

DOI: 10.11992/tis.201703031

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20171109.1250.004.html>

## 多视角模糊双加权可能性聚类算法

蒋亦樟<sup>1</sup>, 朱丽<sup>1</sup>, 刘丽<sup>2</sup>, 王士同<sup>1</sup>

(1. 江南大学 数字媒体学院, 江苏 无锡 214122; 2. 江苏信息职业技术学院 物联网工程学院, 江苏 无锡 214153)

**摘要:**为解决传统可能性聚类算法(PCM)无法满足多视角学习场景聚类的实际问题,并进一步考虑到现有多视角聚类算法尚未重视的视角权重及视角内特征权重优化问题,本文提出一种新的具备最佳视角及最优特征划分能力的多视角模糊双加权可能性聚类算法(MV-FDW-PCM)。该算法将基于传统的 PCM 算法,给出了详细的多视角聚类学习框架使得 PCM 算法具备多视角聚类能力,进而通过引入视角间模糊加权机制及视角内属性模糊加权机制解决视角间权重及视角内特征权重优化问题。实验结果表明,所提的 MV-FDW-PCM 算法在面对多视角聚类问题时较以往算法具有更佳的聚类效果。

**关键词:**多视角聚类; 视角间模糊加权; 视角内属性模糊加权; 可能性聚类

**中图分类号:** TP181 **文献标志码:** A **文章编号:** 1673-4785(2017)06-0806-10

中文引用格式: 蒋亦樟, 朱丽, 刘丽, 等. 多视角模糊双加权可能性聚类算法[J]. 智能系统学报, 2017, 12(6): 806-815.

英文引用格式: JIANG Yizhang, ZHU Li, LIU Li, et al. Multi-view fuzzy double-weighting possibility clustering algorithm[J]. CAAI transactions on intelligent systems, 2017, 12(6): 806-815.

## Multi-view fuzzy double-weighting possibility clustering algorithm

JIANG Yizhang<sup>1</sup>, ZHU Li<sup>1</sup>, LIU Li<sup>2</sup>, WANG Shitong<sup>1</sup>

(1. School of Digital Media, Jiangnan University, Wuxi 214122, China; 2. School of Internet of Things Engineering, Jiangsu Vocational College of Information Technology, Wuxi 214153, China)

**Abstract:** To solve the problem that traditional possibility clustering algorithms (PCM) barely achieve multi-view clustering, and considering that the optimization of views and feature weights has not been regarded as important in existing multi-view clustering algorithms, this paper proposes a new multi-view fuzzy double-weighted possibility clustering algorithm (MV-FDW-PCM). The algorithm is based on the traditional PCM algorithm, and it gives a detailed multi-view clustering learning framework, which gives it its own multi-view clustering ability. It realizes the optimization of the weight of view and the feature weight within the view by the introduction of an inter-view fuzzy weighting mechanism and an inside-view attribute fuzzy weighting mechanism. The experimental results show that the proposed MV-FDW-PCM algorithm has better clustering performance than the previous algorithms regarding multi-view clustering.

**Keywords:** multi-view clustering; fuzzy weighting between views; fuzzy weighting of attribute within views; possibilistic clustering

聚类分析作为一种常见的无监督学习数据预处理方法,在数据挖掘、文件恢复、图像分割及模式分类等领域有着广泛的应用基础。随着现代技术发展

的不断更新,传统的聚类模式已不再适应新的学习场景,如多视角学习场景<sup>[1-5]</sup>、迁移学习场景<sup>[6-9]</sup>、多任务学习场景<sup>[10-11]</sup>及子空间学习场景<sup>[12]</sup>等。本文将主要关注多视角学习场景,进而针对传统聚类模型如何在多视角学习场景下更好地学习优化及应用展开探讨。

对于传统聚类方法,主要有以 FCM(fuzzy c-

收稿日期: 2017-03-23. 网络出版日期: 2017-11-09.

基金项目: 国家自然科学基金项目(61300151, 61702225); 江苏省自然科学基金项目(BK20160187); 中央高校基本科研业务费基金项目(JUSRP11737).

通信作者: 蒋亦樟. E-mail: 241519405@qq.com.

means) 算法<sup>[13-16]</sup>为代表的划分型聚类算法, 还有以 AP(affinity propagation) 算法<sup>[17-18]</sup>为代表的图论型聚类算法等。相对于其他聚类模型, 基于划分的聚类算法模型结构简单, 优化过程亦不复杂, 经常被用于实际应用。但在以 FCM 算法为族群的各种基于划分的算法中, 如 MEC(maximum entropy clustering, MEC) 算法<sup>[19-20]</sup>及 PCM(possibilistic c-means) 算法<sup>[21-22]</sup>等, 经实验验证 PCM 算法较之其他算法具备更好的噪声及孤立点鲁棒性, 因此本文将以经典 PCM 算法模型为理论基础开展其在多视角学习场景下的模型优化及应用问题的研究。

目前针对多视角聚类问题, 已有一些代表性的工作<sup>[2-5]</sup>被提出, 如: 1) 基于概率论方法的多视角协同聚类 Co-EM(collaborative expectation maximization) 算法<sup>[2]</sup>; 2) 基于 FCM 算法模型的 Co-FC(collaborative fuzzy clustering) 算法<sup>[3]</sup>; 3) 针对 Co-FC 算法改进的 Co-FKM(collaborative fuzzy k-means) 算法<sup>[4]</sup>; 4) Tzortzis 等<sup>[5]</sup>基于核聚类方法提出的两种多视角聚类算法 MVKKM(multi-view kernel k-means) 和 MVSpec(multi-view spectral clustering)。尽管上述方法已使得一些传统聚类算法获得了多视角聚类的能力, 但各方法在视角权重和视角内特征权重优化问题上的考量还是欠缺的, 如基于协同学习思想提出的 Co-EM、Co-FC 及 Co-FKM 算法均未考虑视角权重和视角内特征权重优化问题, 而 MVKKM 和 MVSpec 算法仅管采用了视角权重优化方法但在视角内特征权重优化问题上又未涉及。此外, 上述大部分的算法是以 FCM 算法为基础提出的, 鲁棒性较一般。为此, 必须在多视角聚类领域提出一种新的具备较强鲁棒性及多视角聚类能力且兼顾视角权重及视角内特征权重优化问题的新聚类算法。为达此目的, 本文拟针对传统 PCM 算法开展多视角聚类方面的模型优化工作, 本文工作的创新主要涵盖以下几点:

- 1) 针对传统可能性 (PCM) 算法无法解决多视角聚类场景的问题, 提出了多视角 PCM 算法;
- 2) 多视角 PCM 算法各视角之间的视角权重是一致的, 这与客观事实不符。针对各视角之间视角权重应该不同的问题, 引入视角间模糊加权机制;
- 3) 多视角 PCM 算法各视角内的属性权重默认是一致的, 这也与客观事实不符。针对各视角内的属性权重应该不同的问题, 引入视角内属性模糊加权机制。

## 1 相关工作

为了更好地说明本文所提之算法, 首先本小节将对传统的 PCM 算法进行回顾, 其次说明传统

PCM 算法在面对多视角聚类任务时所存在的问题, 最后引出具备最佳视角及最优特征划分能力的多视角模糊双加权可能性聚类算法 (MV-FDW-PCM) 的迫切性。

### 1.1 传统 PCM 算法

传统 PCM 算法于 1996 年被提出<sup>[1]</sup>。当时模糊 C 均值聚类 FCM 算法<sup>[2]</sup>是模糊聚类算法中最流行的聚类算法之一。随着 FCM 算法使用的推广, 一些专家学者发现 FCM 算法中对隶属度的限制条件增大了噪声、例外点对聚类结果的影响。为了消除 FCM 算法中隶属度之和为 1 的限制, R.Krishnapuram 等提出了 PCM 算法。该算法的优势在于去除了隶属度之和为 1 的限制条件, 从而降低了噪声对聚类精度的影响。PCM 算法的目标函数式为

$$J_{\text{PCM}}(\mathbf{U}, \mathbf{V}) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m \|\mathbf{x}_j - \mathbf{v}_i\|^2 + \sum_{i=1}^C \alpha_i \sum_{j=1}^N (1 - u_{ij})^m$$

$$\text{s.t. } 0 \leq u_{ij} \leq 1, 0 < \sum_{j=1}^N u_{ij} < N$$
(1)

式中:  $m$  是模糊系数, 参数  $\alpha_i$  的计算公式为

$$\alpha_i = K \sum_{j=1}^N u_{ij} \|\mathbf{x}_j - \mathbf{v}_i\|^2 / \sum_{j=1}^N u_{ij}, K = 1$$

求解目标函数式 (1) 得到隶属度和聚类中心表达式为

$$u_{ij} = \exp\left(-\frac{\|\mathbf{x}_j - \mathbf{v}_i\|^2}{\alpha_i}\right)$$
(2)

$$\mathbf{v}_i = \sum_{j=1}^N u_{ij}^m \mathbf{x}_j / \sum_{j=1}^N u_{ij}^m$$
(3)

### 1.2 PCM 算法处理多视角聚类任务

随着多视角应用场景不断出现, 传统聚类算法的单视角学习模式的局限性导致其在处理多视角聚类问题时性能往往无法令人满意。如传统 PCM 算法在处理多视角聚类任务时, 其聚类原理如下:

将多视角数据中每一个视角数据独立出来, 作为多个不相干的样本进行独立聚类分析。具体实施时是将各视角的样本直接使用传统 PCM 算法聚类以分别获取各视角的划分结果  $\mathbf{U}_k$  ( $0 < k \leq K$ ),  $K$  为视角数。最后, 对多个划分结果进行整合 (如使用加权平均等策略), 最终得到一个划分, 进而根据该划分确定样本所归属的类别。传统 PCM 算法处理多视角数据的原理图如图 1。

根据上述分析及图 1 所示的原理图可以看出, 传统 PCM 算法在对多视角数据进行聚类任务时, 存在以下问题: 1) 将各视角数据完全独立开来单独聚类, 未考虑各视角间数据的关联性信息; 2) 对各视角聚类结果进行融合时, 未考虑不同视角数

据对聚类结果的差异化影响,即结果的融合策略采用平均策略不符合客观事实。综上,传统 PCM 算法受限于陈旧的聚类模式在处理多视角聚类任务时显得不再有效。

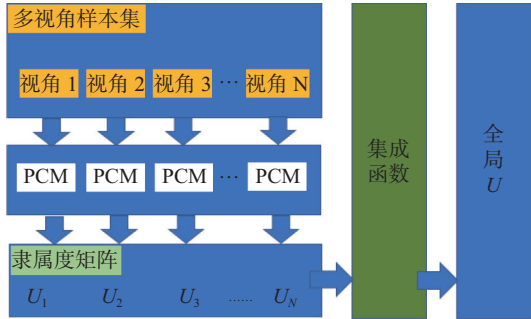


图1 传统 PCM 算法聚类多视角数据原理图

Fig. 1 The principle diagram of traditional PCM algorithm clustering multi-view data

## 2 多视角模糊双加权可能性聚类算法

针对传统 PCM 算法在处理多视角数据聚类任务时效果不理想的问题,本节首先提出了多视角 PCM 算法。考虑到实际的多视角聚类问题各视角的聚类特性应有差异(如图1所示),因而所设计的多视角聚类算法对于各视角的权重应根据实际情况进行优化获取,为此本节提出了视角间模糊加权机制。又由子空间聚类的原理可知各视角内属性的权重也应存在一定的差异性,于是本节又提出了视角内属性模糊加权机制。最后,基于上述两个机制,提出了具备最佳视角及最优特征划分能力的多视角模糊双加权可能性聚类算法。

### 2.1 多视角聚类问题描述

对于一个多视角聚类问题(如图2所示),其描述了一个3维( $X$ 维、 $Y$ 维及 $Z$ 维)的多视角模拟数据,若任意选择二维进行投影,可将一个3维数据变成2维且可视化程度更高的样本(如图2(b)~(d)),同理对于4维以上的数据亦可如此。在投影后,可以清晰地发现由 $X$ 维和 $Y$ 维组成的 $X$ - $Y$ 视角具备较之其他两视角更好的可分性,其类别结构清晰且类与类之间划分亦较为清晰。因此,对于任意一个多视角聚类问题,各视角的权重应通过优化学习得到而并非强制的一致对待。此外,根据子空间聚类理论<sup>[12]</sup>可知样本特征的权重对于不同的聚类问题应是有差异的,这种特征权重的差异性反应到多视角聚类问题中将进一步延伸为视角内部各特征的权重也应有所差异的,即同样以 $X$ - $Y$ 视角为例,若将 $X$ - $Y$ 视角的样本向 $X$ 轴投影,那么“+”类将与“\*”类严重重叠而不易区分,但若向 $Y$ 轴投影则得到的3类的区分度(可分性)更佳。由此可知,在多视

