

doi:10.3969/j.issn.1001-4616.2026.01.010

# 使用模糊标签驱动标签松弛的多视角分类算法

邱成羽, 陈 秀, 程煜婷, 谢宇航, 欧哲权, 张远鹏

(南通大学医学信息学系, 江苏 南通 226007)

[摘要] 随着数据采集技术的不断发展,多视角数据在医学图像、行为识别与多模态分析等领域得到了广泛应用。然而,不同视角间的语义差异性与标签获取过程中的主观性,常导致标签噪声和分类鲁棒性下降等问题。为此,本文提出一种基于模糊标签驱动的标签松弛与一致性监督相结合的多视角分类算法。该方法通过模糊聚类为每个样本构建软标签表示,以挖掘标签的不确定性与语义模糊性。随后,在软标签的学习过程中引入视角权重与真实标签的联合约束,引导模型在真实标签与模糊标签之间建立柔性监督机制,实现标签层面的软性过渡。最终,通过多轮迭代将软标签与视角特征共同优化,学习出具有判别性的特征投影矩阵。在 4 个真实世界数据集上得到的结果与其他多视角分类算法以及传统分类方法进行比较,所提出的方法在应对标签噪声与多视角信息融合方面均表现出优越性。

[关键词] 多视角学习,模糊聚类,标签松弛,机器学习

[中图分类号] TP391.71 [文献标志码] A [文章编号] 1001-4616(2026)01-0096-12

## Multi-view Classification Driven by Fuzzy Labels for Label Relaxation

Qiu Chengyu, Chen Xiu, Cheng Yuting, Xie Yuhang, Ou Zhequan, Zhang Yuanpeng

(Department of Medical Informatics, Nantong University, Nantong 226007, China)

**Abstract:** With the continuous advancement of data acquisition technologies, multi-view data has been widely applied in fields such as medical imaging, action recognition, and multimodal analysis. However, semantic discrepancies across different views and subjectivity in the label annotation process often lead to label noise and reduced classification robustness. To address these issues, this paper proposed a multi-view classification algorithm that integrates fuzzy-label-driven label relaxation with consistency regularization. Specifically, fuzzy clustering was employed to construct soft label representations for each sample, aiming to capture the uncertainty and semantic ambiguity in the labels. During the learning of soft labels, the method introduced view-specific weights and joint constraints with ground-truth labels to guide the model in establishing a flexible supervision mechanism between hard and fuzzy labels, thereby achieving a smooth transition at the label level. Finally, through iterative optimization of both soft labels and view features, the model learned a discriminative feature projection matrix. Experimental results on four real-world multi-view datasets demonstrated that the proposed method outperforms conventional multi-view and traditional classification approaches in terms of robustness to label noise and effectiveness in multi-view information integration.

**Key words:** multi-view learning, fuzzy clustering, label relaxation, machine learning

随着信息采集技术的发展,数据的种类和采集方法越来越多样化,尤其是在图像分析、用户建模、生物信息等领域中,数据常以多视角形式呈现。针对多视角数据进行的多视角学习(multi-view learning, MVL)的重要性也在不断提升。

在 MVL 的研究过程中,如何更好利用不同视角的信息以及保证视角间的一致性一直是 MVL 的难题。随着研究的不断深入,研究人员已经达成一种共识,即 MVL 方法应当基于以下两点原则进行设计:一致性原则和互补性原则<sup>[1-2]</sup>。围绕着这一共识,目前的 MVL 确实克服了传统单视角算法在信息利用与维度控制方面的局限,在多视角任务中取得了更好的结果<sup>[3-6]</sup>。然而,目前大部分 MVL 研究都基于一个假

收稿日期:2025-10-30.

基金项目:国家自然科学基金面上项目(82572382)、江苏高校“青蓝工程”项目、江苏省研究生科研与实践创新计划项目(KYCX24-3561).

