

クラスタリング

階層的クラスタリング, k 平均法, ソフトクラスタリング

中田和秀

東京科学大学 工学院 経営工学系

機械学習入門

<https://www.nakatalab.iee.e.titech.ac.jp/text/nakata.html>

概要

特定のタスクに対する正解は無いものの、データ自体は大量にあるというケースが多い。その場合には教師なし学習を行うことになる。ここでは、その一つであるクラスタリングについて説明をする。クラスタリングによって、データ点を幾つかのグループにまとめることができる。

目次：

1. 階層的クラスタリング
 - ▷ 単連結法、完全連結法、群平均法、Ward 法
2. k 平均法
 - 2.1 学習モデル
 - 2.2 学習アルゴリズム
3. ソフトクラスタリング
 - ▷ 混合正規分布

記号の使い方：

- $A := B$ は、B で A を定義する、B を A に代入することを意味する
- $[n]$ は n までのインデックスの集合を表し $[n] := \{1, 2, \dots, n\}$

クラスタリング


教師なし学習：

与えられたデータに対し、データに潜むパターン・構造・知見を見出す。

クラスタリング

データを幾つかのクラスタにグループ分けする手法

例：顧客層の発見、行動パターンの類型化、企業の分類、故障原因の抽出など




以下で説明する手法

- 階層的クラスタリング
- k 平均法
- ソフトクラスタリング（混合正規分布）

階層的クラスタリング

バラバラの状態から「距離」の近い順に融合して次第に大きなクラスタを作る手法
樹形図 (dendrogram) で表現する。

樹形図



学習アルゴリズム

ステップ0 データ点一つが一つのクラスタとする。

ステップ1 クラスタ間の距離を計算

ステップ2 最も距離が小さなクラスタを合併する

ステップ3 クラスタが二つ以上あればステップ1に戻る

学習アルゴリズムのイメージ





Figure: https://en.wikipedia.org/wiki/Hierarchical_clustering

クラスタ間の距離

- 単連結法：

$$D(C_i, C_j) := \min_{\mathbf{x} \in C_i, \mathbf{y} \in C_j} d(\mathbf{x}, \mathbf{y})$$

大きなクラスタができやすい

- 完全連結法：

$$D(C_i, C_i) := \max_{\mathbf{x} \in C_i, \mathbf{y} \in C_j} d(\mathbf{x}, \mathbf{y})$$

同じようなサイズのクラスタができやすい

- 群平均法：

$$D(C_i, C_j) := \frac{1}{|C_i||C_j|} \sum_{\mathbf{x} \in C_i, \mathbf{y} \in C_j} d(\mathbf{x}, \mathbf{y})$$

単連結法と完全連結法の間の性質


- Ward 法：

μ は平均ベクトル

$$D(C_i, C_j) := \sum_{\mathbf{x} \in C_i \cup C_j} \|\mathbf{x} - \boldsymbol{\mu}_{ij}\|^2 - \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|^2 - \sum_{\mathbf{x} \in C_j} \|\mathbf{x} - \boldsymbol{\mu}_j\|^2$$

クラスタ内変動の増分で距離を定義しており、良さそうな結果になりやすい

数値例



Ward 法の効率的な計算方法

Ward 法

$$D(C_i, C_j) := \sum_{\mathbf{x} \in C_i \cup C_j} \|\mathbf{x} - \boldsymbol{\mu}_{ij}\|^2 - \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|^2 - \sum_{\mathbf{x} \in C_j} \|\mathbf{x} - \boldsymbol{\mu}_j\|^2$$

- クラスタ C_i の平均ベクトルは $\boldsymbol{\mu}_i := \frac{1}{|C_i|} \sum_{\mathbf{x} \in C_i} \mathbf{x}$
- クラスタ C_i と C_j を統合してクラスタ C_{ij} を作る
- クラスタ C_{ij} の平均ベクトルを $\boldsymbol{\mu}_{ij}$ とする

次のように簡単に計算が可能

$$\boldsymbol{\mu}_{ij} = \frac{|C_i|}{|C_i| + |C_j|} \boldsymbol{\mu}_i + \frac{|C_j|}{|C_i| + |C_j|} \boldsymbol{\mu}_j$$

$$D(C_i, C_j) = \frac{|C_i| |C_j|}{|C_i| + |C_j|} \|\boldsymbol{\mu}_i - \boldsymbol{\mu}_j\|^2$$

式変形は次スライド

式変形 1

$$\begin{aligned}\boldsymbol{\mu}_{ij} &:= \frac{1}{|C_{ij}|} \sum_{\mathbf{x} \in C_{ij}} \mathbf{x} \\ &= \frac{1}{|C_i \cup C_j|} \sum_{\mathbf{x} \in C_i \cup C_j} \mathbf{x} \\ &= \frac{1}{|C_i| + |C_j|} \left(\sum_{\mathbf{x} \in C_i} \mathbf{x} + \sum_{\mathbf{x} \in C_j} \mathbf{x} \right) \\ &= \frac{|C_i|}{|C_i| + |C_j|} \frac{1}{|C_i|} \sum_{\mathbf{x} \in C_i} \mathbf{x} + \frac{|C_j|}{|C_i| + |C_j|} \frac{1}{|C_j|} \sum_{\mathbf{x} \in C_j} \mathbf{x} \\ &= \frac{|C_i|}{|C_i| + |C_j|} \boldsymbol{\mu}_i + \frac{|C_j|}{|C_i| + |C_j|} \boldsymbol{\mu}_j\end{aligned}$$

