

# 西南大學

## 本科生课程论文

论文题目： 基于 EM 算法的高斯混合模型聚类及应用

课程名称： 统计计算

任课教师： 刘传递

专 业： 统计学

班 级： 2020 级统计学

学 号： 222020314011081

姓 名： 余乐扬

2023 年 01 月 20 日

# 目录

1. 引言 .....	1
2. EM 算法 .....	1
2.1. EM 算法概述及思想 .....	1
2.1. EM 算法的实现与单调性 .....	1
3. EM 聚类理论 .....	2
3.1. 基于 GMM 的 EM 聚类思想与框架 .....	2
3.2. 基于 GMM 的 EM 聚类算法的实现 .....	3
3.2.1. 最大化 $\mu^k$ .....	3
3.2.2. 最大化 $\Sigma^k$ .....	3
3.2.3. 最大化 $\omega^k$ .....	3
3.2.4. 基于 GMM 的 EM 聚类算法的实现 .....	3
4. EM 聚类的应用 .....	4
参考文献 .....	4

# 基于 EM 算法的高斯混合模型聚类及应用

余乐扬

2020 级统计学

学号：222020314011081

**摘要**：EM 聚类作为一种强大且可靠的聚类算法如今已被广泛运用在各个场合，例如在模式识别、NLP、图像分割与情感分类等诸多领域中都有大量使用，而 EM 聚类的基础 EM 算法本身便是无监督学习中的经典方法。所有 EM 聚类算法中应用最为广泛的是基于高斯混合模型的 EM 聚类算法，得益于正态分布优秀的理论性质与 EM 算法的泛用性，EM 聚类通常能在有限时间内完成，且效果较佳。EM 算法与 EM 聚类有较强的统计学理论支持，本文通过系统解析 EM 算法，进而导出将 EM 算法应用于聚类的理论推理。

**关键词**：聚类分析；无监督学习；EM 算法；高斯混合模型

## 1. 引言

EM 聚类算法基于 EM 算法（Expectation-Maximization Algorithm，期望最大化算法）实现，是一种强力而行之有效的聚类算法，常配合高斯混合模型进行聚类。由于正态分布及高斯混合分布的优良性质，一般能取得较为理想的聚类效果。

EM 算法长期在“机器学习十大算法”评比中榜上有名，是极其受欢迎的一种经典算法，而 EM 聚类亦是被广泛运用在各个领域，因此研究 EM 算法与基于高斯混合模型的 EM 聚类算法是有必要的。

记  $p$  元正态分布 PDF 为  $\mathcal{N}$ ，GMM（高斯混合模型）：

$$\begin{cases} p(\boldsymbol{\theta}) = \sum_{i=1}^N \omega_i \mathcal{N}_p(\boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i) \\ \sum_{i=1}^N \omega_i = 1 \end{cases} \quad (1)$$

## 2. EM 算法

EM 聚类基于 EM 算法实现，研究 EM 聚类便不得不研究 EM 算法。

### 2.1. EM 算法概述及思想

EM 算法是一种用以寻求参数  $\boldsymbol{\theta}$  的极大似然估计或最大后验估计的优化迭代策略。通过考虑缺失数据，避开直接处理似然函数  $L(\boldsymbol{\theta}|\mathbf{x})$  迭代求解，转而利用较容易得到的密度函数  $f_{(X,Z)|\boldsymbol{\theta}}(\mathbf{x}, \mathbf{z}|\boldsymbol{\theta})$  与  $f_{Z|(X,\boldsymbol{\theta})}(\mathbf{z}|\mathbf{x}, \boldsymbol{\theta})$  间接地迭代求解。

通过这种方式，EM 算法能简单地被执行并在保证每一步均单调上升的情况下，可靠地优化到局部最优解。

EM 算法是一种非梯度算法、典型的单调算法<sup>[1]</sup>，但这不能使 EM 算法保证收敛到全局最优解，譬如对于多峰的分布很可能会收敛到局部最优解，这是 EM 算法显著的不足。不过，针对 GMM 这一劣势不存在。