角聚类过程中,各视角下样本特征的权重与视角权重一样也需要得到优化,采用最佳的特征权重关系将进一步使得聚类结果得到显著提升。

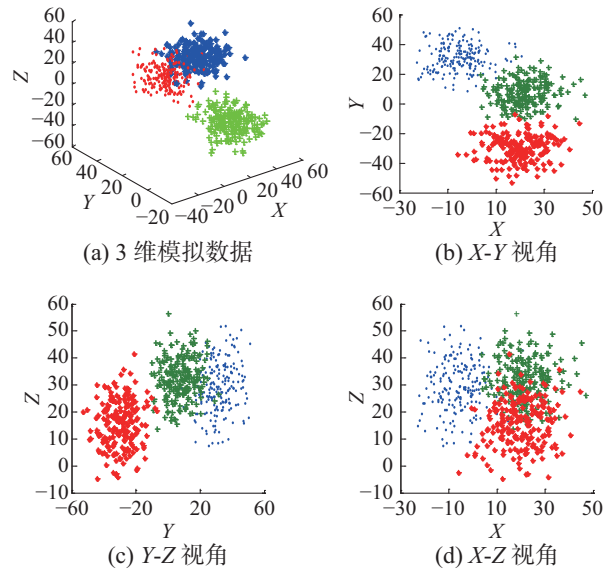


图2 问题描述

Fig. 2 Problem description

本文所用的符号说明如表1所示。

表1 符号说明

Table 1 The explanation of some notations

符号	描述
$u_{ijk}$	隶属度, $u_{ijk}$ 代表第 $k$ 个视角中第 $i$ 个数据属于第 $j$ 个聚类中心的程度
$v_{ik}$	聚类中心,代表第 $k$ 个视角的第 $i$ 个聚类中心
$x_{jk}$	第 $k$ 个视角的第 $j$ 个样本
$C$	聚类数
$N$	样本总数
$D$	特征总数
$K$	视角总数
$D_k$	第 $k$ 个视角数据的维数
$m_1, m_2, m_3$	模糊系数
$\alpha_{ik}$	第 $k$ 个视角下分歧项所占比重系数
$\theta$	视角隶属度融合项的平衡系数
$q_k$	第 $k$ 个视角所占权重
$w_{lk}$	第 $k$ 个视角数据的第 $l$ 维属性所占权重

### 2.2 多视角 PCM 算法

为了让 PCM 算法能够更好地适应多视角聚类任务,本文首先提出了多视角 PCM 算法。该算法的目标函数式如下:

$$J_{MV-PCM}(U, V, W, Q) =$$

$$\sum_{k=1}^K \left( \sum_{i=1}^C \sum_{j=1}^N [\tilde{u}_{ijk, \theta} \|x_{jk} - v_{ik}\|^2] + \sum_{i=1}^C \alpha_{ik} \sum_{j=1}^N (1 - u_{ijk})^{m_3} \right) \quad (4)$$



$$\tilde{u}_{ij,k,\theta} = (1-\theta)u_{ij,k}^{m_3} + \frac{\theta}{K-1} \sum_{k' \neq k, k'=1}^K u_{ij,k'}^{m_3} \quad (5)$$

s.t.  $1 \leq i \leq C, 1 \leq j \leq N, 1 \leq k \leq K, 0 \leq u_{ij,k} \leq 1, 0 < \sum_{j=1}^N u_{ij,k} < N$ 。

式(5)为视角隶属度融合项,  $\theta$ 为视角隶属度融合项的平衡系数。根据式(4)、(5)得到每个视角最终的隶属度矩阵。最终的划分结果用融合函数计算为

$$U_{ij} = \sqrt[K]{\prod_{k \in K} u_{ij,k}} \quad (6)$$

### 2.3 视角间模糊加权机制

多视角 PCM 算法虽然改变了传统 PCM 算法的单视角聚类模型, 使其能够解决多视角聚类任务, 但该算法仍未考虑视角间的权重大小应当存在差异化的情况。因为现实生产生活中, 多视角数据的每一个视角的数据存在聚类特性不相同的情况, 即有些视角数据的聚类特性较好, 有些视角数据的聚类特性较差。如果在聚类的过程中, 无差别地将所有视角数据的权重默许一致, 这种计算策略显然是不科学的。考虑到以上因素, 本节提出了一种可行的视角间模糊加权机制。即赋予每一个视角一个合理的权重且所有视角权重之和为 1。该机制的示意图如图 3 所示。




图 3 视角间加权机制示意图

Fig. 3 The schematic diagram of weighting mechanism between perspectives

视角间加权的表达式为

$$J_1(U, V, Q) = \sum_{k=1}^K q_k^{m_1} (J_{MV-PCM}(U, V, W, Q)) \quad (7)$$

$$\text{s.t. } q_k \in [0, 1], \sum_{k=1}^K q_k = 1, 1 \leq j \leq N, 1 \leq k \leq K。$$

### 2.4 视角内属性模糊加权机制

考虑到各视角内各个属性权重默认相同的情况与客观现实不符, 本文又提出了视角内属性加权机制。赋予聚类质量高的属性高的权重, 聚类质量较差的属性低的权重。具体表达式为

$$J_2(U, V, Q) = \sum_{k=1}^K \left( \sum_{i=1}^C \sum_{j=1}^N \left[ \tilde{u}_{ij,k,\theta} \sum_{l=1}^{D_k} w_{l,k}^{m_2} \|x_{jl,k} - v_{il,k}\|^2 \right] + \sum_{i=1}^C \alpha_{i,k} \sum_{j=1}^N (1 - u_{ij,k})^{m_3} \right) \quad (8)$$

$$\tilde{u}_{ij,k,\theta} = (1-\theta)u_{ij,k}^{m_3} + \frac{\theta}{K-1} \sum_{k' \neq k, k'=1}^K u_{ij,k'}^{m_3} \quad (9)$$