式変形 2

$$\begin{aligned}\sum_{\boldsymbol{x} \in C} d(\boldsymbol{x}, \boldsymbol{\mu})^2 &= \sum_{\boldsymbol{x} \in C} (\boldsymbol{x} - \boldsymbol{\mu})^T (\boldsymbol{x} - \boldsymbol{\mu}) \\&= \sum_{\boldsymbol{x} \in C} \boldsymbol{x}^T \boldsymbol{x} - 2\boldsymbol{\mu}^T \boldsymbol{x} + \boldsymbol{\mu}^T \boldsymbol{\mu} \\&= \sum_{\boldsymbol{x} \in C} \boldsymbol{x}^T \boldsymbol{x} - 2\boldsymbol{\mu}^T \sum_{\boldsymbol{x} \in C} \boldsymbol{x} + |C| \boldsymbol{\mu}^T \boldsymbol{\mu} \\&= \sum_{\boldsymbol{x} \in C} \boldsymbol{x}^T \boldsymbol{x} - 2\boldsymbol{\mu}^T |C| \boldsymbol{\mu} + |C| \boldsymbol{\mu}^T \boldsymbol{\mu} \\&= \sum_{\boldsymbol{x} \in C} \boldsymbol{x}^T \boldsymbol{x} - |C| \boldsymbol{\mu}^T \boldsymbol{\mu}\end{aligned}$$

よって、

$$\sum_{\boldsymbol{x} \in C_i} \|\boldsymbol{x} - \boldsymbol{\mu}_i\|^2 = \sum_{\boldsymbol{x} \in C_i} \boldsymbol{x}^T \boldsymbol{x} - |C_i| \boldsymbol{\mu}_i^T \boldsymbol{\mu}_i$$

$$\sum_{\boldsymbol{x} \in C_j} \|\boldsymbol{x} - \boldsymbol{\mu}_j\|^2 = \sum_{\boldsymbol{x} \in C_j} \boldsymbol{x}^T \boldsymbol{x} - |C_j| \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j$$

$$\sum_{\boldsymbol{x} \in C_{ij}} \|\boldsymbol{x} - \boldsymbol{\mu}_{ij}\|^2 = \sum_{\boldsymbol{x} \in C_{ij}} \boldsymbol{x}^T \boldsymbol{x} - |C_{ij}| \boldsymbol{\mu}_{ij}^T \boldsymbol{\mu}_{ij}$$

式変形 3

$$\begin{aligned} D(C_i, C_j) &:= \sum_{\boldsymbol{x} \in C_{ij}} \|\boldsymbol{x} - \boldsymbol{\mu}_{ij}\|^2 - \sum_{\boldsymbol{x} \in C_i} \|\boldsymbol{x} - \boldsymbol{\mu}_i\|^2 - \sum_{\boldsymbol{x} \in C_j} \|\boldsymbol{x} - \boldsymbol{\mu}_j\|^2 \\ &= \left(\sum_{\boldsymbol{x} \in C_{ij}} \boldsymbol{x}^T \boldsymbol{x} - |C_{ij}| \boldsymbol{\mu}_{ij}^T \boldsymbol{\mu}_{ij} \right) - \left(\sum_{\boldsymbol{x} \in C_i} \boldsymbol{x}^T \boldsymbol{x} - |C_i| \boldsymbol{\mu}_i^T \boldsymbol{\mu}_i \right) \\ &\quad - \left(\sum_{\boldsymbol{x} \in C_j} \boldsymbol{x}^T \boldsymbol{x} - |C_j| \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j \right) \\ &= -|C_{ij}| \boldsymbol{\mu}_{ij}^T \boldsymbol{\mu}_{ij} + |C_i| \boldsymbol{\mu}_i^T \boldsymbol{\mu}_i + |C_j| \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j \\ &= -|C_{ij}| \left(\frac{|C_i| \boldsymbol{\mu}_i + |C_j| \boldsymbol{\mu}_j}{|C_i| + |C_j|} \right)^T \left(\frac{|C_i| \boldsymbol{\mu}_i + |C_j| \boldsymbol{\mu}_j}{|C_i| + |C_j|} \right) + |C_i| \boldsymbol{\mu}_i^T \boldsymbol{\mu}_i + |C_j| \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j \\ &= \frac{|C_i| |C_j|}{|C_i| + |C_j|} (\boldsymbol{\mu}_i^T \boldsymbol{\mu}_i - 2\boldsymbol{\mu}_i^T \boldsymbol{\mu}_j + \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j) \\ &= \frac{|C_i| |C_j|}{|C_i| + |C_j|} \|\boldsymbol{\mu}_i - \boldsymbol{\mu}_j\|^2 \end{aligned}$$

階層的クラスタリングの特徴

- 樹形図で視覚的に捉えることができる。
- 学習後、任意のクラスタ数での分割結果を知ることができる。
- 各特徴量のスケールをあわせておく必要がある。特に情報が無ければ、各特徴量の平均が 0、分散が 1 になるように線形変換を行うことが多い。
- 最初に全データ間の距離の計算が必要 (データ数の 2 乗)。データ数が多くなると計算に時間がかかる (また、可視化も無意味になる)。
- ここではバラバラの状態からクラスタを作っていく「凝縮的クラスタリング」を説明したが、一つのクラスタにまとまった状態から分解していく「分割的クラスタリング」もある。

k 平均法

データ : $\{\mathbf{x}_d\}_{d \in [D]}$ $\mathbf{x}_d \in \mathbb{R}^n$

目的 : K 個のクラスタに分類したい (K は予め決めておいた数)