本文用  $\boldsymbol{\theta}$  表示待估参数，假设完全数据由随机向量  $\mathbf{Y} = (\mathbf{X}, \mathbf{Z})$  产生，其中观测数据样本  $\mathbf{x}$  由随机变（向）量  $\mathbf{X}$  产生，缺失数据  $\mathbf{z}$  由随机变（向）量  $\mathbf{Z}$  产生，并称  $\mathbf{Z}$  为隐变量（Latent Variable），容易导出：

$$f_{Z|(X,\boldsymbol{\theta})}(\mathbf{z}|\mathbf{x}, \boldsymbol{\theta}) = \frac{f_{Y|\boldsymbol{\theta}}(\mathbf{y}|\boldsymbol{\theta})}{f_{X|\boldsymbol{\theta}}(\mathbf{x}|\boldsymbol{\theta})} \quad (2)$$

用  $Q(\boldsymbol{\theta}|\boldsymbol{\theta}_i)$  表示在  $\mathbf{X} = \mathbf{x}$  与  $\boldsymbol{\theta}_i$  条件下，完全数据  $\mathbf{Z}$  的参数  $\boldsymbol{\theta}$  的联合对数似然函数的条件期望：

$$\begin{aligned} Q(\boldsymbol{\theta}|\boldsymbol{\theta}_i) &= \mathbb{E}_Z(\log L(\boldsymbol{\theta}|\mathbf{Y}) | \mathbf{x}, \boldsymbol{\theta}_i) \\ &= \mathbb{E}_Z(\log f_{Y|\boldsymbol{\theta}}(\mathbf{y}|\boldsymbol{\theta}) | \mathbf{x}, \boldsymbol{\theta}_i) \end{aligned} \quad (3)$$

由条件期望公式，有：

$$\begin{aligned} Q(\boldsymbol{\theta}|\boldsymbol{\theta}_i) &= \mathbb{E}_Z(l(\boldsymbol{\theta}|\mathbf{Y}) | \mathbf{x}, \boldsymbol{\theta}_i) \\ &= \int_Z [\log f_{Y|\boldsymbol{\theta}}(\mathbf{y}|\boldsymbol{\theta})] [f_{Z|(X,\boldsymbol{\theta})}(\mathbf{z}|\mathbf{x}, \boldsymbol{\theta}_i)] d\mathbf{z} \end{aligned} \quad (4)$$

上式强调了当给定  $\mathbf{X} = \mathbf{x}$ ， $\mathbf{Z}$  便是  $\mathbf{Y}$  中唯一随机的部分（因为“未知”而导致的随机）。

缺失数据可能并不是真的缺失了，他可能只是为了简化问题而引进的；通过隐变量  $\mathbf{Z}$ ，EM 算法将收敛到关于  $\mathbf{X}$  的参数  $\boldsymbol{\theta}$  MLE 某个局部最优解。

### 2.1. EM 算法的实现与单调性

EM 算法的根本目的是寻找一个使得似然函数  $L(\boldsymbol{\theta}|\mathbf{x})$  最大化的参数  $\boldsymbol{\theta}$ ，即 MLE。由于通过传统统计分析方法直

接求解 MLE 解析解在很多情况下并不方便, 考虑通过迭代算法解出可接受误差范围内的数值解。利用相对容易得到的  $f_{(X,Z)|\theta}(x, \mathbf{z}|\theta)$  和  $f_{Z|(X,\theta)}(\mathbf{z}|x, \theta)$ , 可以间接地求出使得  $L(\theta|x)$  最大化的  $\theta$ 。

EM 算法的一般步骤分为 E 步与 M 步, 通常的改进都是基于这两个步骤的<sup>[5][6]</sup>: 以  $\theta_0$  为初始值, 令  $t = 0$ ,

- E 步: 基于  $\theta_t$  计算  $Q(\theta|\theta_t)$ ;
- M 步:  $\theta_{t+1} = \arg \max_{\theta} Q(\theta|\theta_t)$ , 转步 E 步并令  $t \leftarrow t + 1$  直至收敛。

EM 算法可以被解释为一种坐标下降法<sup>[1]</sup>, 因为每次更新一些参数时, 另一些参数是固定的: 更新部分参数时, 利用未更新参数更新。

EM 算法单调性: 由于

$$\begin{aligned} l(\theta|x) &= \mathbb{E}_Z(l(\theta|x)|x, \theta_i) \\ &= \mathbb{E}_Z\left(\log \frac{f_{Y|\theta}(y|\theta)}{f_{Z|(X,\theta)}(\mathbf{z}|x, \theta)} \middle| x, \theta_i\right) \\ &= Q(\theta|\theta_i) - \mathbb{E}_Z(\log f_{Z|(X,\theta)}(\mathbf{z}|x, \theta) | x, \theta_i) \end{aligned} \quad (5)$$

