)} + d}{b^{(t)} + c + d} \end{aligned}$$

別解

事象	確率	観測数
A	$1/2$	u
B	$\mu/4$	
C	$1/2 - \mu/2$	c
D	$\mu/4$	d

例によって、別解を考えてみよう。対数尤度を考える。

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

これを b, μ について最大化する。まず連続変数である μ について考える

$$\frac{\partial}{\partial \mu} \log P(u, c, d; b; \mu) = b \frac{1}{\mu} - c \frac{1}{1-\mu} + d \frac{1}{\mu}$$

停留点を求める

$$\mu = \frac{b+d}{b+c+d}$$

次に、 b について考える。 μ が与えられていれば、二項分布の性質から、最大値を与える b は


$$b = u \frac{\mu/4}{1/2 + \mu/4}$$

となる。これは2次方程式ゆえ、 b を連続値とすれば、解ける。それは、上記を反復式としても得られそうなことは、以前と同様に推定できる。

クラスタリングとの関係

クラスタリング:

観測値ベクトル x_i で記述されるサンプル i は、いずれも、いずれかのグループ(クラスタ) $j \in \{1, 2, \dots, J\}$ に属するとする。サンプル i が属するクラスタを z_i で表す。この時、グループ j を記述し、また、それに属するサンプル $\{x_i | z_i = j\}$ を推定することを目的とする作業



クラスタリング手法

いくつかの手法が提案されているが、代表的なアプローチに、各クラスタを一つの(単峰の)分布からの i.i.d. サンプルとするものがある。その場合の代表的な推定方法は、分布のパラメータと属するクラスタを最尤推定する方法である。すなわち、次の問題を解きたい

$$\max_{\theta} \max_{z_i} \log \prod_i p(x_i, z_i; \theta) = \max_{\theta} \max_{z_i} \sum_i \log p(x_i, z_i; \theta)$$

この最大化問題には、多数の離散変数 z_i が含まれるため、実際上、解けない。そこで、例えば、次の2つの方法がとられる。

・周辺化して、属するクラスタ番号を消去し、可観測変数のみに対して、EM アルゴリズムを適用する。すなわち、次を解く。クラスタ番号はMAP推定する。

$$\max_{\theta} \sum_{Z_1, \dots, Z_m} \prod_{i=1}^m p(x_i, Z_i; \theta) = \max_{\theta} \prod_{Z_i} \sum_i p(x_i, Z_i; \theta)$$

・k-means 法: 元の問題を、coordinate ascent 法で(近似的に)解く

EM Alg. によるクラスタリング

今更記述する必要もないが、

$$\max_{\theta} \max_{z_i} \log \prod_i p(x_i, z_i; \theta) = \max_{\theta} \max_{z_i} \sum_i \log p(x_i, z_i; \theta)$$

ではなく、次を行う

$$\max_{\theta} \sum_{Z_1, \dots, Z_m} \prod_{i=1}^m p(x_i, Z_i; \theta) = \max_{\theta} \prod_{Z_i} \sum_i p(x_i, Z_i; \theta)$$

$$\Rightarrow \max_{\theta} \sum_i \log \sum_{Z_i} p(x_i, Z_i; \theta)$$

$$\Rightarrow \theta^{(t+1)} = \arg \max_{Z_i, \theta^{(t)}} E \sum_i \log p(x_i, Z_i; \theta)$$

K-means によるクラスタリング

「実際上、解けない」クラスタリングの尤度最大化問題を、直接的に、しかし繰り返し手順で、近似的に解く方法である。通常、等方的かつ分散の等しい正規分布の混合分布を考える。

$$\max_{\theta} \max_{z_i} \log \prod_i p(x_i, z_i; \theta) = \max_{\theta} \max_{z_i} \sum_i \log p(x_i, z_i; \theta)$$

を

$$z_i^{(t+1)} = \arg \max_{z_i} \sum_i \log p(x_i, z_i^{(t)}; \theta^{(t)}) \quad \text{実際上 } z_i^{(t)} \text{ は用いない}$$

$$\theta^{(t+1)} = \arg \max_{\theta} \sum_i \log p(x_i, z_i^{(t+1)}; \theta^{(t)}) \quad \text{実際上 } \theta^{(t)} \text{ は用いない}$$

の繰り返しで求める。ただし、

$$p(x_i, z_i; \theta) = N(x_i, \mu_{z_i})$$

とする。

K-means (続)

$$z_i^{(t+1)} = \arg \max_{z_i} \sum_i \log p(x_i, z_i^{(t)}; \theta^{(t)}) = \arg \max_{z_i} \sum_i \log N(x_i, \mu_{z_i})$$

については、各 x_i について、 $\log N(x_i, \mu_j) = -|x_i - \mu_j|^2 + \text{const.}$ が最大になるような j を選ばばよい(それが可能)。いいかえれば、「ベクトル x_i にもっとも近い中心 μ_j を求めよ。 $z_i = j$ とせよ」

$$\theta^{(t+1)} = \arg \max_{\theta} \sum_i \log p(x_i, z_i^{(t+1)}; \theta^{(t)}) = \arg \max_{\mu} \sum_i \log N(x_i, \mu_{z_i})$$


については、今度は、各 j について、 $\sum_{i: z_i=j} \log N(x_i, \mu_j)$ が最大になるように μ_j を選ばばよい。これは、 $\{x_i | z_i = j\}$ が μ_j を中心とする正規分布のサンプルだととして、中心 μ_j を求める問題である。これは最尤推定すればよい。いいかえれば、「ベクトル $\{x_i | z_i = j\}$ の平均を μ_j とせよ」

K-Means クラスタリング: Lloyd アルゴリズム

1. **Lloyd アルゴリズム**
2. 任意に k 個のクラスタ中心を選ぶ
3. **while** クラスタ中心が変更された
4. 各データ点をクラスタ C_i に割り当てる
割り当てるクラスタは、最も近いクラスタ中心のクラスタ
($1 \leq i \leq k$)
5. すべての点への割り当てが終わったら、
各クラスタの重心を新たなクラスタ中心とする
すなわち、新たなクラスタ中心は、クラスタ C それぞれに
$$\frac{\sum_{v \in C} v}{|C|}$$

*このアルゴリズムは局所解に陥ることがある。

EM-アルゴリズムの実行イメージ



K-Means クラスタリングとの比較