アイデア :

データ点が所属しているクラスタの代表点までの「距離」の和を最小化

- クラスタ k の代表点 : $\boldsymbol{\mu}_k \in \mathbb{R}^n$
- クラスタ k が属するデータ点の集合 : $C_k \subset \{\mathbf{x}_d\}_{d \in [D]}$

学習

変数は $\boldsymbol{\mu}_k$ と C_k ($k \in [K]$)

$$\begin{aligned} \min \quad & \sum_{k \in [K]} \sum_{\mathbf{x} \in C_k} d(\mathbf{x}, \boldsymbol{\mu}_k) \\ \text{s.t.} \quad & \bigcup_{k \in [K]} C_k = \{\mathbf{x}_d\}_{d \in [D]}, \\ & C_i \cap C_j = \emptyset \quad (i \neq j, i, j \in [K]). \end{aligned}$$

学習アルゴリズム

最適解を見つけることは難しい。

→ 近似最適解を計算する。

学習アルゴリズム

交互最適化

ステップ0 ランダムに μ_k を定める

ステップ1 $\mu_k \in \mathbb{R}^n$ を固定して、各データ点が属するクラスタを最適化

ステップ2 クラスタを固定して、 $\mu_k \in \mathbb{R}^n$ を最適化

ステップ3 目的関数値が変化しなければ終了。

そうでなければステップ1に戻る

- 「距離」として $d(x, y) := \|x - y\|^2$ を利用することが多い¹
- 以下では、この距離におけるアルゴリズムを説明する

¹ 距離の公理は満たしていないが、2点間の遠さを表す指標にはなる

ステップ1の説明

学習

変数は μ_k と C_k ($k \in [K]$)

$$\begin{aligned} & \min \sum_{k \in [K]} \sum_{\boldsymbol{x} \in C_k} d(\boldsymbol{x}, \boldsymbol{\mu}_k) \\ \text{s.t. } & \bigcup_{k \in [K]} C_k = \{\boldsymbol{x}_d\}_{d \in [D]}, \\ & C_i \cap C_j = \emptyset \quad (i \neq j, i, j \in [K]). \end{aligned}$$

μ_k は固定された状態で、各データ点が属するクラスタを最適化する。

- データ点 x_d は一番近い代表点 μ_k のクラスタに所属するのが最適。
- $k^* := \operatorname{argmin}_{k \in [K]} d(\boldsymbol{x}_d, \boldsymbol{\mu}_k)$ としたとき、 $\boldsymbol{x}_d \in C_{k^*}$

※ 一番近い代表点が 2つ以上あるときはランダムに選ぶ

ステップ2の説明

学習

変数： μ_k と C_k ($k \in [K]$)

$$\begin{aligned} & \min \sum_{k \in [K]} \sum_{\boldsymbol{x} \in C_k} d(\boldsymbol{x}, \boldsymbol{\mu}_k) \\ \text{s.t. } & \bigcup_{k \in [K]} C_k = \{\boldsymbol{x}_d\}_{d \in [D]}, \\ & C_i \cap C_j = \emptyset \quad (i \neq j, i, j \in [K]). \end{aligned}$$

クラスタは固定された状態で、 μ_k を最適化

クラスタごとに独立して最適化が可能

$$\min_{\boldsymbol{\mu}_k} \sum_{\boldsymbol{x} \in C_k} d(\boldsymbol{x}, \boldsymbol{\mu}_k)$$

$d(\boldsymbol{x}, \boldsymbol{y}) := \|\boldsymbol{x} - \boldsymbol{y}\|^2$ のときの最適解は平均ベクトル（重心）

$$\boldsymbol{\mu}_k^* := \frac{1}{|C_k|} \sum_{\boldsymbol{x} \in C_k} \boldsymbol{x}$$

ステップ2の説明

$$\begin{aligned} f(\boldsymbol{\mu}_k) &:= \sum_{\mathbf{x} \in C_k} \|\mathbf{x} - \boldsymbol{\mu}_k\|^2 = \sum_{\mathbf{x} \in C_k} (\mathbf{x} - \boldsymbol{\mu}_k)^T (\mathbf{x} - \boldsymbol{\mu}_k) \\ &= \sum_{\mathbf{x} \in C_k} (\boldsymbol{\mu}_k^T \boldsymbol{\mu}_k - 2\mathbf{x}^T \boldsymbol{\mu}_k + \mathbf{x}^T \mathbf{x}) \\ &= |C_k| \boldsymbol{\mu}_k^T \boldsymbol{\mu}_k - 2 \left(\sum_{\mathbf{x} \in C_k} \mathbf{x} \right)^T \boldsymbol{\mu}_k + \sum_{\mathbf{x} \in C_k} \mathbf{x}^T \mathbf{x} \end{aligned}$$

2次関数の微分を考える。

$$\nabla f(\boldsymbol{\mu}_k) = 2|C_k| \boldsymbol{\mu}_k - 2 \sum_{\mathbf{x} \in C_k} \mathbf{x}, \quad \nabla^2 f(\boldsymbol{\mu}_k) = 2|C_k| \mathbf{I}$$