因此定义  $H(\theta|\theta_i) = \mathbb{E}_Z(\log f_{Z|(X,\theta)}(\mathbf{z}|x, \theta) | x, \theta_i)$ ,

$$\begin{aligned} l(\theta_{i+1}|x) - l(\theta_i|x) &= \mathbb{E}_Z(l(\theta_{i+1}|x)|x, \theta_i) - \mathbb{E}_Z(l(\theta_i|x)|x, \theta_i) \\ &= [Q(\theta_{i+1}|\theta_i) - Q(\theta_i|\theta_i)] - [H(\theta_{i+1}|\theta_i) - H(\theta_i|\theta_i)] \end{aligned} \quad (6)$$

其中  $Q(\theta_{i+1}|\theta_i) - Q(\theta_i|\theta_i) \geq 0$ , 这是 EM 算法的 M 步保证的; 故只需要说明  $\forall \tilde{\theta} \in \Theta, -[H(\tilde{\theta}|\theta_i) - H(\theta_i|\theta_i)] \geq 0$  则可证明 EM 的单调性:

$$\begin{aligned} & -[H(\tilde{\theta}|\theta_i) - H(\theta_i|\theta_i)] \\ &= \mathbb{E}_Z\left(\log \frac{f_{Z|(X,\theta)}(\mathbf{z}|x, \tilde{\theta})}{f_{Z|(X,\theta)}(\mathbf{z}|x, \theta_i)} \middle| x, \theta_i\right) \\ &= \int_Z -\log \frac{f_{Z|(X,\theta)}(\mathbf{z}|x, \tilde{\theta})}{f_{Z|(X,\theta)}(\mathbf{z}|x, \theta_i)} f_{Z|(X,\theta)}(\mathbf{z}|x, \theta_i) dz \\ &\geq -\log \int_Z f_{Z|(X,\theta)}(\mathbf{z}|x, \theta_i) dz \quad (\text{Jensen不等式}) \\ &= -\log 1 = 0 \end{aligned} \quad (7)$$

从信息论角度观察, (7) 实质是 Gibbs 不等式的运用。

针对 EM 算法的不足, 国内外基于传统 EM 算法已提出 PX-EM 算法、ECME 算法、MCEM 算法等诸多 EM 算法的改良版本。

记  $\theta^*$  为 EM 算法的不动点、收敛的局部最优解, EM 算法的收敛阶定义为:

$$\rho = \lim_{i \rightarrow \infty} \frac{\|\theta_{i+1} - \theta^*\|}{\|\theta_i - \theta^*\|} \quad (8)$$

除了应用于聚类分析, 在 NLP、图像分割、机器学习 (如 HMM、LDA 变分推断) 与计算机图形学等诸多领域中 EM 算法都表现出了强大的效力<sup>[5]</sup>。关于应用场景将在后文提到。

### 3. EM 聚类理论

EM 算法作为一个“框架”可以被应用在多个场合, EM 聚类则是 EM 算法的一个典型应用。EM 聚类通常考虑某类模型作为条件或假设, 如参数未知的 GMM (高斯混合模型)、隐马尔可夫过程, 因此这是一种参数化的方法。通过 EM 算法解出这些参数 (的 MLE), 故这种聚类算法被称为 EM 聚类算法。

#### 3.1. 基于 GMM 的 EM 聚类思想与框架

需要解释的是为什么考虑 EM 算法: 试图直接对  $L(\theta|X)$  偏导以得到参数解析解是极其麻烦的, 即使模型已知 (以(1)为定义的 GMM), 记第  $j$  个正态分布均值向量为  $\mu_j$ 、协方差阵为  $\Sigma_j$ , 用  $n$  表示样本量:

$$\begin{aligned} l(\theta|X) &= \log \prod_{i=1}^n P_{GMM}(x_i|\theta) \\ &= \sum_{i=1}^n \log \sum_{j=1}^N \omega_j P(x_i|\theta) \\ &= \sum_{i=1}^n \log \sum_{j=1}^N \omega_j \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma_j|} \exp\left(-\frac{1}{2}(x_i - \mu_j)^T \Sigma_j^{-1} (x_i - \mu_j)\right) \end{aligned} \quad (9)$$

