

東京大学工学部 4年生 夏学期 [03-501130]

応用音響学

第4回 (5/ 1)

亀岡弘和

東京大学大学院情報理工学系研究科
システム情報学専攻
kameoka@hil.t.u-tokyo.ac.jp

講義スケジュール

前半(亀岡担当)

- 4/08: 第1回
- 4/15: 第2回
- 4/22: 第3回
- 4/29: 休日
- 5/01(木): 第4回
- 5/06: 休日
- 5/13: 第5回
- 5/20: 第6回
- 5/27: 第7回

後半(牧野担当)

- 6/03: 第8回
- 6/10: 第9回
- 6/17: 第10回
- 6/24: 第11回
- 7/01: 第12回
- 7/08: 第13回
- 7/15: 第14回
- 7/22: 学期末試験

講義資料と成績評価

■ 講義資料

- <http://hil.t.u-tokyo.ac.jp/~kameoka/aa/>

■ 成績評価

- 出席点
- 学期末試験

本日の話題


- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリングのおさらい
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係


k-meansクラスタリング

- データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



k-meansクラスタリング

- データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法




(Step 0)

クラスタ代表値を初期設定

k-meansクラスタリング

- データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)


クラスタ代表値を初期設定

(Step 1)

クラスタ境界を決定

k-meansクラスタリング

■ データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)


クラスタ代表値を初期設定

(Step 1)

クラスタ境界を決定

k-meansクラスタリング

■ データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)

クラスタ代表値を初期設定

(Step 1)


クラスタ境界を決定

(Step 2)

クラスタ代表値を決定

k-meansクラスタリング

■ データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)

クラスタ代表値を初期設定

(Step 1)


クラスタ境界を決定

(Step 2)

クラスタ代表値を決定

k-meansクラスタリング

■ データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)

クラスタ代表値を初期設定

(Step 1)


クラスタ境界を決定

(Step 2)

クラスタ代表値を決定

k-meansクラスタリング

■ データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)

クラスタ代表値を初期設定

(Step 1)


クラスタ境界を決定

(Step 2)

クラスタ代表値を決定

k-meansクラスタリング

■ データ $X = \{x_1, \dots, x_N\}$ の教師なしクラスタリングの一手法



(Step 0)

クラスタ代表値を初期設定

(Step 1)

クラスタ境界を決定

(Step 2)

クラスタ代表値を決定

k-meansクラスタリング


■ アルゴリズムの収束性

■ クラスタリングの目的関数

$$J(Z, \mu) \equiv \sum_k \sum_n \mathbf{1}[z_n = k] \underbrace{\|x_n - \mu_k\|_2^2}_{\text{散らばり}}$$

$$\mathbf{1}[z_n = k] = \begin{cases} 1 & (z_n = k) \\ 0 & (z_n \neq k) \end{cases}$$

- $\{\mu_1, \dots, \mu_K\}$: クラスタ代表値
- $\{z_1, \dots, z_N\}$: 各データの帰属クラスタ



■ 反復アルゴリズム

- **(Step 1)** $\hat{Z} \leftarrow \underset{Z}{\operatorname{argmin}} J(Z, \mu) \Rightarrow$ 明らかに $\hat{z}_n = \underset{j}{\operatorname{argmin}} \|x_n - \mu_j\|_2^2$
- **(Step 2)** $\hat{\mu} \leftarrow \underset{\mu}{\operatorname{argmin}} J(Z, \mu) \Rightarrow \partial J(Z, \mu) / \partial \mu_j = 0$ を解くと

目的関数は当然単調減少する
→ 収束性が保証される

$$\hat{\mu}_j = \frac{\sum_n \mathbf{1}[z_n = j] x_n}{\sum_n \mathbf{1}[z_n = j]} \quad \begin{array}{l} \text{クラスタ} \\ \text{重心} \end{array}$$

本日の話題


- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係


k-meansクラスタリングの生成モデルとしての解釈

- K個のクラスタ(塊)からなるデータの生成プロセスを確率モデルで表現できないか？
 - クラスタリング問題はその逆プロセス




k-meansクラスタリングの生成モデルとしての解釈

- K個のクラスタ(塊)からなるデータの生成プロセスを確率モデルで表現できないか？
 - クラスタリング問題はその逆プロセス
- 生成プロセスの例
 - K個の正規分布をランダムに生成
 - サンプルごとに
 - 正規分布のクラス番号をランダムに選択
 - 選択されたクラス番号の正規分布に従ってサンプル値を生成
 - 生成された全サンプルが観測データ！



k-meansクラスタリングの生成モデルとしての解釈

- K個のクラスタ(塊)からなるデータの生成プロセスを確率モデルで表現できないか？
 - クラスタリング問題はその逆プロセス
- 生成プロセスの例
 - K個の正規分布をランダムに生成
 - サンプルごとに
 - 正規分布のクラス番号をランダムに選択
 - 選択されたクラス番号の正規分布に従ってサンプル値を生成
 - 生成された全サンプルが観測データ！
- データの確率的な生成プロセスの仮定
 - ⇔ データの確率モデル化