$\nabla^2 f(\boldsymbol{\mu}_k)$ は半正定値なので、 $f(\boldsymbol{\mu}_k)$ は凸関数。

最適解の必要十分条件 $\nabla f(\boldsymbol{\mu}_k^*) = \mathbf{0}$ を解くと、

$$\boldsymbol{\mu}_k^* := \frac{1}{|C_k|} \sum_{\mathbf{x} \in C_k} \mathbf{x}$$

有限回の反復での終了

k 平均法は有限回の反復で終了する。

- ステップ1で各データ点の所属クラスタが決まれば、ステップ2で μ_k が決まり、ステップ3での目的関数値も一つに定まる
- データ点の所属クラスタのパターンは有限なので、ステップ3での目的関数値も有限個の異なる値しかとれない。
- ステップ1とステップ2では目的関数値は増えることはない。
- ステップ3時点での目的関数が変わらなければ終了。
減ったとしても、いずれ目的関数が変わらなくなり終了。

最適化アルゴリズムの実行例

赤いX：代表点、色：クラスタ。 左上が正解で、中上から先が k 平均法の各反復。





Figure: <http://taustation.com/k-means-clustering/>

最尤推定

データ点は K 個の多変量正規分布 $N(\boldsymbol{\mu}_k, \sigma^2 \mathbf{I})$ のどれかから生成された点であると考える。

データ点 \mathbf{x}_d がクラスタ k から生成される確率: $q_{dk} \in [0, 1]$

尤度関数

$$l(\mathcal{D}|\mathbf{U}, \mathbf{Q}) := \prod_{d \in [D]} \sum_{k \in [K]} q_{dk} \left\{ \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} (\mathbf{x}_d - \boldsymbol{\mu}_k)^T (\mathbf{x}_d - \boldsymbol{\mu}_k) \right\} \right\}$$

$$\mathbf{U} = \{\boldsymbol{\mu}_k\}_{k \in [K]}, \quad \mathbf{Q} \in \mathbb{R}^{D \times K}$$

尤度の最大化を考える。データ点 \mathbf{x}_d 毎に q_{dk} は最大化できる。

$$\begin{aligned} & \max_{q_{d1}, \dots, q_{dK}} \quad \sum_{k \in [K]} c_{dk} q_{dk} \\ \text{s.t.} \quad & \sum_{k \in [K]} q_{dk} = 1, \\ & 0 \leq q_{dk} \leq 1 \quad (k \in [K]). \end{aligned}$$

$$\text{ただし、 } c_{dk} := \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} (\mathbf{x}_d - \boldsymbol{\mu}_k)^T (\mathbf{x}_d - \boldsymbol{\mu}_k) \right\}$$

最尤推定 (続き)

この問題の最適値は $\max_{k \in [K]} c_{dk}$ である。

【証明】 前ページにある最適化問題の最適値を z^* とする。

- 最適解を $q_{dk}^* (k \in K)$ とする。

$$z^* := \sum_{k \in [K]} c_{dk} q_{dk}^* \leq \sum_{k \in [K]} \left(\max_{k' \in [K]} c_{dk'} \right) q_{dk}^*$$

$$= \max_{k' \in [K]} c_{dk'} \sum_{k \in [K]} q_{dk}^* = \max_{k' \in [K]} c_{dk'}$$

- $\widetilde{q}_{dk} := \begin{cases} 1 & (k = \operatorname{argmax}_{k' \in [K]} c_{dk'}) \\ 0 & (\text{o.w.}) \end{cases}$ とすると、実行可能解である。

そのときの目的関数値は $\sum_{k \in [K]} c_{dk} \widetilde{q}_{dk} = \max_{k' \in [K]} c_{dk'}$ となる。

よって、 $z^* \geq \max_{k' \in [K]} c_{dk'}$ と分かる。

以上より、 $z^* = \max_{k \in [K]} c_{dk}$ である。

最尤推定 (続き)

$$\max_{\boldsymbol{U}, \boldsymbol{Q}} l(\mathcal{D} | \boldsymbol{U}, \boldsymbol{Q})$$

$$\iff \max_{\boldsymbol{U}} \prod_{d \in [D]} \max_{k \in [K]} c_{dk}$$

$$\iff \max_{\boldsymbol{U}} \prod_{d \in [D]} \max_{k \in [K]} \left\{ \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} (\boldsymbol{x}_d - \boldsymbol{\mu}_k)^T (\boldsymbol{x}_d - \boldsymbol{\mu}_k) \right\} \right\}$$


$$\iff \max_{\boldsymbol{U}} \sum_{d \in [D]} \max_{k \in [K]} \left\{ -\frac{1}{2\sigma^2} (\boldsymbol{x}_d - \boldsymbol{\mu}_k)^T (\boldsymbol{x}_d - \boldsymbol{\mu}_k) \right\}$$

$$\iff \min_{\boldsymbol{U}} \sum_{d \in [D]} \min_{k \in [K]} (\boldsymbol{x}_d - \boldsymbol{\mu}_k)^T (\boldsymbol{x}_d - \boldsymbol{\mu}_k)$$

$$\iff \min_{\boldsymbol{U}} \sum_{d \in [D]} \min_{k \in [K]} d(\boldsymbol{x}_d, \boldsymbol{\mu}_k)$$

ユークリッド距離の2乗を用いた k 平均法は、この分布における最尤推定

計算例



当然だが、 k の指定によってクラスタリングは異なる

k 平均法の特徴

特徴

- 学習結果は初期点に依存するため、幾つか初期点から学習を行い、結果の良いもの（目的関数値の低いもの）を採用する。
- 予めクラスタ数 K を決めておく必要がある。
- 各特徴量のスケールをあわせておく必要がある。特に情報が無ければ、各特徴量の平均が 0、分散が 1 になるように線形変換を行うことが多い。
- 距離としてユークリッド距離の 2 乗を用いない場合は、代表点 μ_k の計算が難しくなる。