(9) 式难以直接优化求解, 因此考虑在 GMM 聚类中应用 EM 算法的想法是自然的<sup>[1]</sup>。

此外, 值得说明的是 EM 算法的运用: 如果某样本最可能是由第  $z$  个总体产生的, 则他应该被归为第  $z$  个集群, 这等价于通过最大后验概率确定样本所属的聚类。引入隐变量  $Z = (z_1, z_2, \dots, z_n)$  代表所属类别, 令第  $i$  个样本点具有隐变量  $z_i = j$ , 即第  $i$  个样本点属于第  $j$  类, 由此类比(9)可以写出  $l(\theta|Y)$  具体形式:

$$\begin{aligned} l(\theta|Y) &= \log \prod_{i=1}^n P_{GMM}(z_i, x_i|\theta) \\ &= \sum_{i=1}^n \log (\omega_{z_i} P(z_i, x_i|\theta)) \end{aligned} \quad (10)$$

其中  $P_{GMM}(z_i, x_i|\theta)$  代表从属 GMM 的随机变量  $X_i = x_i$  且属第  $z_i$  集群的概率,  $P(z_i, x_i|\theta)$  代表从属第  $i$  个集群的随机变量  $X_i = x_i$  的概率。

由(4)可知, 在  $X$  确定时  $Z$  是唯一的变量, 故(10)式对  $Z$  取条件期望 (实质是对  $Z$  积分), 得到  $Q(\theta|\theta_t)$ :

$$\begin{aligned} Q(\theta|\theta_t) &= \mathbb{E}_Z(l(\theta|Y)|x, \theta_t) \\ &= \sum_Z l(\theta|Y) P(Z|x, \theta_t) \\ &= \sum_Z \sum_{i=1}^n \log (\omega_{z_i} P(z_i, x_i|\theta)) P(Z|x_i, \theta_t) \\ &= \sum_{j=1}^N \sum_{i=1}^n \log (\omega_j P(j, x_i|\theta)) P(j|x_i, \theta_t) \end{aligned} \quad (11)$$

为计算 $P(j|x_i, \theta_t)$ ，应用Bayes公式：

$$P(j|x_i, \theta_t) = \frac{P(j, x_i|\theta_t)}{\sum_{k=1}^N P(k, x_i|\theta_t)} \quad (12)$$

由(11)与(12)，至此得到了可运用EM算法的GMM下EM聚类的理论更新算法：

首先设置初始簇数 $N$ （可以参考K-Means的结果），并分别用随机的正态分布参数 $\mu_j^{(0)}$ 、 $\Sigma_j^{(0)}$ 与 $\omega_j$ 初始化第 $i$ 个簇（可以通过样本数据为这些正态分布提供一个良好的假设参数，但这不是必要的，因为EM聚类算法可以在较少的步骤内迅速优化这些参数），令 $t=0$ 、所有的参数集结为 $\theta_0$ ，记：

$$Q_{GMM}(\theta|\theta_t) = \sum_{j=1}^N \sum_{i=1}^n \log(\omega_j P(j, x_i|\theta)) \frac{P(j, x_i|\theta_t)}{\sum_{k=1}^N P(k, x_i|\theta_t)} \quad (13)$$

- E步：基于 $\theta_t$ 计算 $Q_{GMM}(\theta|\theta_t)$ ；
- M步： $\theta_{t+1} = \arg \max_{\theta} Q_{GMM}(\theta|\theta_t)$ ，转步E步并令 $t \leftarrow t+1$ 直至收敛。

### 3.2. 基于GMM的EM聚类算法的实现

鉴于本文的研究对象是针对GMM的EM聚类，基于GMM可以进一步具体地导出具体的更新算法，这主要体现在M步上。

首先对 $Q(\theta|\theta_t)$ 分解<sup>[7]</sup>：

$$q_1(\theta|\theta_t) = \sum_{j=1}^N \sum_{i=1}^n \log(\omega_j) P(j|x_i, \theta_t) \quad (14)$$

$$q_2(\theta|\theta_t) = \sum_{j=1}^N \sum_{i=1}^n \log(P(j, x_i|\theta)) P(j|x_i, \theta_t) \quad (15)$$

易见有 $Q(\theta|\theta_t) = (15) + (16)$ ；

#### 3.2.1. 最大化 $\mu_k$

$$\begin{aligned} \frac{\partial Q(\theta|\theta_t)}{\partial \mu_k} &= \frac{\partial q_2(\theta|\theta_t)}{\partial \mu_k} \\ &= \frac{\partial}{\partial \mu_k} \sum_{i=1}^n \log(P(k, x_i|\theta)) P(k|x_i, \theta_t) \end{aligned} \quad (16)$$

$$\begin{aligned} &= - \sum_{i=1}^n \Sigma_k^{-1} (x_i - \mu_k^{(t)}) P(k|x_i, \theta_t) \\ &\stackrel{let}{=} 0 \\ \Rightarrow \mu_k^{(t)} &= \frac{\sum_{i=1}^n x_i P(k|x_i, \theta_t)}{\sum_{i=1}^n P(k|x_i, \theta_t)} \end{aligned} \quad (17)$$

