

第9章 混合モデルとEM

*Pattern
Recognition
and
Machine
Learning*

2015年度 夏合宿

交通研B4

庄司惟

目次

第9章 (混合モデルとEM)

■ 9.1 K-meansクラスタリング

□ 9.1.1 画像分割と画像圧縮

■ 9.2 混合ガウス分布

□ 9.2.1 最尤推定

□ 9.2.2 混合ガウス分布のEMアルゴリズム

■ 9.3 EMアルゴリズムのもう一つの解釈

□ 9.3.1 混合ガウス分布再訪

□ 9.3.2 K-meansとの関係

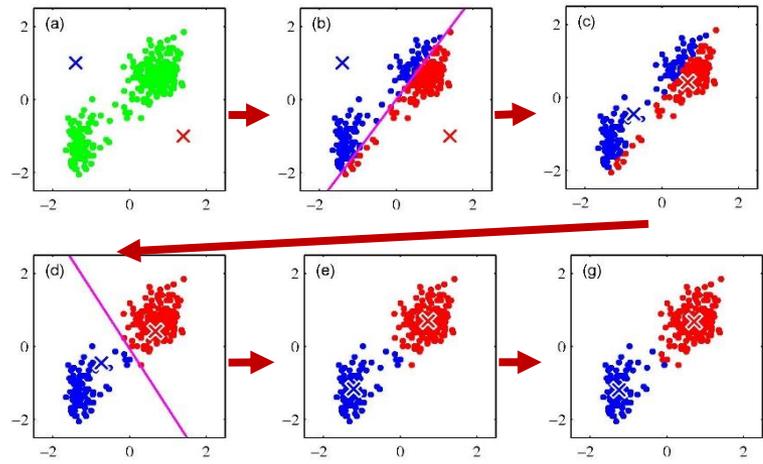
□ 9.3.3 混合ベルヌーイ分布

□ 9.3.4 ベイズ線形回帰に関するEMアルゴリズム

■ 9.4 一般のEMアルゴリズム

1. K-meansと混合ガウスEM

K-means クラスタリング

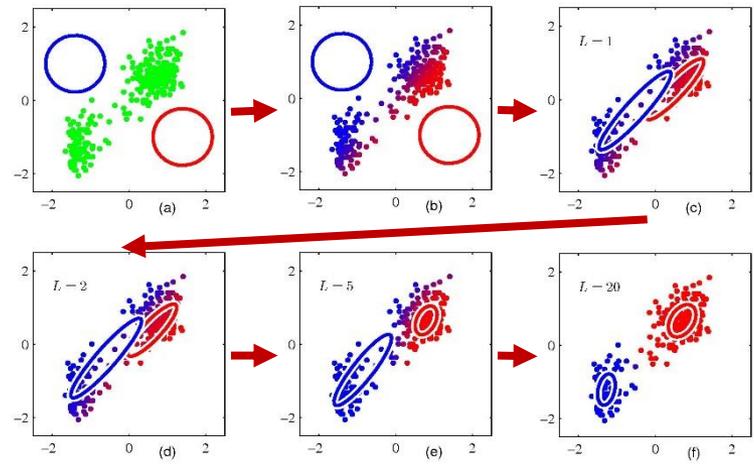


混合ガウス分布のEMアルゴリズム

緩和



極限



- ① 点群が観測点 (上図中では二次元ベクトル)
- ② クラスタ＝データ点間距離が小さいグループ
- ③ \times \times がクラスタ中心 (プロトタイプと呼ばれるベクトルで表現)
- ④ 各クラスタにデータ点を割り当て、割り当てられた点群からの総二乗距離が最小となるようにクラスタ中心を移動し、再度データ点を割り当てなおす。これを繰り返す。

- ① \bigcirc \bigcirc は、ガウス分布の標準偏差の等高線
- ② データ点の各分布に対する割り当ての割合 (=負担率) を計算、負担率から分布形状 (つまり、平均と分散) を調整、するとまた負担率が変化するので、これを繰り返す。

※観測点は必ず唯一つのクラスタに属する！！

※観測点が各々の割合で各ガウス分布に属する！

2. K-means クラスタリング

4

目的関数 $J = \sum_{n=1}^N \sum_{k=1}^K r_{nk} \|\mathbf{x}_n - \boldsymbol{\mu}_k\|^2$ の最小化

観測点

割り当ての指示変数 (1 or 0)

クラスター中心

★目的関数を最小化する r_{nk} $\boldsymbol{\mu}_k$ を求める.