式(9)为视角隶属度融合项,  $\theta$ 为视角隶属度融合项的平衡系数。

### 2.5 多视角模糊双加权可能性聚类算法

在多视角 PCM 基础上, 通过引入视角间模糊加权以及视角内属性模糊加权两种机制, 本文提出了具备最佳视角及最优特征划分能力的多视角模糊双加权可能性聚类 MV-FDW-PCM 算法。该算法的原理如图 4 所示。

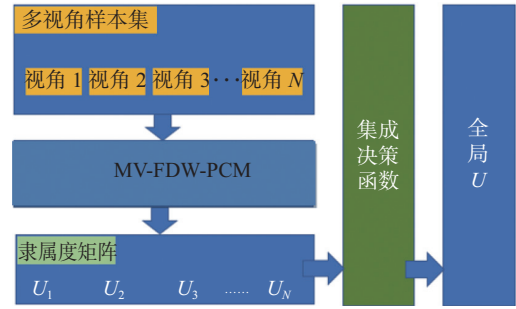


图 4 MV-FDW-PCM 算法聚类多视角数据

Fig. 4 The MV-FDW-PCM algorithm clustering multi-view data

算法的目标函数式为

$$J_{MV-FDW-PCM}(U, V, W, Q) = \sum_{k=1}^K q_k^{m_1} \left( \sum_{i=1}^C \sum_{j=1}^N \left[ \tilde{u}_{ij,k,\theta} \sum_{l=1}^{D_k} w_{l,k}^{m_2} \|x_{jl,k} - v_{il,k}\|^2 \right] + \sum_{i=1}^C \alpha_{i,k} \sum_{j=1}^N (1 - u_{ij,k})^{m_3} \right) \quad (10)$$

$$\tilde{u}_{ij,k,\theta} = (1-\theta)u_{ij,k}^{m_3} + \frac{\theta}{K-1} \sum_{k' \neq k, k'=1}^K u_{ij,k'}^{m_3} \quad (11)$$

$$\text{s.t. } \sum_{l=1}^{D_k} w_{l,k} = 1, \sum_{k=1}^K q_k = 1, \mu_{ij,k} \in [0, 1], 0 < \sum_{j=1}^N u_{ij,k} < N, w_{l,k} \in [0, 1], q_k \in [0, 1], 1 \leq j \leq N, 1 \leq k \leq K。$$

由于式(10)采用了属性加权机制以及多视角隶属度融合机制, 所以 $\alpha_{i,k}$ 的新优化项定义如下:

$$\alpha_{i,k} = G \sum_{j=1}^N \tilde{u}_{ij,k,\theta} \sum_{l=1}^{D_k} w_{l,k}^{m_2} \|x_{jl,k} - v_{il,k}\|^2 / \sum_{j=1}^N \tilde{u}_{ij,k,\theta}, G = 1。$$

利用拉格朗日最小化目标函数式(10), 得到聚类中心、隶属度、视角权重以及属性权重的计算式

$$v_{il,k} = \sum_{j=1}^N \tilde{u}_{ij,k,\theta} w_{l,k}^{m_2} x_{jl,k} / \sum_{j=1}^N \tilde{u}_{ij,k,\theta} w_{l,k}^{m_2} \quad (12)$$

$$u_{i,j,k} = \frac{1}{1 + \left( \frac{(1-\theta) \sum_{l=1}^{D_k} w_{l,k}^{m_2} \|\mathbf{x}_{j,l,k} - \mathbf{v}_{il,k}\|^2 + \frac{\theta}{K-1} \sum_{k' \neq k, k'=1}^K \sum_{l=1}^{D_k} w_{l,k'}^{m_2} \|\mathbf{x}_{j,l,k'} - \mathbf{v}_{il,k'}\|^2}{\alpha_{i,k}} \right)^{\frac{1}{m_3-1}}} \quad (13)$$

$$q_k = \frac{1}{\sum_{h=1}^K \left( \frac{\left( \sum_{i=1}^C \sum_{j=1}^N \left[ \tilde{u}_{ij,k,\theta} \sum_{l=1}^{D_r} w_{l,k}^{m_2} \|\mathbf{x}_{j,l,k} - \mathbf{v}_{il,k}\|^2 \right] + \sum_{i=1}^C \alpha_{i,k} \sum_{j=1}^N (1-u_{ij,k})^{m_3} \right)}{\left( \sum_{i=1}^C \sum_{j=1}^N \left[ \tilde{u}_{ij,h,\theta} \sum_{l=1}^{D_r} w_{l,h}^{m_2} \|\mathbf{x}_{j,l,h} - \mathbf{v}_{il,h}\|^2 \right] + \sum_{i=1}^C \alpha_{i,k} \sum_{j=1}^N (1-u_{ij,k})^{m_3} \right)} \right)^{\frac{1}{m_1-1}}} \quad (14)$$

$$w_{l,k} = \frac{1}{\sum_{h=1}^{d_k} \left( \frac{\sum_{i=1}^C \sum_{j=1}^N (\tilde{u}_{ij,k,\theta} \|\mathbf{x}_{j,l,k} - \mathbf{v}_{il,k}\|^2)}{\sum_{i=1}^C \sum_{j=1}^N (\tilde{u}_{ij,h,\theta} \|\mathbf{x}_{j,l,h} - \mathbf{v}_{il,h}\|^2)} \right)^{\frac{1}{m_2-1}}} \quad (15)$$

最终的划分结果用式 (16) 融合函数进行计算:

$$U_{ij} = \sum_{k=1}^K q_k u_{ij,k} \quad (16)$$

MV-FDW-PCM 算法步骤如下:

- 1) 给定聚类数  $C$ , 样本总数  $N$ , 视角总数  $K$ , 聚类精度  $\varepsilon$ , 最大迭代次数  $T$ , 模糊系数  $m_1, m_2, m_3$ , 初始化隶属度矩阵  $U$  和聚类中心  $V$ ;
- 2) 根据式 (12) 更新聚类中心;
- 3) 根据式 (13) 更新隶属度;
- 4) 根据式 (14) 更新视角间权重系数;
- 5) 根据式 (15) 更新视角内属性权重系数;
- 6) 当  $\|U(t+1) - U(t)\| < \varepsilon$  或迭代次数达到最大迭代次数  $T$  时, 算法运行终止, 否则, 返回 2);
- 7) 算法收敛后, 输出各视角的隶属度矩阵  $u_{ij,k}$ ;
- 8) 利用式 (16) 计算出最终的划分结果。