- ▶ $d(\mathbf{x}, \mathbf{y}) := \|\mathbf{x} - \mathbf{y}\|_1 = \sum_{i=1}^n |x_i - y_i|$ → 各次元でメディアンの計算
- ▶ $d(\mathbf{x}, \mathbf{y}) := \|\mathbf{x} - \mathbf{y}\|$ → Fermat-Weber 問題
- ▶ 一般の距離： 代表点をデータ点に限定する → K-medoid 法

計算時間の比較例

データ数	k 平均法 ($k = 10$)	階層的クラスタリング (Ward 法)
1.0×10^3	0.05s	0.08s
3.0×10^3	0.11s	0.68s
1.0×10^4	1.06s	10.9s
3.0×10^4	1.50s	68s
1.0×10^5	2.62s	メモリ不足
3.0×10^5	9.85s	
1.0×10^6	27.7s	
3.0×10^7	59.7s	
1.0×10^8	259s	

ソフトクラスタリング

混合モデル

- K 個の分布の中から一つが選ばれる。

k 番目の分布が選ばれる確率 : π_k

$$\boldsymbol{\pi} \geq 0, \quad \mathbf{e}^T \boldsymbol{\pi} = 1$$

- 選ばれた分布でデータが生成される。

$p(\mathbf{x}) := p_k(\mathbf{x}; \boldsymbol{\theta}_k) \quad \boldsymbol{\theta}_k$ は分布のパラメタ

$$(k \in [K])$$

確率密度 : $p(\mathbf{x}) := \sum_{k \in [K]} \pi_k p_k(\mathbf{x}; \boldsymbol{\theta}_k)$

例：混合正規分布の場合

$$p_k(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) := \frac{1}{(2\pi)^{n/2}} \frac{1}{\det(\boldsymbol{\Sigma}_k)^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x} - \boldsymbol{\mu}_k) \right\}$$

ソフトクラスタリング

\mathbf{x}_d が k 番目のクラスタ (分布) に属する確率

$$p(C_k | \mathbf{x}_d) = \frac{p(C_k) p(\mathbf{x}_d | C_k)}{\sum_{k' \in [K]} p(C_{k'}) p(\mathbf{x}_d | C_{k'})} = \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\theta}_{k'})}$$

パラメタの推定

独立にサンプリングされたデータ： $\mathcal{D} := \{\mathbf{x}_d\}_{d \in [D]}$

$$p(\mathcal{D}) = \prod_{d \in [D]} p(\mathbf{x}_d) = \prod_{d \in [D]} \sum_{k \in [K]} \pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$$

を最大にするパラメタ $\boldsymbol{\pi} \in \mathbb{R}^K, \boldsymbol{\theta}_k$ ($k \in [K]$) を見つける

対数尤度の最大化

変数： $\boldsymbol{\pi} \in \mathbb{R}^K, \boldsymbol{\theta}_k$ ($k \in [K]$)

$$\begin{aligned} & \max \quad \sum_{d \in [D]} \log \sum_{k \in [K]} \pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) \\ & \text{s.t.} \quad \mathbf{e}^T \boldsymbol{\pi} = 1, \quad \boldsymbol{\pi} \geq \mathbf{0}. \end{aligned}$$

この最適化問題の解法を幾つかの方向から考える。

最適性条件

最適解であるための必要条件 (証明は 2 ページ後)

$$r_{dk} = \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\theta}_{k'})} \quad (d \in [D], k \in [K]) \quad (1)$$

$$\pi_k = \frac{1}{D} \sum_{d \in [D]} r_{dk} \quad (k \in [K]) \quad (2)$$

$$\sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\theta}_k} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) = \mathbf{0} \quad (k \in [K]) \quad (3)$$

一般にこの方程式を解くことは容易ではない

→ 一部の変数を固定した方程式を解く

(1) $\pi, \boldsymbol{\theta}_k$ を固定して、 r_{dk} を計算

(2), (3) r_{dk} を固定して、 $\pi, \boldsymbol{\theta}_k$ を計算

最適化アルゴリズム

混合分布のパラメタ推定

ステップ0 初期点 $\pi, \boldsymbol{\theta}_k$ ($k \in [K]$) を決める。

ステップ1 $r_{dk} := \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\theta}_{k'})}$ ($d \in [D], k \in [K]$)

ステップ2 $\pi_k := \frac{1}{D} \sum_{d \in [D]} r_{dk}$ ($k \in [K]$)

ステップ3 次の方程式を $\boldsymbol{\theta}_k$ について解く ^a

$\sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\theta}_k} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) = \mathbf{0}$ ($k \in [K]$)

ステップ4 終了条件を満たしていなければ、ステップ1に戻る

^a解けるかどうかは p_k の形による。例えば正規分布の場合は簡単に計算できる。

最適性条件の証明 1

以下では、 $\boldsymbol{\theta} := \{\theta_k\}_{k \in [K]}$ とする。

ひとまず、不等式条件 $\boldsymbol{\pi} \geq \mathbf{0}$ は無視して、ラグランジュの未定乗数法を考える。

$$L(\boldsymbol{\pi}, \boldsymbol{\theta}, \lambda) := \sum_{d \in [D]} \log \sum_{k \in [K]} \pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) + \lambda(1 - \mathbf{e}^T \boldsymbol{\pi})$$

$$\nabla_\lambda L(\boldsymbol{\pi}, \boldsymbol{\theta}, \lambda) = 1 - \mathbf{e}^T \boldsymbol{\pi} = 0$$