(Step1)

各観測点について、そこからの距離が最短であるクラスター中心を選ぶ。

指示変数 r_{nk} の値を更新。

(Step2)

r_{nk} を固定して目的関数を最小化する。単純な二次関数なので一階条件を解いて $\boldsymbol{\mu}_k$ の値を更新。

$$\boldsymbol{\mu}_k = \frac{\sum_{n=1}^N r_{nk} \mathbf{x}_n}{\sum_{n=1}^N r_{nk}}$$

k番目のクラスターに割り当てられた全ての観測点の平均値 (∴K-means !!)

3. 混合ガウス分布

5

混合ガウス分布とは（復習？）

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

3. 混合ガウス分布

素直なアプローチ（潜在変数用いない）を考察する。

パラメータ推定のために最大化する対数尤度関数は以下の通り。

$$\ln p(X | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k N(\mathbf{x}_k | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}$$


対数の中にK個の要素に関する和が存在し、尤度関数の一階条件を解こうとしても、陽な解が得られない！！（K-meansとの決定的な違い）

とりあえず、素直なアプローチとして、K-means同様 π_k を固定し、パラメータ $\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k$ に関して一階条件を求めようとしてみよう。（無理っぽいけど）

3. 混合ガウス分布

$$\ln p(\mathbf{X}|\boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}$$

$$\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\boldsymbol{\Sigma}|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}$$

D: 観測点ベクトルの次数

$\boldsymbol{\Sigma}$ が対称行列→二次形式

$\boldsymbol{\mu}_k$ に関する一階条件は

$$\sum_{n=1}^N \frac{\pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \left\{ \frac{\partial}{\partial \boldsymbol{\mu}_k} \left(-\frac{1}{2} (\mathbf{x}_n - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_n - \boldsymbol{\mu}_k) \right) \right\}$$

付録1: 二次形式の微分 参照

$$= \sum_{n=1}^N \frac{\pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \{ -\boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_n - \boldsymbol{\mu}_k) \} = 0$$

これ以上整理できない。

(∵ガウス分布の密度関数そのまま残っている, nに関する和の形が残っている.)

3.2 二次形式のベクトル微分

$n \times n$ 正方対称行列 \mathbf{A} に対する (各 a_{ij} は定数) 二次形式 $\mathbf{x}'\mathbf{A}\mathbf{x}$ のベクトル微分

$$\begin{aligned} \frac{\partial \mathbf{x}'\mathbf{A}\mathbf{x}}{\partial \mathbf{x}} &= \begin{pmatrix} \frac{\partial \sum \sum a_{ij}x_i x_j}{\partial x_1} \\ \frac{\partial \sum \sum a_{ij}x_i x_j}{\partial x_2} \\ \vdots \\ \frac{\partial \sum \sum a_{ij}x_i x_j}{\partial x_n} \end{pmatrix} = \begin{pmatrix} 2 \sum a_{1j}x_j \\ 2 \sum a_{2j}x_j \\ \vdots \\ 2 \sum a_{nj}x_j \end{pmatrix} \\ &= 2\mathbf{A}\mathbf{x} \end{aligned}$$

3. 混合ガウス分布

$$\ln p(\mathbf{X} | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}$$

$$\mathcal{N}(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\boldsymbol{\Sigma}|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}$$