本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
- 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

最尤推定

- データから、尤度関数が最大となる確率モデルのパラメータを推定するための一般的な枠組


- 尤度関数とは？

- データを X , パラメータを Θ とすると、尤度関数は $p(X|\Theta)$ のこと
- 「データ X の生成源として、パラメータ Θ の確率モデルがどの程度尤もらしいか」を意味した規準

- 最尤推定

- 最も尤もらしい、データの生成源を推定すること

- クラスタリング問題の例では・・・



本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
- 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係


本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
- 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

混合正規分布モデル (Gaussian Mixture Model; GMM)

■ 混合正規分布モデルによるデータの生成プロセス


- K個の正規分布をランダムに生成
- サンプルごとに
 - 正規分布のクラス番号をランダムに選択
 - 選択されたクラス番号の正規分布に従ってサンプル値を生成
- 生成された全サンプルが観測データ



■ 生成モデル

```
for  $k = 1, \dots, K$   
   $\{\mu_k, \sigma_k, \pi_k\} \sim H$   
  
for  $n = 1, \dots, N$   
   $z_n \sim \text{Categorical}(\pi_1, \dots, \pi_K)$   
   $x_n | z_n \sim \mathcal{N}(\mu_{z_n}, \Sigma_{z_n})$ 
```

π_k : k番目の正規分布
が選ばれる確率



本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
- 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

EMアルゴリズム

■ GMMパラメータの最尤推定

■ GMMのパラメータ: $\Theta = \{\mu_k, \sigma_k, \pi_k\}_{k=1, \dots, K}$

対数をとっても最大化の目標は変わらない

■ 求めたいのは $\hat{\Theta}_{\text{ML}} = \underset{\Theta}{\operatorname{argmax}} p(X|\Theta) = \underset{\Theta}{\operatorname{argmax}} \log p(X|\Theta)$

■ 尤度関数の導出

生成
モデル

$$\begin{cases} p(Z|\Theta) = \prod_n p(z_n|\Theta) = \prod_n \pi_{z_n} \\ P(X|Z, \Theta) = \prod_n p(x_n|z_n, \Theta) = \prod_n \mathcal{N}(x_n; \mu_{z_n}, \Sigma_{z_n}) \end{cases}$$

$$\mathcal{N}(x_n; \mu_k, \Sigma_k) \equiv \frac{1}{\sqrt{(2\pi)^J |\Sigma_k|}} \exp \left\{ -\frac{1}{2} (x_n - \mu_k)^\top \Sigma_k^{-1} (x_n - \mu_k) \right\}$$


$$\begin{aligned} p(X|\Theta) &= \sum_Z p(X|Z, \Theta) p(Z|\Theta) = \prod_n \sum_{z_n=1}^K p(x_n|z_n, \Theta) p(z_n|\Theta) \\ &= \prod_n \sum_{z_n=1}^K \pi_{z_n} \mathcal{N}(x_n; \mu_{z_n}, \Sigma_{z_n}) \end{aligned}$$

EMアルゴリズム

■ $p(X|\Theta) = \prod_n \sum_{z_n=1}^K \pi_{z_n} \mathcal{N}(x_n; \mu_{z_n}, \Sigma_{z_n})$ を最大化する Θ を求めたい

■ しかし解析的には求められない！

■ ちなみに、 Z が既知であれば(各データにクラスラベルが付与されていれば), 各正規分布パラメータの最尤推定は解析的に求められる

⇒ 平均, 分散, データの各クラスへの帰属率を求めるだけ

■ 解析的な求解を困難にしているのは

$$\log p(X|\Theta) = \sum_n \log \sum_{z_n=1}^K \pi_{z_n} \mathcal{N}(x_n; \mu_{z_n}, \Sigma_{z_n})$$

におけるlogの中のsummation

Z のように
尤度関数に姿を現さない
変数のことを「潜在変数」
または「隠れ変数」という

補助関数法

■ 補助関数法


- 目的関数 $D(\theta)$ を局所最小化するためのテクニック
- $D(\theta) = \min_{\bar{\theta}} G(\theta, \bar{\theta})$ を満たす $G(\theta, \bar{\theta})$ を補助関数と定義
- 反復アルゴリズム

$$[1] \quad \bar{\theta}^{(l+1)} = \operatorname{argmin}_{\bar{\theta}} G(\theta^{(l)}, \bar{\theta})$$

$$[2] \quad \theta^{(l+1)} = \operatorname{argmin}_{\theta} G(\theta, \bar{\theta}^{(l+1)})$$