通讯作者:张远鹏,博士,教授,研究方向:医学人工智能. E-mail:y.p.zhang@ieec.org

设——即训练集标签完全可靠,忽视了多视角环境中标签噪声与不确定性的存在。

在实际应用中,真实标签往往难以获取,因此训练数据集通常通过人工标注来构建。在医学领域,临床医生往往根据初步检查将患者划分为不同的组别;而在图像识别和语音识别等任务中,机器学习领域常借助在线平台进行众包标注。由于标注过程具有主观性,加之某些样本本身就难以分类,人工收集的标签可能与真实标签不一致,这种匹配通常被称为标签噪声<sup>[7-8]</sup>。同时由于噪声、采样误差和仪器误差,所采集的数据往往还包含一定程度的不确定性<sup>[9-10]</sup>,进一步影响了样本的质量。在多视角学习任务中,这种标签噪声与数据不确定性的共存,会让不同视角下的样本表示相互冲突,从而进一步使各类别间的决策边界变得模糊,并导致融合时无法充分利用各视角的互补信息。为解决这一问题,研究人员引入了“标签松弛”策略。

标签松弛策略通过将原始硬标签转化为软标签或引入可优化的标签变量,将离散的硬标签转化为能够反映样本不确定性的连续或软标签,从而扩大类边距,使模型在面对标签噪声、语义模糊或不确定性时具备更强的容错能力与泛化性能。Yang 等<sup>[11]</sup>使用 Spearman 相关系数衡量样本之间的相似性并构造每个视图的松弛矩阵,再与原始标签拼接得到松弛后的非负矩阵标签,在此基础上构建多视角聚类模型,证明了标签松弛策略能有效提升多视角数据的学习性能。Liang 等<sup>[7]</sup>通过多视图最小二乘回归引入了可优化的松弛标签矩阵,构建了一个兼具流形平滑与噪声校正的多视图分类模型,实验证明该方法相比不去噪或单视图方法显著提高了分类准确率和鲁棒性。Fu 等<sup>[12]</sup>通过引入一个非负的松弛矩阵,将二值标签转换为可优化的连续标签,并构建了多视角线性回归分类模型,得到的分类准确率均优于传统单视图和已有多视图方法。

尽管上述通过引入标签松弛都提升了多视角数据的学习性能,但仍有两个问题需要进一步解决。首先,大多数现有的标签松弛方法只在优化目标下尽可能地最大化类边距,这显然导致了较差的泛化能力。其次,许多松弛策略未能显式考虑数据的语义模糊性,而这种模糊性恰恰蕴含了关于类别边界与样本结构的重要先验知识。为了解决上述问题,本文提出一种基于模糊标签驱动的标签松弛与一致性监督分类算法(fuzzy-label consistency-guided multi-view classification, FC-MVCC)。该方法的核心思想是引入模糊标签作为软性中介,在真实标签与样本特征之间构建柔性连接,从而缓解由硬标签引发的分类误差并增强视角协同。主要有以下创新:(1)基于模糊 C 均值算法在各视角中独立构建软隶属度矩阵,以刻画数据分布的不确定性与语义模糊性(2)引入模糊标签作为软标签,并通过真实标签对其进行约束,以提升模型对语义边界模糊样本的纠错能力(3)通过引入视角自适应权重与样本一致性损失,有效调节多视角贡献,并抑制噪声视角的干扰。我们在 4 个真实世界的多视角数据集上对所提方法进行了验证。实验结果表明,FC-MVCC 在准确率、稳定性及对复杂特征结构的适应能力方面均优于当前主流方法,尤其在视角质量不均、样本稀疏的小样本场景中表现出显著优势。

## 1 相关工作

MVL 方法主要可以分为早期融合、中期融合与晚期融合三大类策略。但这三类策略在应对真实数据中“模态不均”“弱视角噪声”“标签对齐困难”等挑战时,仍存在以下局限:

对于早期融合如直接拼接或特征重加权方法,本质上是一个单一视角模型,其假设不同视角的权重都是固定的或者相同的,而实际上不同视角的数据质量往往不一,尤其是当某个视角含有的特征大于其他视角时,在拼接后该视角会拥有更高的权重,会掩盖其他视角中的特征贡献<sup>[13]</sup>。这种方法无法充分利用多视角的互补性,并且由于拼接后的样本往往维度过高容易导致“维度灾难”问题<sup>[14-15]</sup>。对于中期融合如典型相关分析(canonical correlation analysis, CCA)及其扩展方法,通常的做法是将来自不同的数据进行一系列处理构建全新的“中间表示”,再对得到的中间表示进行对齐或者合并,以寻找两个或多个视图之间的相关性<sup>[16-18]</sup>。但是并未利用标签信息,在涉及分类任务时往往力不从心<sup>[19]</sup>。后续推出的监督式的 CCA<sup>[20]</sup>将标签作为先验并对特征进行筛选,但依然采用无监督的 CCA 来寻找最大相关性,导致标签信息仍未在核心投影过程中发挥作用。对于晚期融合策略如决策平均<sup>[21]</sup>、决策投票<sup>[22]</sup>、加权决策<sup>[23-24]</sup>,通常做法是为每一个视角单独训练模型,再融合各视角结果以得到最终分类结果。但这种方法无法捕捉不同视角之间的互补性信息,且在学习过程中,不同训练过程中无法共享知识并利用互补信息,无法充分利用多视

角数据.