D : 観測点ベクトルの次数

$\boldsymbol{\Sigma}_k$ に関する一階条件は

$$0 = \sum_{n=1}^N \frac{\pi_k}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \left\{ \frac{1}{(2\pi)^{D/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x}_n - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_n - \boldsymbol{\mu}_k) \right\} \right\} \left\{ \frac{-1}{2} \frac{1}{|\boldsymbol{\Sigma}_k|^{3/2}} \left(\frac{\partial}{\partial \boldsymbol{\Sigma}_k} |\boldsymbol{\Sigma}_k| \right) - \frac{1}{2} \frac{\partial}{\partial \boldsymbol{\Sigma}_k} (\mathbf{x}_n - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_n - \boldsymbol{\mu}_k) \right\}$$

$$\boldsymbol{\Sigma}_k^{-1} = (\boldsymbol{\Sigma}_k^{-1})^T \quad \frac{\partial}{\partial \boldsymbol{\Sigma}_k} |\boldsymbol{\Sigma}_k| = |\boldsymbol{\Sigma}_k| (\boldsymbol{\Sigma}_k^{-1})^T \quad \left\{ \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_n - \boldsymbol{\mu}_k) (\mathbf{x}_n - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} \right\}^T$$

$$\boldsymbol{\Sigma}_k = \frac{1}{\sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}} \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} (\mathbf{x}_n - \boldsymbol{\mu}_k) (\mathbf{x}_n - \boldsymbol{\mu}_k)^T$$

3. 混合ガウス分布

10

$$L = \ln p(X | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) + \lambda \left(\sum_{k=1}^K \pi_k - 1 \right) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\} + \lambda \left(\sum_{k=1}^K \pi_k - 1 \right)$$

π_k に関する一階条件は,

制約条件 (パラメタ π の総和が1)を考慮したラグランジュ関数を微分して,

$$0 = \sum_{n=1}^N \frac{N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} + \lambda \quad \longrightarrow \quad 0 = \sum_{k=1}^K \left\{ \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} + \lambda \pi_k \right\}$$

両辺に π_k を掛け,
全体を k に関して総和

$$\sum_{k=1}^K \pi_k = 1 \quad \text{より,} \quad \lambda = -N$$

$$0 = \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} - N \pi_k$$

3. 混合ガウス分布

11

まとめると・・・

$$0 = \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \{-\boldsymbol{\Sigma}_k^{-1}(\mathbf{x}_n - \boldsymbol{\mu}_k)\} \quad \boldsymbol{\mu}_k = \frac{1}{\sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}} \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \mathbf{x}_n$$

$$\boldsymbol{\Sigma}_k = \frac{1}{\sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}} \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} (\mathbf{x}_n - \boldsymbol{\mu}_k)(\mathbf{x}_n - \boldsymbol{\mu}_k)^T$$

$$0 = \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} - N \pi_k \quad \pi_k = \frac{1}{N} \sum_{n=1}^N \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}$$

まとめると・・・

$$\gamma(z_{nk}) = \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}$$

実際には複雑,

しかし γ (負担率) でまとめると各パラメータが陽な形で得られる。
⇒ 単純な繰り返し手続きで計算すればよいという示唆を得る。

$$\boldsymbol{\mu}_k = \frac{1}{\sum_{n=1}^N \gamma(z_{nk})} \sum_{n=1}^N \gamma(z_{nk}) \mathbf{x}_n$$

$$\pi_k = \frac{1}{N} \sum_{n=1}^N \gamma(z_{nk})$$

$$\boldsymbol{\Sigma}_k = \frac{1}{\sum_{n=1}^N \gamma(z_{nk})} \sum_{n=1}^N \gamma(z_{nk}) (\mathbf{x}_n - \boldsymbol{\mu}_k)(\mathbf{x}_n - \boldsymbol{\mu}_k)^T$$

繰り返し計算とは

- ①各パラメタの値に基づき, γ (負担率) を計算
- ②それを定数として代入し, 各パラメタを求め
る
- ①②を繰り返す!