### 3 实验与分析

#### 3.1 实验环境及实验参数设置

为了验证本文所提 MV-FDW-PCM 算法的性能, 本文在以下几个数据集上进行了实验分析, 实验数据集分别是: UCI 标准数据集、Brodatz 纹理图像<sup>[23]</sup>以及一组关于我实验室老师的真实人脸图像的实际应用效果展示。实验采用的对比算法主要有: 经典的适用于单视角聚类环境的可能性  $C$  均值聚类算法 PCM(Possibilistic c-means)、具备多视角模糊聚类性能的协同模糊  $K$  均值算法 CoFKM<sup>[4]</sup>(Collaborative fuzzy  $K$ -means)、具备聚类任务组合能力的  $K$  均值算法 CombKM<sup>[24]</sup>(Combine  $K$ -means)、具有多视角聚类算法代表性的多视角谱聚类算法 MVSpec<sup>[5]</sup>(Multi-view spectral clustering)。所有实验运行平台的配置如下: 酷睿 i3 3.6 GHz CPU, 3.42G RAM, 32 位 Windows 7 操作系统, MATLAB R2012b 编程环境。

本文算法的评价指标如表 2 所示。

表 2 评价指标

Table 2 The evaluation index

评价指标	表达式	注释
NMI	$\frac{\sum_{i=1}^C \sum_{j=1}^C N_{i,j} \log N \cdot N_{i,j} / N_i \cdot N_j}{\sqrt{\sum_{i=1}^C N_i \log N_i / N \cdot \sum_{j=1}^C N_j \log N_j / N}}$	$N_{i,j}$ 为第 $i$ 个聚类与类 $j$ 的契合程度, $N_i$ 为第 $i$ 个聚类所包含的数据样本量, $N_j$ 为类 $j$ 所包含的数据样本量, $N$ 为样本总量
RI	$\frac{f_{00} + f_{11}}{N(N-1)/2}$	$f_{00}$ 为样本具有不同的类标签且属于不同类的配对数目, $f_{11}$ 则为样本具有相同的类标签且属于同一类的配对数目, $N$ 为样本总量

表中两种评价指标分别为归一化互信息 (normalized mutual information, NMI) 和芮氏指标 (rand index, RI), 这两种指标为常用的评价聚类结果评价指标<sup>[5, 12]</sup>, 其取值范围均在  $[0, 1]$ , 指标数值越大 (越接近 1), 代表该算法的性能表现越好。

实验中相关参数设置如下: 本文 MV-FDW-PCM 算法中参数  $m_1, m_2, m_3$  均在  $\{1.1, 1.3, 1.5, 1.7, 1.9, 2.5\}$  中寻优取得, 参数  $\theta$  设为 1。MVSpec 算法

中指数  $p$  通过从  $\{1, 1.1, \dots, 1.9, 2, 3, \dots, 6, 7\}$  中进行网络搜索来设置最优值。实验结果均为算法运行 20 次的平均值与均方差, 因此实验结果部分对应的 NMI-mean、NMI-std、RI-mean、RI-std 分别为 NMI 和 RI 指标在 20 次运行后所得结果的均值和方差。

#### 3.2 UCI 标准数据实验

本文使用了 UCI 数据集中经典的 4 种多视角表达的数据集, 分别是手写数据集 (MF)、图像分割

数据集 (IS)、污水处理数据集 (WTP) 及互联网广告数据集 (IADS), 表 3 中简要介绍了各数据集的基本

信息。此外, 各算法在这 4 种 UCI 数据集上的实验结果如表 4 所示。

表 3 UCI 数据集介绍

Table 3 Description of UCI data sets

数据集	介绍	样本数	维数	视角数	聚类数
Multiple Features (MF)	手写体数据集	2 000	649	6	10
Image Segmentation (IS)	图像分割数据集	2 310	19	2	7
Water Treatment Plant (WTP)	该数据集来自一个城市的污水处理厂的传感器传来的日常数据	527	38	4	13
Internet Advertisement (IADS)	该数据集表示在互联网上出现的一组可能的广告	3 279	1 040	3	2

表 4 UCI 数据集上的实验结果对比

Table 4 The performance of clustering algorithm

数据集	算法	NMI-mean	NMI-std	RI-mean	RI-std
MF	PCM	0.634 2	0.018 7	0.859 7	0.020 4
	CombKM	0.670 1	0.024 1	0.893 3	0.021 9
	CoFKM	0.786 8	0.071 5	0.941 7	0.022 6
	MVSpec	0.723 9	0.013 7	0.937 3	0.013 2
	MV-FDW-PCM	0.841 2	0.014 1	0.965 1	0.012 5
IS	PCM	0.470 9	0.013 3	0.779 8	0.017 6
	CombKM	0.473 5	0.029 3	0.782 3	0.020 2
	CoFKM	0.542 2	0.035 3	0.829 3	0.019 5
	MVSpec	0.586 2	0.020 2	0.852 6	0.010 2
	MV-FDW-PCM	0.603 2	0.025 1	0.863 4	0.007 5
WTP	PCM	0.172 4	0.022 6	0.693 8	0.026 9
	CombKM	0.198 2	0.031 3	0.713 2	0.014 5
	CoFKM	0.198 6	0.014 0	0.705 6	0.004 4
	MVSpec	0.191 3	0.010 4	0.718 2	0.002 3
	MV-FDW-PCM	0.216 7	0.010 6	0.719 1	0.008 3
IADS	PCM	0.117 8	0.087 5	0.706 3	0.048 1
	CombKM	0.096 3	0.108 1	0.654 9	0.027 9
	CoFKM	0.215 1	0.002 6	0.803 9	0.000 6
	MVSpec	0.238 9	0.004 1	0.800 9	0.011 2
	MV-FDW-PCM	0.224 2	0.003 6	0.797 6	0.003 5

从实验结果可以观察出如下结论:

1) 通过观察各算法在 MF 数据集上的聚类结果, 可以明显地看出 CoFKM 算法及本文所提的 MV-FDW-PCM 算法有着较大的性能优势。但是由于 MF 数据集本身所含的各视角样本的可分性均是比较均衡一致的, 因此本文算法的视角加权的优势并不明显, 其所得性能与 CoFKM 算法基本接近。