より、 $\sum_{k \in [K]} \pi_k = 1$ だと分かる。

先に、次のように記号を定義する²。

$$r_{dk} := \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\theta}_{k'})} \quad (d \in [D], k \in [K])$$

² \mathbf{x}_d が k 番目の分布に属する確率 $P(C_k | \mathbf{x}_d)$

最適性条件の証明 2

$$\begin{aligned}\nabla_{\pi_k} L(\boldsymbol{\pi}, \boldsymbol{\theta}, \lambda) &= \sum_{d \in [D]} \frac{1}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\theta}_{k'})} p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) - \lambda \\ &= \sum_{d \in [D]} \frac{1}{\pi_k} r_{dk} - \lambda = 0\end{aligned}$$

より、 $\pi_k \lambda = \sum_{d \in [D]} r_{dk}$ であると分かる。両辺で $k \in [K]$ に対して和を取ると、

$$\begin{aligned}\sum_{k \in [K]} \pi_k \lambda &= \sum_{k \in [K]} \sum_{d \in [D]} r_{dk} \\ \lambda &= \sum_{d \in [D]} \sum_{k \in [K]} r_{dk} \quad (\because \sum_{k \in [K]} \pi_k = 1) \\ &= \sum_{d \in [D]} 1 = D \quad (\because \sum_{k \in [K]} r_{dk} = 1)\end{aligned}$$

最適性条件の証明 3

よって、 $\pi_k = \frac{1}{D} \sum_{d \in [D]} r_{dk}$ という関係が得られる。

このとき、 $\pi_k \geq 0$ であるから、非負条件は自動的に満たされる。

$$\begin{aligned}\nabla_{\boldsymbol{\theta}_k} L(\boldsymbol{\pi}, \boldsymbol{\theta}, \lambda) &= \sum_{d \in [D]} \frac{\pi_k}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\theta}_{k'})} \nabla_{\boldsymbol{\theta}_k} p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) \\ &= \sum_{d \in [D]} \frac{r_{dk}}{p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)} \nabla_{\boldsymbol{\theta}_k} p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) \\ &= \sum_{d \in [D]} r_{dk} \frac{\nabla_{\boldsymbol{\theta}_k} p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)} \\ &= \sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\theta}_k} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) = \mathbf{0}\end{aligned}$$

以上より、最適性条件を導くことができた³。

³逆に、得られた 3 つの条件から最初に述べた必要十分条件を導くこともできる

混合正規分布の場合

正規分布の場合

$$p_k(\boldsymbol{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) := \frac{1}{(2\pi)^{n/2}} \frac{1}{\det(\boldsymbol{\Sigma}_k)^{1/2}} \exp \left\{ -\frac{1}{2} (\boldsymbol{x} - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\boldsymbol{x} - \boldsymbol{\mu}_k) \right\}$$

方程式 $\sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\theta}_k} \log p_k(\boldsymbol{x}_d; \boldsymbol{\theta}_k) = \mathbf{0}$ の解は、次のようになる。

$$\boldsymbol{\theta}_k := \{\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$$

$$\boldsymbol{\mu}_k := \frac{\sum_{d \in [D]} r_{dk} \boldsymbol{x}_d}{\sum_{d \in [D]} r_{dk}} \quad (k \in [K])$$

$$\boldsymbol{\Sigma}_k := \frac{\sum_{d \in [D]} r_{dk} (\boldsymbol{x}_d - \boldsymbol{\mu}_k)(\boldsymbol{x}_d - \boldsymbol{\mu}_k)^T}{\sum_{d \in [D]} r_{dk}} \quad (k \in [K])$$

重み付き平均と重み付き分散共分散行列

証明は2ページ後

混合正規分布の場合

混合正規分布のパラメタ推定

ステップ0 初期点 $\pi, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k$ ($k \in [K]$) を決める。

ステップ1 $r_{dk} := \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{k' \in [K]} \pi_{k'} p_{k'}(\mathbf{x}_d; \boldsymbol{\mu}_{k'}, \boldsymbol{\Sigma}_{k'})}$ ($d \in [D], k \in [K]$)

ステップ2 $\pi_k := \frac{1}{D} \sum_{d \in [D]} r_{dk}$ ($k \in [K]$)

ステップ3 $\boldsymbol{\mu}_k := \frac{\sum_{d \in [D]} r_{dk} \mathbf{x}_d}{\sum_{d \in [D]} r_{dk}}$ ($k \in [K]$)

ステップ4 $\boldsymbol{\Sigma}_k := \frac{\sum_{d \in [D]} r_{dk} (\mathbf{x}_d - \boldsymbol{\mu}_k)(\mathbf{x}_d - \boldsymbol{\mu}_k)^T}{\sum_{d \in [D]} r_{dk}}$ ($k \in [K]$)

ステップ5 終了条件を満たしていなければ、ステップ1に戻る

$$p_k(\mathbf{x}_d; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) := \frac{1}{(2\pi)^{n/2}} \frac{1}{\det(\boldsymbol{\Sigma}_k)^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x}_d - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_d - \boldsymbol{\mu}_k) \right\}$$

証明 1

$$\log p_k(\mathbf{x}_d; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) = -\frac{n}{2} \log 2\pi - \frac{1}{2} \log \det \boldsymbol{\Sigma}_k - \frac{1}{2} (\mathbf{x}_d - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_d - \boldsymbol{\mu}_k)$$