Eステップ

$$\gamma(z_{nk}) = \frac{\pi_k N(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}$$

Mステップ

$$\boldsymbol{\mu}_k = \frac{1}{\sum_{n=1}^N \gamma(z_{nk})} \sum_{n=1}^N \gamma(z_{nk}) \mathbf{x}_n$$

$$\boldsymbol{\Sigma}_k = \frac{1}{\sum_{n=1}^N \gamma(z_{nk})} \sum_{n=1}^N \gamma(z_{nk}) (\mathbf{x}_n - \boldsymbol{\mu}_k)(\mathbf{x}_n - \boldsymbol{\mu}_k)^T$$

$$\pi_k = \frac{1}{N} \sum_{n=1}^N \gamma(z_{nk})$$

対数尤度計算
収束判定

$$\ln p(\mathbf{X} | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}$$

Expectation-Maximization algorithm

観測不可能な潜在変数に確率モデルが依存する場合にパラメータを推定する手法。

基本的に、最尤法に基づく。期待値最大化法とも。

EステップとMステップを交互に繰り返す。

Eステップ (期待値ステップ)

現在推定されている潜在変数の分布に基づいて、モデル尤度の期待値を計算する。



Mステップ (最大化ステップ)

Eステップで得られた尤度の期待値を最大化するようなパラメータを求める。これにより次のEステップで用いられる潜在変数分布を決めることができる。

→よくわからない...まずは潜在変数を理解する。

5. 混合ガウスの潜在変数

16

K次元の2値確率変数 \mathbf{z} を導入する。

これは1-of-K, つまりK通りの内どれか一つだけ1,他は0.

$z_k=1$ なる事象の事前確率

$$p(z_k = 1) = \pi_k \quad \longrightarrow \quad p(\mathbf{z}) = \prod_{k=1}^K \pi_k^{z_k}$$

※ π の定義より, $0 \leq \pi_k \leq 1, \sum_{k=1}^K \pi_k = 1$ であり, 確率の値の定義を満たす.

$$p(\mathbf{x} | z_k = 1) = N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \quad \longrightarrow \quad p(\mathbf{x} | \mathbf{z}) = \prod_{k=1}^K N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)^{z_k}$$

$$p(\mathbf{x}) = \sum_{\mathbf{z}} p(\mathbf{z}) p(\mathbf{x} | \mathbf{z}) = \sum_{k=1}^K \pi_k N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

5. 混合ガウスの潜在変数

17

$$p(z_k = 1) = \pi_k \quad p(\mathbf{x} | z_k = 1) = N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

$$p(\mathbf{x}) = \sum_{\mathbf{z}} p(\mathbf{z}) p(\mathbf{x} | \mathbf{z}) = \sum_{k=1}^K \pi_k N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$



$$\text{※} p(\mathbf{x}) p(\mathbf{z} | \mathbf{x}) = p(\mathbf{z}) p(\mathbf{x} | \mathbf{z})$$

$$p(z_k = 1 | \mathbf{x}) = \frac{p(z_k = 1) p(\mathbf{x} | z_k = 1)}{\sum_{j=1}^K p(z_j = 1) p(\mathbf{x} | z_j = 1)} = \frac{\pi_k N(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j N(\mathbf{x} | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}$$

Xを観測したときの対応する事後確率

= 混合要素kがxの観測を説明する度合を表す「負担率」と解釈できる。

以上，混合ガウス分布での示唆より，
EMアルゴリズムは，

「潜在変数の事後分布」に着目してつくられた
簡易計算法なのでは？

と考えられる．

混合ガウス分布から拡張し，EMアルゴリズムの
一般的な利用を試みる．

観測変数 X と潜在変数 Z の同時分布 $p(X, Z|\theta)$ が与えられていて、パラメータ θ で支配されているとする。アルゴリズムの目的は尤度関数 $p(X|\theta)$ を θ に関して最大化することである。

1: パラメータの初期値 $\theta(\text{old})$ を選ぶ。

2(Eステップ): 事後確率 $p(Z|X, \theta(\text{old}))$ を計算する。

3(Mステップ): 上で求めた事後確率を所与として尤度関数を最大化する $\theta(\text{new})$ を求める。

4: 尤度関数またはパラメータ値が収束条件を満たしていない場合 $\theta(\text{old})$ に $\theta(\text{new})$ を代入し2へ！