2) 当进一步观察本文算法在 IS 及 WTP 这两

个多视角数据集上的聚类性能, 本文所提的 MV-FDW-PCM 算法在 IS 数据集上性能优势较为明显, 这是由于 IS 这类图像分割数据集不同视角间的特征差异明显、可分性也有一定的区分, 这使得本文算法的属性加权机制和视角加权机制产生了一些积极的聚类效果, 提高了聚类性能。而对于 WTP 这一水污染数据集, 本文算法的性能与其他 4 种方法相比基本处于相同的性能水平, 导致这一现象的原因主要是水污染数据集样本数较少各类之间的数据分布区分并不显著, 此外该数据所含的类别较多, 这对于采用欧式距离的算法而言是一种挑战, 对于此类数据集, 我们将在今后考虑使用其他的距离公式来替换欧氏距离改善聚类性能。

3) 观察 IADS 数据可发现具备多视角聚类能力的算法较之单视角的聚类算法如经典的 PCM 算法有着明显的聚类优势, 但本文所提的 MV-FDW-PCM 算法的聚类性能却略差于基于谱聚类聚类原理的 MVSpec 算法。究其原因在于如 IADS 等广告类数据一般数据分布呈现非团状数据特征, 而 PCM、CombKM、CoFKM 及 MV-FDW-PCM 均是基于 c-means 框架提出的方法, 其对团状数据有效, 对于非团状数据特别是凸型数据则显得无能为力。为了改善此类算法在非团状数据集上的聚类性能, 一种有效的途径也是更换距离公式, 今后我们也将在这部分研究内容上进行深入的探讨。

### 3.3 Brodatz 纹理图像实验

除了验证本文算法在 UCI 标准数据集上的聚类性能, 本小节还在图像分割实验中验证了本文算法的性能。本文在著名的 Brodatz 纹理图库中 (<http://www.ux.uis.no/~tranden/brodatz.html>) 选择了 7 种具有常见的具备代表性的纹理图片组成了图 5。两种不同的纹理组合图像的目标分割数均为 7。对比算法不变, 各算法对该纹理图的分割结果如图 6 所示。具体的聚类性能对比如表 5 所示。

根据图 6 各算法在两种不同的纹理组合图像

上的实验结果可以观察出,本文算法 MV-FDW-PCM 所得的分割结果与理想分割结果图的效果最为接近。观察图 6(a)、6(b)、6(f) 及 6(g) 的实验结果,我们可以肉眼评价出单视角聚类算法的性能明显劣于 3 种多视角聚类算法,其分割结果的图像质量较差。而对于 3 种多视角聚类算法,本文方法由于其具备多视角加权和多视角属性加权

机制,特别是多视角属性加权机制,该机制能够增大图像中重要属性的权重进而提高分割结果的质量使得本文算法获得了优于其他两种多视角聚类算法的更佳分割效果。综合图 6 与表 5 的结果,我们可以得出结论,本文提出的 MV-FDW-PCM 算法在图像分割实验中较其他算法具有更好的聚类性能。




图 5 纹理图像

Fig. 5 Texture image

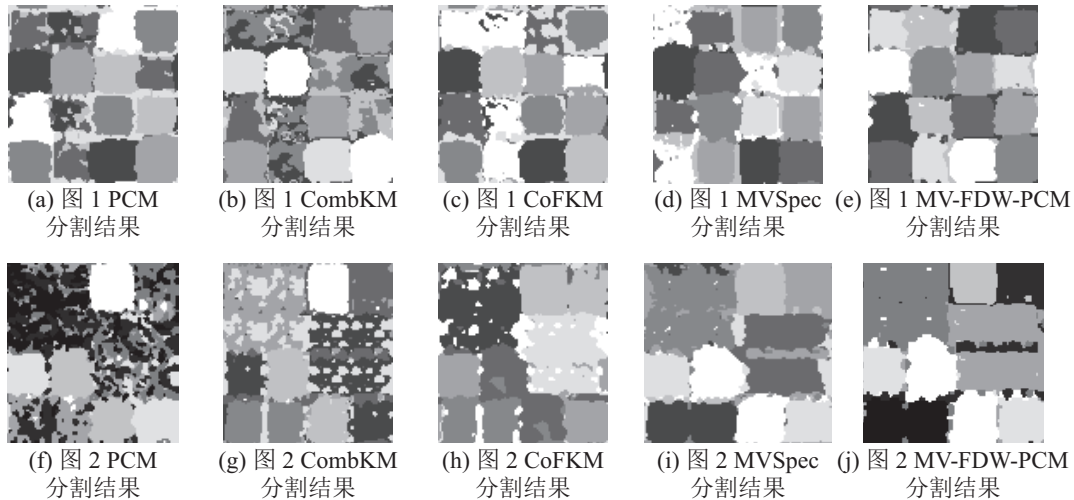


图 6 各算法分割结果对比

Fig. 6 Comparison of image segmentation results

表 5 各算法的聚类性能对比

Table 5 Comparison of clustering performance of each algorithm

算法	图1算法					图2算法				
	PCM	CombKM	CoFKM	MVSpec	MV-FDW-PCM	PCM	CombKM	CoFKM	MVSpec	MV-FDW-PCM
NMI-mean	0.525 0	0.565 6	0.623 8	0.623 2	0.663 1	0.531 1	0.583 2	0.636 1	0.639 2	0.658 6
NMI-std	0.027 9	0.013 7	0.014 4	0.021 4	0.016 2	0.019 8	0.001 2	0.008 9	0.009 6	0.022 4
RI-mean	0.855 1	0.872 1	0.891 1	0.893 2	0.904 7	0.826 1	0.842 2	0.879 1	0.892 1	0.895 1
RI-std	0.018 9	0.003 1	0.007 6	0.003 9	0.003 5	0.005 4	0.008 5	0.005 4	0.011 9	0.010 9

### 3.4 真实人脸图像实验

在本节的实验中,我们针对一幅真人的证件照片图 7(a) 为例,以最基本的 RGB 通道分别获得 3 个视角样本如图 7(b)、(c) 所示,而后使用本文所提的 MV-FDW-PCM 算法与其他的 4 种相关算法

做了进一步的性能比对分析。由于真人照片无法标定像素的真实标记,因此 NMI 指标和 RI 指标在该实验部分将无法使用,仅能够通过图 8 给出的分割结果从肉眼上进行评估。