であるので、

$$\sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\mu}_k} \log p_k(\mathbf{x}_d; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) = \sum_{d \in [D]} r_{dk} \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_d - \boldsymbol{\mu}_k) = \mathbf{0}$$

よって、

$$\sum_{d \in [D]} r_{dk} (\mathbf{x}_d - \boldsymbol{\mu}_k) = \mathbf{0}$$

$$\sum_{d \in [D]} r_{dk} \mathbf{x}_d = \sum_{d \in [D]} r_{dk} \boldsymbol{\mu}_k$$

$$\boldsymbol{\mu}_k = \frac{\sum_{d \in [D]} r_{dk} \mathbf{x}_d}{\sum_{d \in [D]} r_{dk}}$$

証明 2

$$\begin{aligned} & \sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\Sigma}_k} \log p_k(\mathbf{x}_d; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \\ &= \sum_{d \in [D]} \frac{r_{dk}}{2} \left(-\boldsymbol{\Sigma}_k^{-1} + \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_d - \boldsymbol{\mu}_k) (\mathbf{x}_d - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} \right) = \mathbf{O} \end{aligned}$$

$$\sum_{d \in [D]} r_{dk} \boldsymbol{\Sigma}_k = \sum_{d \in [D]} r_{dk} (\mathbf{x}_d - \boldsymbol{\mu}_k) (\mathbf{x}_d - \boldsymbol{\mu}_k)^T$$

$$\boldsymbol{\Sigma}_k = \frac{\sum_{d \in [D]} r_{dk} (\mathbf{x}_d - \boldsymbol{\mu}_k) (\mathbf{x}_d - \boldsymbol{\mu}_k)^T}{\sum_{d \in [D]} r_{dk}}$$

別の見方

必要条件の変数の一部を固定する方法では、反復が進んだときによいものになっているのか分からぬ。

同じ解法の別の解釈として、次の 2 つがある。

- 補助関数法
- 有限離散分布に対する EM アルゴリズム → 「生成モデル」で説明

以下で説明を行う。

補助関数法の導入

$$\max \sum_{d \in [D]} \log \sum_{k \in [K]} \pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$$

$f_0(x) := \log x$, $f_k(\boldsymbol{\theta}) := \pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$ とする。

- $-f_0(x)$ は凸関数（最大化なのでマイナスをつける）
- $f_k(\boldsymbol{\theta}) \geq 0 \quad (\forall \boldsymbol{\theta})$

補助関数法の話を適用すると、

- $\sum_{k \in [K]} r_{dk} = 1$, $r_{dk} \geq 0$ を満たす r_{dk} に対して、

$$\log \sum_{k \in [K]} \pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) \geq \sum_{k \in [K]} r_{dk} \log \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{r_{dk}}$$

- $r_{dk} := \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{\sum_{k' \in [K]} \pi_{k'} p_k(\mathbf{x}_d; \boldsymbol{\theta}_{k'})}$ のとき等号が成り立つ。

これを $d \in [D]$ に関する和として適用すると、補助関数法が適用できる。

補助関数法の内部で解く最適化問題

補助関数法のステップ 2

変数： π, θ_k ($k \in [K]$)

$$\begin{aligned} & \max \sum_{d \in [D]} \sum_{k \in [K]} r_{dk} \log \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{r_{dk}} \\ & \text{s.t. } \mathbf{e}^T \boldsymbol{\pi} = 1, \quad \boldsymbol{\pi} \geq \mathbf{0}. \end{aligned}$$

$$\begin{aligned} & \sum_{d \in [D]} \sum_{k \in [K]} r_{dk} \log \frac{\pi_k p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)}{r_{dk}} \\ &= \sum_{d \in [D]} \sum_{k \in [K]} r_{dk} (\log \pi_k + \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) - \log r_{dk}) \\ &= \sum_{k \in [K]} \left(\sum_{d \in [D]} r_{dk} \right) \log \pi_k + \sum_{k \in [K]} \left(\sum_{d \in [D]} r_{dk} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) \right) + \text{定数} \end{aligned}$$

1 + K 個の最適化問題に分割できる。

ステップ2での最適化

$$\begin{aligned} \text{問題 } A : \quad & \max_{\boldsymbol{\pi}} \sum_{k \in [K]} \left(\sum_{d \in [D]} r_{dk} \right) \log \pi_k \\ \text{s.t.} \quad & \mathbf{e}^T \boldsymbol{\pi} = 1, \quad \boldsymbol{\pi} \geq \mathbf{0}. \end{aligned}$$

$$\text{問題 } B_k : \quad \max_{\boldsymbol{\theta}_k} \sum_{d \in [D]} r_{dk} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$$

問題 A： 最適解は $\pi_k^* := \frac{1}{D} \sum_{d \in [D]} r_{dk} \quad (k \in [K])$ 証明は次ページ

問題 B_k ： 重み付き最尤推定

分布 $p_k(\mathbf{x}; \boldsymbol{\theta}_k)$ で、 $\{\mathbf{x}_d\}_{d \in [D]}$ のサンプルが得られたときの最尤推定は以下のもの

$$\max_{\boldsymbol{\theta}_k} \prod_{d \in [D]} p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) \iff \max_{\boldsymbol{\theta}_k} \sum_{d \in [D]} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$$