3(Mステップ): 上で求めた事後確率を所与として尤度関数を最大化する $\theta(\text{new})$ を求める。

$$\theta^{new} = \arg \max_{\theta} Q(\theta, \theta^{old})$$

$$Q(\theta, \theta^{old}) = \sum_{\mathbf{z}} p(\mathbf{Z} | \mathbf{X}, \theta^{old}) \ln p(\mathbf{X}, \mathbf{Z} | \theta)$$

完全データ対数尤度の期待値

⇒なぜ期待値を最大化してるのか？

4. 一般のEMアルゴリズム

21

$$\underline{p(\mathbf{X} | \theta)} = \sum_{\mathbf{Z}} p(\mathbf{X}, \mathbf{Z} | \theta)$$

これが最適化困難であるときどうするか。

確率の連鎖律より $\ln p(\mathbf{X}, \mathbf{Z} | \theta) = \ln p(\mathbf{Z} | \mathbf{X}, \theta) + \ln p(\mathbf{X} | \theta)$

$$L(q, \theta) \equiv \sum_{\mathbf{Z}} q(\mathbf{Z}) \ln \left\{ \frac{p(\mathbf{X}, \mathbf{Z} | \theta)}{q(\mathbf{Z})} \right\} \quad \text{と定義してこれを計算}$$

代入

$$= \sum_{\mathbf{Z}} q(\mathbf{Z}) \{ \ln p(\mathbf{Z} | \mathbf{X}, \theta) + \ln p(\mathbf{X} | \theta) - q(\mathbf{Z}) \}$$

$$= \sum_{\mathbf{Z}} q(\mathbf{Z}) \ln \left\{ \frac{\ln p(\mathbf{Z} | \mathbf{X}, \theta)}{q(\mathbf{Z})} \right\} + \ln p(\mathbf{X} | \theta) \underbrace{\sum_{\mathbf{Z}} q(\mathbf{Z})}_{=1}$$

$$= -KL(q \| p) + \ln p(\mathbf{X} | \theta)$$

$$KL(q \parallel p) = -\sum_{\mathbf{Z}} q(\mathbf{Z}) \ln \left\{ \frac{\ln p(\mathbf{Z} | \mathbf{X}, \theta)}{q(\mathbf{Z})} \right\} \quad \text{に関して}$$

これは $q(\mathbf{Z})$ と事後分布 $p(\mathbf{Z} | \mathbf{X}, \theta)$ の
カルバック-ライブラーダイバージェンス (KLダイバージェンス) ,
つまり相対エントロピーである .

$$\text{一般型 } KL(q \parallel p) = -\int p(\mathbf{x}) \ln \left\{ \frac{q(\mathbf{x})}{p(\mathbf{x})} \right\} d\mathbf{x} \geq -\ln \int q(\mathbf{x}) d\mathbf{x} = 0$$

∴関数 $-\ln x$ が凸関数

$$\text{※} \int q(\mathbf{x}) d\mathbf{x} = 1 \text{ (規格化条件)}$$

Eステップ解説

以下を， $q(Z)$ について最大化

$$L(q, \theta^{old}) \equiv \underbrace{-KL(q \parallel p)}_{\geq 0} + \ln \underbrace{p(\mathbf{X} | \theta^{old})}_{q(Z) \text{ には依存しない}}$$

→ $KL(q \parallel p) = 0 \Rightarrow \underbrace{q(\mathbf{Z}) = p(\mathbf{Z} | \mathbf{X}, \theta^{old})}_{\text{のとき最大である!}}$