在此基础上,目前的研究大多专注于从不同维度开展探索以求解决不同融合策略的缺点.例如 Zhang 等<sup>[25]</sup>通过多视角 2D CNN 提取局部特征、3D CNN 获取全局特征,并结合注意力机制进行切片级特征加权融合,较传统方法获得了 1.6–7.1% 的提高. Song 等<sup>[26]</sup>基于 DenseNet 设计了两个独立的不共享参数的特征提取分支分别提取水平和纵向超声图像中的低级局部特征和高级全局特征再进行融合,以避免不同视角可能存在的数据质量不均问题,显著提高了诊断性能. 尽管基于深度学习的方法确实有效提高了多视角特征的分类性能,但仍未充分利用多视角数据之间的互补性,甚至有可能导致在特征提取或者分类的过程中视角间互补信息的丢失<sup>[27]</sup>,并且由于深度学习的“黑盒”问题,其特征解释性也受到制约. Shu 等<sup>[4]</sup>提出了一种基于最近子空间的多视角分类器,通过投影残差、视图相关类可分性、视图相似度三个模块,创新性的考虑了类与视图的关系,有效利用了对于多视角数据互补信息. Zhang 等<sup>[28]</sup>结合后验一致性和域适应设计了多视角学习的受限玻尔兹曼机模型,该模型能同时学习视图一致性和特定于视图的隐藏表示,并平衡多视图分类的视图一致性表示,在两类和多分类多视角数据中都取得了良好的结果.

与此形成对比的是,当前多视角学习领域中针对标签建模层面的研究仍显薄弱. 大多数方法依然将标签视为确定的硬标签,未能充分挖掘标签中的语义模糊性与不确定性. 在真实应用中,人工标注往往伴随主观性偏差与类间模糊,尤其在医学影像、遥感解译等任务中尤为突出. 若缺乏对标签不确定性的显式建模,极易导致模型在训练阶段出现过拟合或边界误导,限制其泛化能力与鲁棒性. 另一方面,已有多视角方法虽在特征空间强调一致性与差异性,但较少有工作将“标签松弛机制”引入多视角协同过程中,尚未建立起标签与特征之间的柔性桥梁.

## 2 FC-MVCC 算法概述

### 2.1 模糊隶属度学习

为了更好地刻画在多视角场景中数据普遍存在的模糊性和不确定性,基于模糊集理论,我们引入了模糊 C-means 聚类策略来描述样本的类别的不确定性,该策略允许样本同时以不同程度隶属于多个簇. 为了简单起见,采用欧几里得距离来评估样本和聚类质心之间的相关性. 具体而言,若某样本与某簇质心在欧氏距离上更接近,则可得到更高的  $h_{ij}$  值,反之则更低. 目标函数具体如下:

$$\begin{aligned} \min_{\mathbf{o}_j, \mathbf{H}} \sum_{i=1}^n \sum_{j=1}^c h_{ij} \| \mathbf{x}_i - \mathbf{o}_j \|_2^2 + \alpha \| \mathbf{H} \|_F^2, \\ \text{s.t. } \sum_{j=1}^c h_{ij} = 1, \quad 0 \leq h_{ij} \leq 1, \end{aligned} \quad (1)$$

其中  $\mathbf{o}_j$  是第  $j$  个聚类的质心,  $h_{ij}$  是第  $i$  个样本和第  $j$  个聚类之间的隶属度得分,  $\mathbf{H}$  表示隶属度矩阵. 同时,为了避免隶属度出现极端分配,我们在第二项中加入正则化约束以保证不同聚类中每个数据点的成员稀疏性.  $\alpha$  是正则化参数.

对于多视角数据  $\mathbf{X} = [\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^V] \in \mathbb{R}^{n \times d}$ , 不同视角的特征  $\mathbf{X}^v (v=1, 2, \dots, V)$  表示同一样本的不同特定属性. 当分析来自不同视角的数据特征时,将获得不同的结果,将公式(1)进一步推广到多个视角中,我们将获得多个隶属度并得到以下式子:

$$\begin{aligned} \min_{\mathbf{o}_j^v, \mathbf{H}^v} \sum_{v=1}^V \left( \sum_{i=1}^n \sum_{j=1}^c h_{ij}^v \| \mathbf{x}_i^v - \mathbf{o}_j^v \|_2^2 + \alpha \| \mathbf{H}^v \|_F^2 \right), \\ \text{s.t. } \sum_{j=1}^c h_{ij}^v = 1, \quad 0 \leq h_{ij}^v \leq 1, \end{aligned} \quad (2)$$

其中  $\mathbf{H}^v \in \mathbb{R}^{n \times c}$  是由第  $v$  个视角特征矩阵计算得到的隶属度矩阵.