从图 8 的分割结果可以明显地看出,3 种具备



多视角聚类能力的 Co-FKM 算法、MVSPEC 算法及本文所提的 MV-FDW-PCM 算法较之传统的单视角 PCM 算法及 CombKM 算法在分割性能上有着明显的优势。进而, 对 3 种多视角聚类算法的结果进行分析, 本文所提的 MV-FDW-PCM 算法在脸部及皮肤分割方面较之其他两种方法有着一定的分割优势, 这也从侧面反映了两种加权策略 (视角加权和属性加权) 在聚类过程中起到了一定的作用, 改善了聚类结果。




图 7 真实人脸图像

Fig. 7 Real face image

### 3.5 算法运行性能分析

根据表 6 的实验结果可知, 本文所提方法的运行效率在所对比的 5 种方法中排名在后两位。因本文算法包含了 4 个参数 (聚类中心、隶属度、视角内属性权重及视角权重) 需要迭代优化, 较之传统的 PCM 算法的 2 优化参数 (类中心及隶属度)、组合 K 均值算法 CombKM 的 2 优化参数 (类中心及隶属度) 及多视角协同算法 CoFKM 的 2 优化参数 (类中心及隶属度) 均有着高出近 1 倍的优化迭代需求, 而对于多视角谱聚类算法 MVSPEC, 由于该算法

基于谱聚类原理和 MV-FDW-PCM 算法的 C 均值聚类原理有较大差别, 两者的运行性能不具可比性。综上, 本文算法虽拥有较之其他相关算法更佳的聚类性能, 但在运行效率上较之其他算法显得并不高效。为此, 今后我们将进一步地探讨如何在更少的优化参数下保持当前聚类性能的多视角可能性聚类算法。

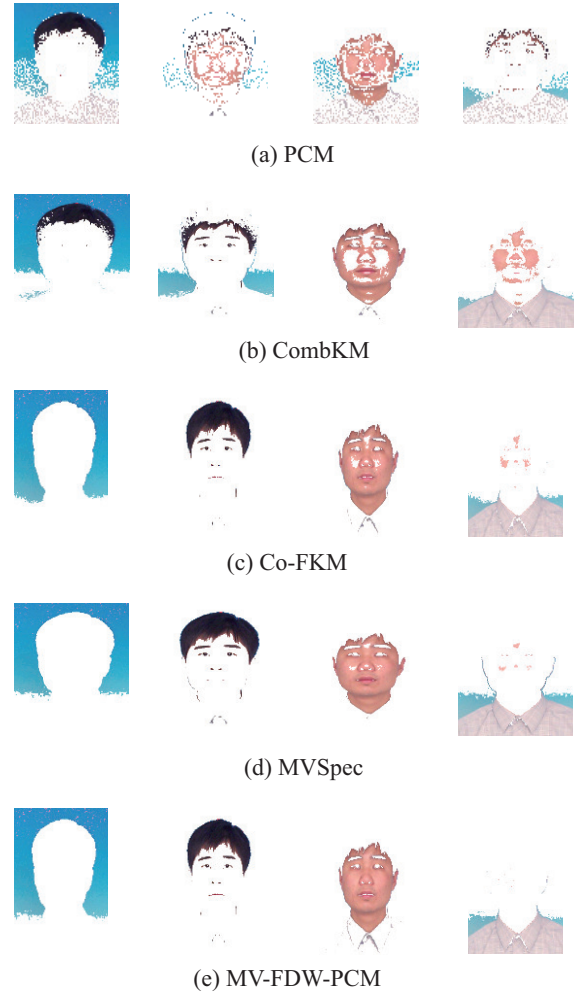


图 8 各算法在真实人脸图像上的分割结果

Fig. 8 The segmentation results of the algorithm on the real face image

表 6 各算法的运行性能对比

Table 6 Comparison of the running time of each algorithm

	PCM	CombKM	CoFKM	MVSPEC	MV-FDW-PCM
MF	228.12 (2)*	192.77 (1)	284.69 (3)	491.14 (5)	482.31 (4)
IS	5.078 (2)	4.414 (1)	18.724 (3)	33.782 (5)	19.824 (4)
WTP	6.332 (1)	6.709 (2)	11.844 (3)	16.018 (4)	18.849 (5)
IADS	4.754 (1)	5.356 (2)	69.114 (3)	272.24 (5)	103.62 (4)
图1	8.018 (2)	7.226 (1)	12.792 (3)	351.53 (5)	55.969 (4)
图2	8.365 (1)	8.729 (2)	12.802 (3)	224.66 (5)	55.119 (4)
真实人脸	22.367 (2)	20.144 (1)	35.015 (3)	401.78 (5)	78.122 (4)

注: \* 括号内的数值为各算法的排名(Ranking Values)。



## 4 结束语

为解决传统可能性聚类算法无法满足多视角学习场景聚类的实际问题,并进一步考虑到现有多视角聚类算法尚未重视的视角间权重及视角内特征权重优化问题,本文致力于提出一种新的具备最佳视角及最优特征划分能力的多视角模糊双加权可能性聚类算法(MV-FDW-PCM)。该算法基于传统的PCM算法,给出详细的多视角聚类学习框架,使得PCM算法具备多视角聚类能力,进而通过引入视角间模糊加权机制及视角内属性模糊加权机制以解决视角权重及视角内特征权重优化问题。本文在UCI中的标准多视角数据集、纹理图像分割实验以及真实人脸图像中,均进行了实验验证。实验结果表明,本文所提的MV-FDW-PCM算法在面对多视角聚类问题时较其他对比聚类算法具备更佳的聚类效果。