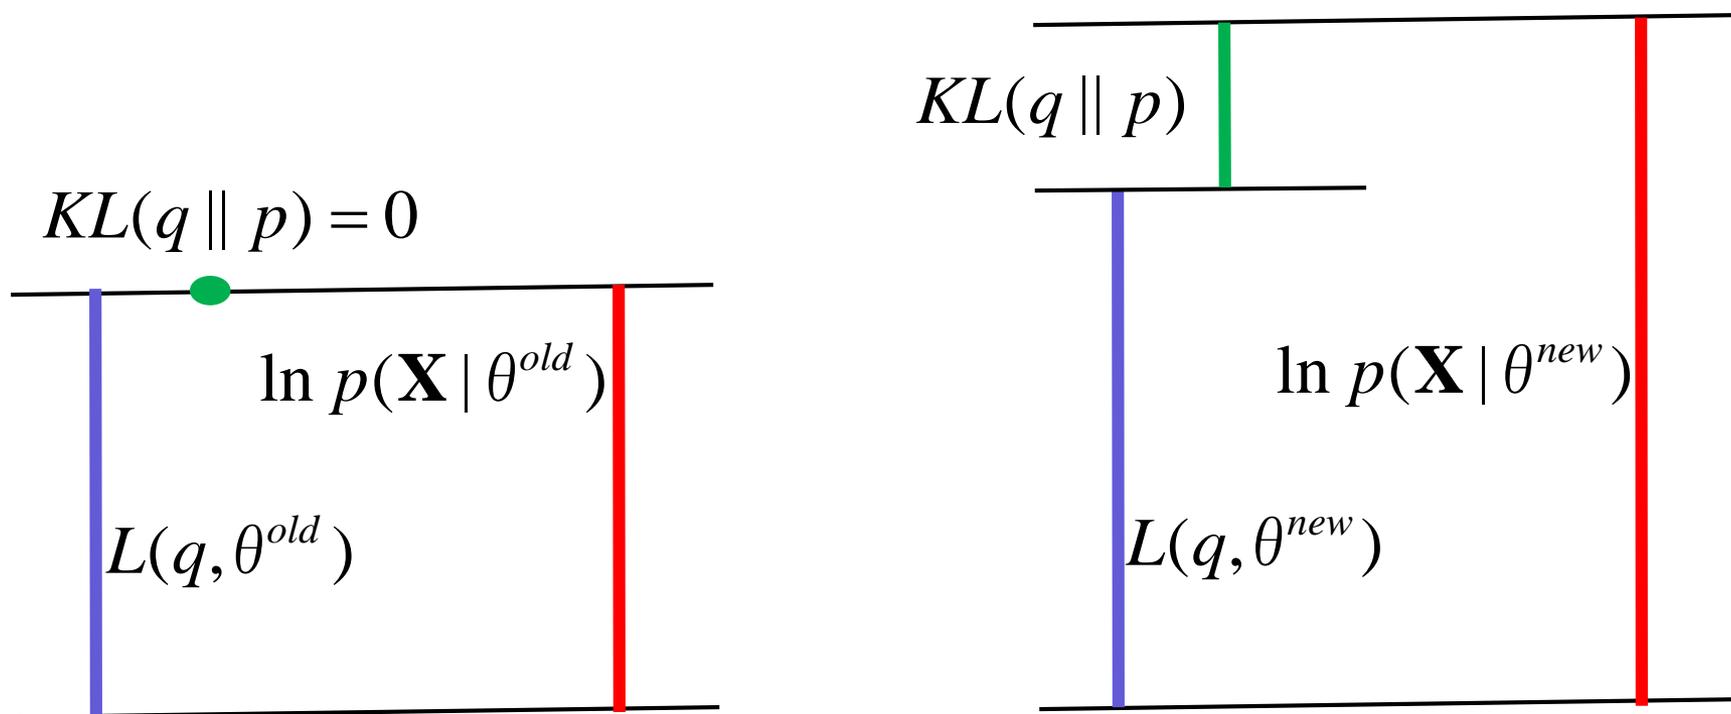
4. 一般のEMアルゴリズム

24

Mステップ解説

$$L(q, \theta) \equiv -KL(q \parallel p) + \ln p(\mathbf{X} | \theta)$$

$q(Z)$ を固定し， θ について下界を最大化



$\Rightarrow \ln p(\mathbf{X} | \theta)$ の増加量は $L(q, \theta)$ の増加量よりも大きい

Mステップ解説

$$\begin{aligned} L(q, \theta) &\equiv \sum_{\mathbf{Z}} q(\mathbf{Z}) \ln \left\{ \frac{p(\mathbf{X}, \mathbf{Z} | \theta)}{q(\mathbf{Z})} \right\} && q(\mathbf{Z}) = p(\mathbf{Z} | \mathbf{X}, \theta^{old}) \\ &= \sum_{\mathbf{Z}} p(\mathbf{Z} | \mathbf{X}, \theta^{old}) \ln \left\{ \frac{p(\mathbf{X}, \mathbf{Z} | \theta)}{p(\mathbf{Z} | \mathbf{X}, \theta^{old})} \right\} \\ &= \sum_{\mathbf{Z}} p(\mathbf{Z} | \mathbf{X}, \theta^{old}) \ln p(\mathbf{X}, \mathbf{Z} | \theta) - \sum_{\mathbf{Z}} p(\mathbf{Z} | \mathbf{X}, \theta^{old}) \ln p(\mathbf{Z} | \mathbf{X}, \theta^{old}) \\ &= Q(\theta, \theta^{old}) + const. \end{aligned}$$

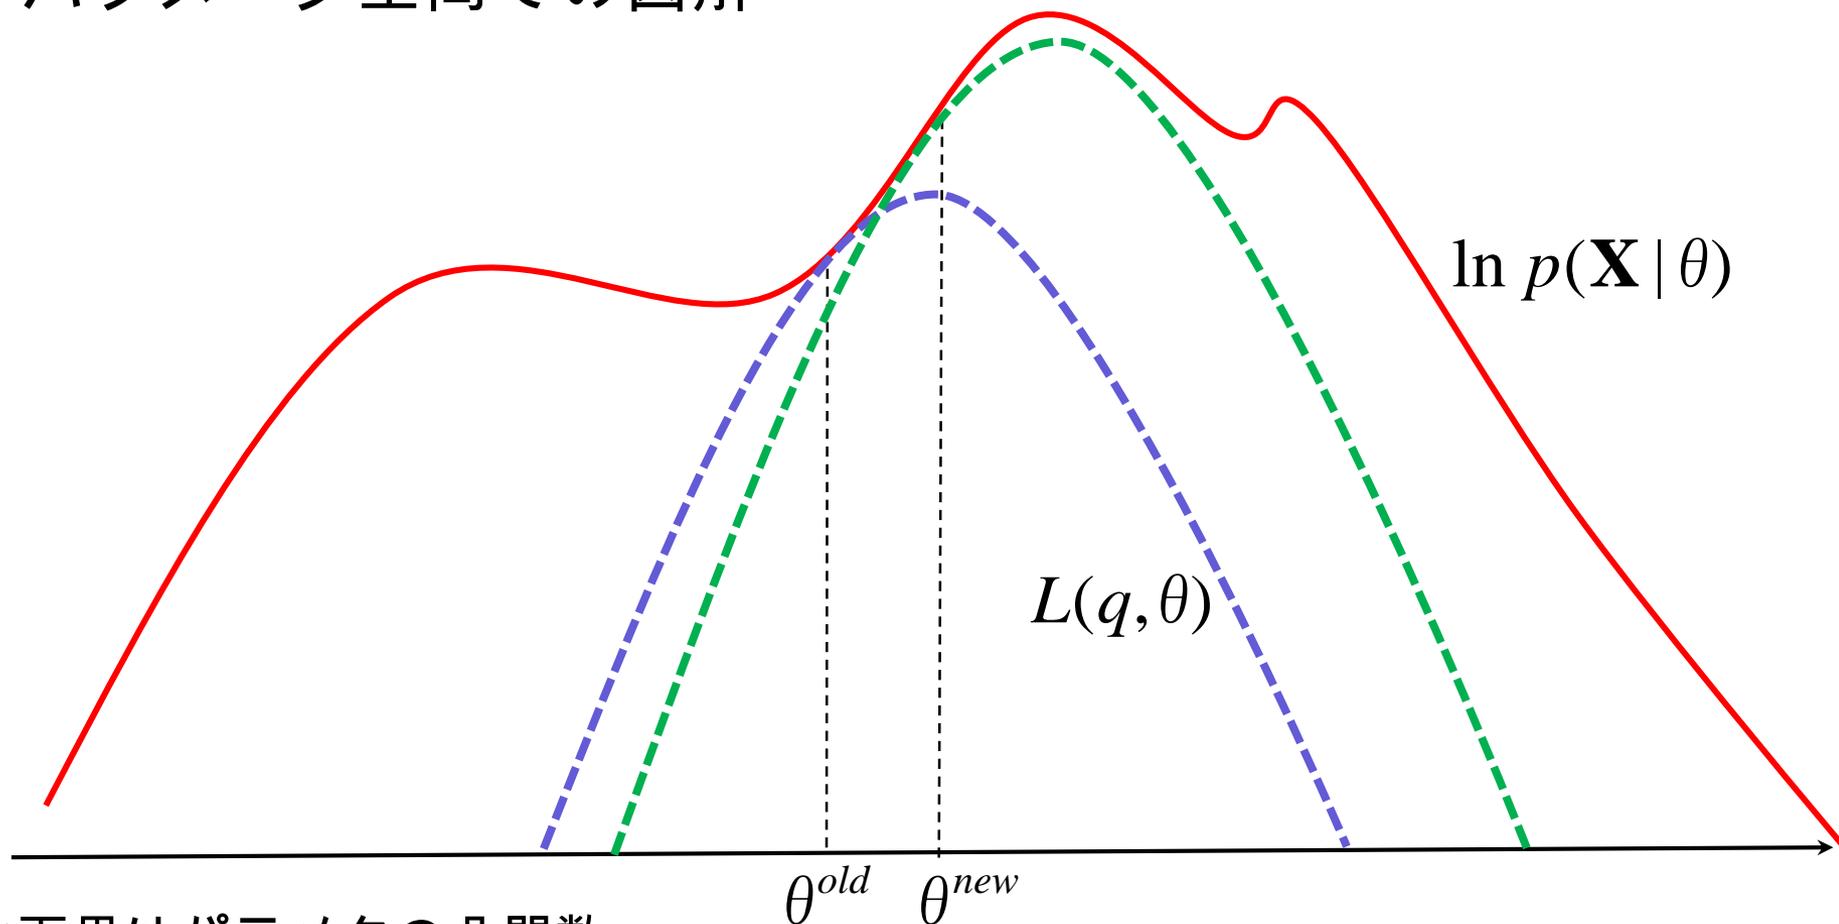
$L(q, \theta)$ を最大化するとき，実際は「完全データ対数尤度の**期待値**」を最大化することになる。