■ 収束性

$$\begin{aligned} D(\theta^{(l)}) &= G(\theta^{(l)}, \bar{\theta}^{(l+1)}) \\ &\geq G(\theta^{(l+1)}, \bar{\theta}^{(l+1)}) \\ &\geq D(\theta^{(l+1)}) \end{aligned}$$



Jensenの不等式

■ Jensenの不等式


- $\phi(\cdot)$: 凸関数
- $\lambda_i \geq 0, \sum_i \lambda_i = 1$

$$\Rightarrow \phi\left(\sum_i \lambda_i z_i\right) \leq \sum_i \lambda_i \phi(z_i)$$

例えば,

$\phi(z) = -\log z$ の場合:

$$\begin{aligned} & -\log\left(\sum_i \lambda_i z_i\right) \\ & \leq -\sum_i \lambda_i \log z_i \end{aligned}$$



EMアルゴリズム

■ 対数尤度 $\log p(X|\Theta) = \sum_n \log \sum_{k=1}^K \pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k)$ の下限関数

$$\begin{aligned} & \log \sum_{k=1}^K \pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k) \\ &= \log \sum_{k=1}^K \lambda_{k,n} \frac{\pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k)}{\lambda_{k,n}} \\ &\geq \sum_{k=1}^K \lambda_{k,n} \log \frac{\pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k)}{\lambda_{k,n}} \end{aligned}$$


← 対数関数が凹関数であることに注意してJensenの不等式を適用

$$Q(\Theta, \lambda) \equiv \sum_n \sum_{k=1}^K \lambda_{k,n} \log \frac{\pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k)}{\lambda_{k,n}} \quad \text{は } \log p(X|\Theta) \text{ の}$$

補助関数！


EMアルゴリズム

- 対数尤度と補助関数の関係: $\min_{\lambda} Q(\Theta, \lambda) = \log p(X|\Theta)$
- 反復アルゴリズムによる局所最大化



EMアルゴリズム

- 対数尤度と補助関数の関係: $\min_{\lambda} Q(\Theta, \lambda) = \log p(X|\Theta)$
- 反復アルゴリズムによる局所最大化



なぜEMアルゴリズムと呼ばれるか

■λの更新式

$$\begin{aligned}\lambda_{k,n}^{(l+1)} &= \frac{\pi_k \mathcal{N}(x_n; \mu_k^{(l)}, \Sigma_k^{(l)})}{\sum_m \pi_m \mathcal{N}(x_n; \mu_m^{(l)}, \Sigma_m^{(l)})} \\ &= \frac{p(x_n | z_n = k, \Theta) p(z_n = k | \Theta)}{\sum_m p(x_n | z_n = m, \Theta) p(z_n = m | \Theta)} \\ &= \frac{p(x_n | z_n = k, \Theta) p(z_n = k | \Theta)}{p(x_n | \Theta)} \\ &= p(z_n = k | x_n, \Theta)\end{aligned}$$

データ x_n がクラス m の正規分布から生成された(事後)確率

■補助関数

$$Q(\Theta, \lambda) \equiv \sum_n \sum_{k=1}^K \lambda_{k,n} \log \frac{\pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k)}{\lambda_{k,n}}$$

$p(x_n, z_n = k | \Theta)$
観測データと潜在変数のペア
⇒「完全データ」と呼ぶ

よって、 $Q(\Theta, \lambda)$ は「完全データに対する対数尤度」の期待値に相当

本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

本日の話題

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係

k-meansクラスタリングとの関係

■ k-means アルゴリズム

- (Step 1) $z_n \leftarrow \operatorname{argmin}_j \|x_n - \mu_j\|_2^2$
- (Step 2) $\mu_j \leftarrow \frac{\sum_n \mathbf{1}[z_n = j] x_n}{\sum_n \mathbf{1}[z_n = j]}$


■ EM アルゴリズムによる

GMM パラメータの最尤推定

- (E-Step) $\lambda_{k,n} \leftarrow \frac{\pi_k \mathcal{N}(x_n; \mu_k, \Sigma_k)}{\sum_m \pi_m \mathcal{N}(x_n; \mu_m, \Sigma_m)}$
- (M-step) $\mu_k \leftarrow \frac{\sum_n \lambda_{k,n} x_{k,n}}{\sum_n \lambda_{k,n}} \dots$

■ 後者が前者と等価となる条件: $\Sigma_k \rightarrow 0$

- Eステップにおけるデータのクラス分けが排他的になる



本日の講義のまとめ

- 確率モデル(生成モデル)による
パターン認識(クラスタリング)問題の定式化
 - k-meansクラスタリング
 - k-meansクラスタリングの生成モデルとしての解釈
 - 最尤推定
 - 混合正規分布モデル (Gaussian Mixture Model; GMM)
 - EMアルゴリズム
 - 補助関数とJensen不等式
 - EMアルゴリズムによるGMMパラメータの最尤推定
とk-meansアルゴリズムの関係