多个一元正态分布组合而成的GMM情况：

$$\mu_k^{(t)} = \frac{\sum_{i=1}^n x_i P(k|x_i, \theta_t)}{\sum_{i=1}^n P(k|x_i, \theta_t)} \quad (18)$$

其中：

$$P(k, x_i|\theta) = \omega_k \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma_k|} \exp\left(-\frac{1}{2} (x_i - \mu_k)^T \Sigma_k^{-1} (x_i - \mu_k)\right) \quad (19)$$

#### 3.2.2. 最大化 $\Sigma_k$

同理于3.2.1.：

$$\begin{aligned} \frac{\partial Q(\theta|\theta_t)}{\partial \Sigma_k} &= \frac{\partial q_2(\theta|\theta_t)}{\partial \Sigma_k} \stackrel{let}{=} 0 \\ &\Leftrightarrow \sum_{i=1}^n ((x_i - \mu_k)(x_i - \mu_k)^T - \Sigma_k^{(t)}) P(k|x_i, \theta_t) \stackrel{let}{=} 0 \end{aligned} \quad (20)$$

$$\Rightarrow \Sigma_k^{(t)} = \frac{\sum_{i=1}^n P(k|x_i, \theta_t) (x_i - \mu_k)(x_i - \mu_k)^T}{\sum_{i=1}^n P(k|x_i, \theta_t)} \quad (21)$$

多个一元正态分布组合而成的GMM情况：

$$\sigma_k^{2(t)} = \frac{\sum_{i=1}^n (x_i - \mu_k)^2 P(k|x_i, \theta_t)}{\sum_{i=1}^n P(k|x_i, \theta_t)} \quad (22)$$

#### 3.2.3. 最大化 $\omega_k$

$$\begin{aligned} \frac{\partial Q(\theta|\theta_t)}{\partial \omega_k} &= \frac{\partial q_1(\theta|\theta_t)}{\partial \omega_k} \\ &= \frac{\partial}{\partial \omega_k} \sum_{i=1}^n \log(\omega_j) P(j|x_i, \theta_t) \\ &= \sum_{i=1}^n \frac{1}{\omega_k} P(k|x_i, \theta_t) \\ &\stackrel{let}{=} 0 \end{aligned} \quad (23)$$

由于存在 $\sum_{i=1}^n \omega_i = 1$ 的限制，因此与(24)联立解得：

$$\Rightarrow \omega_k^{(t)} = \frac{\sum_{i=1}^n P(k|x_i, \theta_t)}{n} \quad (24)$$

多个一元正态分布组合而成的GMM情况：

$$\omega_k^{(t)} = \frac{\sum_{i=1}^n P(k|x_i, \theta_t)}{n} \quad (25)$$

#### 3.2.4. 基于GMM的EM聚类算法的实现

综上所述，由(17)、(21)和(24)可以直接计算出M步更新参数的大小，注意到式中唯一非源自原始样本数据的统计量 $P(k|x_i, \theta_t)$ 根据Bayes公式也是可计算的<sup>[7]</sup>，即(12)式。

$$P(k|x_i, \theta_t) = \frac{P(k, x_i|\theta_t)}{\sum_{j=1}^N P(j, x_i|\theta_t)}$$

综上所述，首先通过3.1.中的方法初始化参数，接下来进行迭代：

- E步： $\forall k \leq n$ ，计算 $P(k|x_i, \theta_t) = \frac{P(k, x_i|\theta_t)}{\sum_{j=1}^N P(j, x_i|\theta_t)}$ ；
- M步： $\forall k \leq n$ ，计算 $\mu_k^{(t)}$ 、 $\Sigma_k^{(t)}$ 与 $\omega_k^{(t)}$ ，转步E步并令 $t \leftarrow t+1$ 直至收敛，其中：

$$\begin{cases} \mu_k^{(t)} = \frac{\sum_{i=1}^n x_i P(k|x_i, \theta_t)}{\sum_{i=1}^n P(k|x_i, \theta_t)} \\ \Sigma_k^{(t)} = \frac{\sum_{i=1}^n P(k|x_i, \theta_t) (x_i - \mu_k)(x_i - \mu_k)^T}{\sum_{i=1}^n P(k|x_i, \theta_t)} \\ \omega_k^{(t)} = \frac{\sum_{i=1}^n P(k|x_i, \theta_t)}{n} \end{cases} \quad (26)$$