変数 θ は対数の中のみを表れている→最適化容易

4. 一般のEMアルゴリズム

26

パラメータ空間での図解



※下界はパラメタの凸関数

まとめると・・・

EMアルゴリズムはKmeansと比べるとほぼ終息するまでに必要な繰り返し数と繰り返し一回の計算量が多い。

⇒一般的に、混合ガウスモデルの適切な初期値を見つけるためにKmeansが使われたりする。（そのあとにEMを使う）

Q, どうKmeansとEMを対応させる？

A, 共分散行列の初期値 → クラスタのサンプル分散

混合係数の初期値 → 各クラスタに属するデータ点の割合

※対数尤度関数が多峰であることが多く、その場合に唯一解を与えない。

観測データ集合 X から計算される尤度/対数尤度関数

$$p(X | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \prod_{n=1}^N \left\{ \sum_{k=1}^K \pi_k N(\mathbf{x}_k | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\} \quad \ln p(X | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k N(\mathbf{x}_k | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}$$

完全データ集合 (\Rightarrow 各データ点がどの要素から生成したかを示すラベルを含むデータ集合) に関する

$$p(X, Z | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \prod_{n=1}^N \prod_{k=1}^K \pi_k^{z_{nk}} \left\{ N(\mathbf{x}_k | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}^{z_{nk}}$$

$$\ln p(X, Z | \boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \sum_{k=1}^K z_{nk} \left\{ \ln \pi_k + \ln N(\mathbf{x}_k | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\}$$