問題 A の最適解の証明

不等式条件 $\pi \geq \mathbf{0}$ は無視して、ラグランジュの未定乗数法を適用する。

$$L(\boldsymbol{\pi}, \lambda) := \sum_{k \in [K]} \left(\sum_{d \in [D]} r_{dk} \right) \log \pi_k + \lambda(1 - \mathbf{e}^T \boldsymbol{\pi})$$

$$\nabla_{\pi_k} L(\boldsymbol{\pi}, \lambda) = \left(\sum_{d \in [D]} r_{dk} \right) \frac{1}{\pi_k} - \lambda = 0 \quad (k \in [K])$$

$$\nabla_{\lambda} L(\boldsymbol{\pi}, \lambda) = 1 - \mathbf{e}^T \boldsymbol{\pi} = 0$$

上式より、

$$\begin{aligned} \lambda \pi_k &= \sum_{d \in [D]} r_{dk} \\ \sum_{k \in [K]} \lambda \pi_k &= \sum_{k \in [K]} \sum_{d \in [D]} r_{dk} \\ \lambda &= D \end{aligned}$$

よって、 $\pi_k = \frac{1}{D} \sum_{d \in [D]} r_{dk}$ となり、 $\pi \geq \mathbf{0}$ も満たすので最適解。

補助関数法

混合分布に対する補助関数法

ステップ0 初期点 π, θ_k ($k \in [K]$) を決める。

ステップ1 $r_{dk} := \frac{\pi_k p(\mathbf{x}_d; \boldsymbol{\theta}_k)}{\sum_{k' \in [K]} \pi_{k'} p(\mathbf{x}_d; \boldsymbol{\theta}_{k'})}$ $d \in [D], k \in [K]$

ステップ2

$$\pi_k := \frac{1}{D} \sum_{d \in [D]} r_{dk} \quad (k \in [K])$$

$k \in [K]$ に対して、重み付き最尤推定を行う。

$$\max_{\boldsymbol{\theta}_k} \sum_{d \in [D]} r_{dk} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$$

ステップ3 終了条件を満たしていなければ、ステップ1に戻る

補助関数法と変数固定法の関係

重み付き最尤推定問題： $\max_{\boldsymbol{\theta}_k} \sum_{d \in [D]} r_{dk} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k)$

最適解の必要条件は

$$\nabla_{\boldsymbol{\theta}_k} \sum_{d \in [D]} r_{dk} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) = \mathbf{0}$$

$$\sum_{d \in [D]} r_{dk} \nabla_{\boldsymbol{\theta}_k} \log p_k(\mathbf{x}_d; \boldsymbol{\theta}_k) = \mathbf{0}$$

この方程式を解くものと思えば、p.29 の解法と同じものになる。

k 平均法と混合ガウス分布の関係 1

k 平均法で解く最適化問題 (p.20)

変数： $\pi_d \in \mathbb{R}^K$ ($d \in [D]$), $\mu_k \in \mathbb{R}^n$ ($k \in [K]$)

$$\begin{aligned} & \max \quad \sum_{d \in [D]} \log \sum_{k \in [K]} [\pi_d]_k p_k(\mathbf{x}_d; \mu_k, \sigma^2 \mathbf{I}) \\ & \text{s.t.} \quad \mathbf{e}^T \pi_d = 1, \quad \pi_d \geq \mathbf{0} \quad (d \in [D]). \end{aligned}$$

混合ガウス分布での最適化問題と比較して、

- 分散共分散行列を $\sigma^2 \mathbf{I}$ で固定
- データ点ごとにカテゴリ分布 π を持つ

という違いがある。

混合正規分布 (p.27)

変数： $\pi \in \mathbb{R}^K$, $\mu_k \in \mathbb{R}^n$, $\Sigma_k \in \mathbb{R}^{n \times n}$ ($k \in [K]$)

$$\begin{aligned} & \max \quad \sum_{d \in [D]} \log \sum_{k \in [K]} \pi_k p_k(\mathbf{x}_d; \mu_k, \Sigma_k) \\ & \text{s.t.} \quad \mathbf{e}^T \pi = 1, \quad \pi \geq \mathbf{0}. \end{aligned}$$

k 平均法と混合ガウス分布の関係 2

別の関係性を考える。

混合ガウス分布において、正規分布のばらつきが極端に小さい状況を考える。
つまり、

$$\boldsymbol{\Sigma}_k = \lim_{\sigma^2 \rightarrow 0} \sigma^2 \mathbf{I}$$

とする。このとき、

$$\begin{aligned} r_{dk} &:= \lim_{\sigma^2 \rightarrow 0} \frac{\pi_k p(\mathbf{x}_d; \boldsymbol{\mu}_k, \sigma^2 \mathbf{I})}{\sum_{k' \in [K]} \pi_{k'} p(\mathbf{x}_d; \boldsymbol{\mu}_{k'}, \sigma^2 \mathbf{I})} \\ &= \begin{cases} 1 & (k = \underset{k' \in [K]}{\operatorname{argmax}} p(\mathbf{x}_d; \boldsymbol{\mu}_{k'}, \mathbf{I})) \\ 0 & (\text{o.w.}) \end{cases} \\ &= \begin{cases} 1 & (k = \underset{k' \in [K]}{\operatorname{argmin}} \|\mathbf{x}_d - \boldsymbol{\mu}_{k'}\|) \\ 0 & (\text{o.w.}) \end{cases} \end{aligned}$$

すると、p.34 のアルゴリズムは k 平均法のアルゴリズムと一致する。

ソフトクラスタリングの特徴

特徴

- 重み付きの最尤推定ができる分布ならば適用できる。
- k 平均法よりも柔軟にクラスタリングができる。
一方、解釈しづらくなる。
- 各クラスタ（分布）への所属確率をベクトルにして特徴量にすることも可能