## 参考文献:

- [1] JIANG Y Z, DENG Z H, CHUNG F L, et al. Realizing two-view TSK fuzzy classification system by using collaborative learning[J]. IEEE transactions on systems, man, and cybernetics: systems, 2017, 47(1): 145–160.
- [2] YAMANISHI Y, VERT J P, KANEHISA M. Protein network inference from multiple genomic data: a supervised approach[J]. Bioinformatics, 2004, 20(1): 363–370.
- [3] PEDRYCZ W. Collaborative fuzzy clustering[J]. Pattern recognition letter, 2002, 23(14): 1675–1686.
- [4] CLEUZIOU G, EXBRAYAT M, MARTIN L, et al. CoFKM: a centralized method for multiple-view clustering [C]//Proc of the 9th IEEE International Conference on Data Mining (ICDM 2009). Miami, USA, 2009: 752–757.
- [5] TZORTZIS G F, LIKEAS A C. Kernel-based weighted multi-view clustering[C]//IEEE 12th International Conference on Data Mining. Brussels, Belgium, 2012: 675–684.
- [6] DENG Z H, JIANG Y Z, ISHIBUCHI H, et al. Enhanced knowledge-leverage-based tsk fuzzy system modeling for inductive transfer learning[J]. ACM transactions on intelligent systems and technology, 2016, 8(1): 1–21.
- [7] QIAN P J, JIANG Y Z, DENG Z H, et al. Cluster prototypes and fuzzy memberships jointly leveraged cross-domain maximum entropy clustering[J]. IEEE transaction on cybernetics, 2016, 46(1): 181–193.
- [8] DENG Z H, JIANG Y Z, CHUNG F L, et al. Transfer prototype-based fuzzy clustering[J]. IEEE transactions on fuzzy systems, 2016, 24(5): 1210–1232.
- [9] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE transactions on knowledge and data engineering, 2010, 22(10): 1345–1359.
- [10] JIANG Y Z, CHUNG F L, ISHIBUCHI H, et al. Multitask TSK fuzzy system modeling by mining intertask common hidden structure[J]. IEEE transactions on cybernetics, 2015, 45(3): 548–561.
- [11] CARUANA R. Multitask learning[J]. Machine learning, 1997, 28(1): 41–75.
- [12] DENG Z H, CHOI K S, JIANG Y Z, et al. A survey on soft subspace clustering[J]. Information sciences, 2016, 348: 84–106.
- [13] HALL LO, GOLDFOF DB. Convergence of the single-pass and online fuzzy C-means algorithms[J]. IEEE transactions on fuzzy systems, 2011, 19(4): 792–794.
- [14] BEZDEK J C. Pattern recognition with fuzzy objective function algorithms[M]. New York, USA: Plenum Press, 1981: 65–79.
- [15] FREY B J, DUECK D. Clustering by passing messages between data points[J]. Science, 2007, 315(5814): 972–976.
- [16] 曾令伟, 伍振兴, 杜文才. 基于改进自监督学习群体智能 (ISLCI) 的高性能聚类算法[J]. 重庆邮电大学学报: 自然科学版, 2016, 28(1): 131–137.  
ZENG Lingwei, WU Zhengxin, DU Wencai. Improved self-supervised learning collection intelligence based high performance data clustering approach[J]. Journal of Chongqing university of posts and telecommunications: natural science edition, 2016, 28(1): 131–137.
- [17] 程咏, 王士同. 基于局部保留投影的多可选聚类发掘算法[J]. 智能系统学报, 2016, 11(5): 600–607.  
CHENG Yang, WANG Shitong. A multiple alternative clusterings mining algorithm using locality preserving projections[J]. CAAI transactions on intelligent systems, 2016, 11(5): 600–607.
- [18] 杭文龙, 蒋亦樟, 刘解放, 等. 迁移近邻传播聚类算法[J]. 软件学报, 2016, 27(11): 2796–2813.  
HANG Wenlong, JIANG Yizhang, LIU Jiefang, et al. Transfer affinity propagation clustering algorithm[J]. Journal of software, 2016, 27(11): 2796–2813.
- [19] 邓赵红, 王士同, 吴锡生, 等. 鲁棒的极大熵聚类算法 RMEC 及其例外点标识[J]. 中国工程科学, 2004, 6(9): 38–45.  
DENG Zhaohong, WANG Shitong, WU Xisheng, et al. Robust maximum entropy clustering algorithm rmec and its outlier labeling[J]. Engineering science, 2004, 6(9): 38–45.
- [20] KARAYIANNIS N B. MECA: maximum entropy clustering algorithm[C]//Proc of the 3rd IEEE Conf. on Fuzzy Systems. Orlando: IEEE Press, 1994: 630–635.
- [21] KRISHNAPURAM R, KELLER J. A possibilistic ap-

proach to clustering[J]. IEEE transactions on fuzzy systems, 1993, 1(2): 98–110.

[22] KRISHNAPURAM R, KELLER J M. The possibilistic means algorithms: Insights and recommendation[J]. IEEE transactions on fuzzy systems, 1996, 4(3): 385–393.

[23] TRYGVE R, BRODATZ T. Texture classification [EB/OL]. [2007-08-01]. <http://www.ux.uis.no/tranden/brodatz.html>.

[24] GU Q Q, ZHOU J. Learning the shared subspace for multi-task clustering and transductive transfer classification [C]//Proc Int Conf Data Mining (ICDM). Miami, USA, 2009: 59–168.


#### 作者简介:



蒋亦樟, 男, 1988 年生, 讲师, 博士, 主要研究方向为人工智能、模式识别、模糊系统。发表学术论文 40 余篇, 其中被 SCI、EI 检索 20 余篇。



朱丽, 女, 1996 年生, 硕士研究生, 主要研究方向为人工智能、模式识别、模糊系统。



刘丽, 女, 1987 年生, 讲师, 主要研究方向为人工智能、模式识别、模糊系统。



王士同, 男, 1964 年生, 教授, 博士生导师, 主要研究方向为人工智能、模式识别和生物信息。发表学术论文百余篇, 其中被 SCI、EI 检索 50 余篇。

## 2018 年第二届图像及信号处理国际会议 The 2nd International Conference on Graphics and Signal Processing (ICGSP 2018)

Oct. 6-8, 2018, Sydney, Australia

The 2nd International Conference on Graphics and Signal Processing (ICGSP 2018) aims to be a prime international forum for both researchers and industry practitioners to exchange the latest fundamental advances in the state of the art and practice of graphics and signal processing, identify emerging research topics, and define the future of Signal Processing. ICGSP offers a three-day technical program including keynote speeches, hot-topic oral&poster sessions, tutorials.

Papers that present original work, validated by experimentation, simulation, or analysis, are solicited. Practical experiences and experimental efforts from both industry and academia, duly documenting the lessons learned from test-beds, field-trials, or real deployments, are also welcome.

Accepted conference papers (full paper only) after authors' attendance will be published in the conference proceedings, which will be online and indexed.

#### Important Date

- Abstract Submission Deadline: May 10th, 2018
- Full manuscript due: May 30th, 2018
- Acceptance notification: June 20th, 2018
- Camera Ready: July 30, 2018

Website: <http://icgsp.org/>