可以看出, EM 聚类算法实质是在每个总体都服从一个正态分布的假定下, 通过 EM 算法解出这些正态总体的均值向量 $\{\mu_i\}_{i=1}^N$ 与协方差阵 $\{\Sigma_i\}_{i=1}^N$ 。

值得一提的是, 从 EM 聚类的实现思路上看可以看出 EM 聚类算法是一种软聚类算法, 这意味着 EM 算法是将数据以一定的概率分配到各集群中的, 一个样本点可能以不同的概率(程度)从属于不同的集群: EM 聚类算法只讨论某个样本点属于任意一个集群的概率, 而不限制一个样本点只能属于一个簇。因此, EM 聚类算法是一种基于统计模型的、基于概率的聚类算法<sup>[4]</sup>, 这与诸多硬聚类算法有本质不同。

## 4. EM 聚类的应用

理论上, 足够复杂的 GMM 可以在任意精度内拟合任何分布<sup>[2]</sup>, 因此 GMM 是一种非常强大的模型。基于 GMM 的 EM 聚类算法在今天得到广泛关注, 与 GMM 和 EM 算法本身的性质密不可分。

相比其他聚类算法 EM 聚类有许多优势<sup>[3]</sup>, 下主要将 EM 聚类与 K-Means 算法对比以说明 EM 聚类的长处。

- 1) 较之 K-Means 算法, EM 聚类算法不仅考虑“距离”(通过集群正态分布的均值), 还考虑了分布的形状(通过集群正态分布的协方差阵控制), 这使得在面临一些并非呈圆或球体分布的样本时 EM 聚类表现更好, 应对复杂分布的适应性更强<sup>[3]</sup>, 而传统 K-Means 的效果较差(这时除了 EM 聚类, 还可以考虑基于密度的聚类算法)。
- 2) 由于 EM 聚类属软聚类算法, 在多个集群距离较近时仍能有很好的聚类效果<sup>[6]</sup>, 而 K-Means 在质心较近时则表现糟糕。
- 3) 算法步骤并不复杂, EM 算法的单调性使得每一次的迭代值都稳定上升, 最终收敛到最优解, 尽管这个最优解可能是局部的。
- 4) 相对而言对初始值不太敏感(GMM), 人为设置参数的影响小, EM 算法的更新参数会在若干步骤内很快收敛到可接受误差范围内, 相对而言 K-Means 算法对初始值依赖极其严重。
- 5) 算法运行中占用存储空间小。

同时, EM 聚类也有一些不足之处, 其中部分问题可以通过改进 EM 算法解决, 部分问题至今尚未有泛用的应对办法。

- 1) 噪声、离群点对结果可能有明显影响, 这与 K-Means 算法的劣势一致, 一些基于密度的聚类算法能解决这个问题<sup>[5]</sup>。
- 2) 计算量相对较大, 导致不能很好处理大样本与高维数据, 这时可以考虑一些 EM 算法的改进算法<sup>[5][6]</sup>。

## 参考文献

- [1] Jeff A. Bilmes, "A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models"[J], *International Computer Science Institute*, 1998
- [2] Miin-Shen Yang, Chien-Yo Lai and Chih-Ying Lin, "A robust EM clustering algorithm for Gaussian mixture models"[J], *Pattern Recognition*, vol 1, no, 2012, pp 3950–3961
- [3] Osama Abu Abbas, "Comparisons Between Data Clustering Algorithms"[J], *The International Arab Journal of Information Technology*, vol 5, no. 3, pp 320-325, July, 2008
- [4] 李世锋, 文志强, 吴岳忠, 基于改进的 GMM 参数估计的目标检测方法[J], *重庆工商大学学报(自然科学版)*, 2013, 30(05): 30-36.
- [5] 史鹏飞, 基于改进 EM 算法的混合模型参数估计及聚类分析[D], 西北大学, 2009
- [6] 王凯南, 金立左, 基于高斯混合模型的 EM 算法改进与优化[J], *工业控制计算机*, 2017, 30(05): 115-116+118
- [7] 张宏东, EM 算法及其应用[D], 山东大学, 2014