通过这种方式,我们能独立地从每个视角中学习到其局部结构,有效保留不同视图下的特征差异和细粒度信息. 同时,多视图间的模糊隶属度矩阵  $\mathbf{H}^v$  在后续与标签信息或特征投影过程相结合时,也能提供更丰富的语义线索.

### 2.2 自适应真实标签监督

在多视角软隶属度学习的过程中,仅依赖无监督聚类往往难以保证与真实类别标签的一致性. 因此

我们引入真实标签来引导各视角隶属度的学习,使模型在保留模糊聚类弹性的同时,能够更好地对齐真实标签,从而提升区分度和预测准确率.此外我们引入了自适应视角权重  $w_i^v$  用以表示第  $i$  个样本在第  $v$  个视角上所占的权重.具体来说,如果某个视角对于判别该样本更具有优势,那么模型会倾向于赋予该视角更高的  $w_i^v$  值,反之则降低.此部分的学习函数写为

$$\begin{aligned} \min_{\mathbf{W}} \sum_{i=1}^n \left\| \mathbf{y}_i - \sum_{v=1}^V w_i^v \mathbf{h}_i^v \right\|_2^2 \\ \text{s.t. } \mathbf{w}_i^T \mathbf{1} = 1. \end{aligned} \quad (3)$$

其中  $\mathbf{y}_i$  是第  $i$  个样本的真实标签,  $\mathbf{h}_i^v$  为第  $i$  个样本在第  $v$  个视角下的软隶属度向量,  $\mathbf{w}_i = [w_i^1, w_i^2, \dots, w_i^V]^T \in \mathbb{R}^{V \times 1}$  是第  $i$  行隶属矩阵对应的各视图权重组成的列向量,  $\mathbf{W} \in \mathbb{R}^{V \times n}$  为所有数据点(即隶属矩阵各行)对应的视图权重矩阵.

通过在模糊隶属度的学习过程中增加真实标签的引导的方法,能够在无监督聚类的基础上增强模型判别能力,同时通过  $w_i^v$  的自适应调整,充分利用各视角数据的互补性,使得样本在多簇之间的隶属度分配更具灵活性,可以更好地应对噪声和不确定性.

### 2.3 投影矩阵学习

在分类任务中,通过最小化多视角数据在投影后的特征空间中与其标签之间的差异,以实现具有判别性的映射.在此基础上,投影目标形式如下:

$$\min_{\mathbf{P}} \sum_{v=1}^V \sum_{i=1}^n \left\| \mathbf{x}_i^v \mathbf{P}^v - \mathbf{y}_i \right\|_2^2 + \gamma \sum_{v=1}^V \left\| \mathbf{P}^v \right\|_F^2. \quad (4)$$

基于前文学习到的软隶属度矩阵,我们进一步设置了一种“标签松弛”策略,用以在真实标签和样本特征之间提供柔性的语义过渡.假设训练集包含  $n$  个样本、 $c$  个类别,则有  $\mathbf{Y} = [y_{ij}] \in \{0, 1\}^{n \times c}$ ,  $\mathbf{Y}$  为热标签矩阵.当  $y_{ij} = 1$  时,说明样本  $i$  属于类别  $j$ .设先前学习到的模糊聚类矩阵为  $\mathbf{M}$ ,则  $\mathbf{M} = [m_{ij}] \in \mathbb{R}_{\geq 0}^{n \times c}$ ,其中  $m_{ij}$  表示样本  $i$  对于类别  $j$  的隶属度.同时为了突出目标类别(正向信号)并抑制其余类别(负向信号),引入二值极性矩阵  $\mathbf{B}$  并表示如下

$$b_{ij} = \begin{cases} +1, & \text{if } y_{ij} = 1 \\ -1, & \text{if } y_{ij} = 0 \end{cases}$$

此时可将原来的硬标签  $\mathbf{Y}$  重构为松弛标签矩阵  $\mathbf{Y}' = \mathbf{Y} + \mathbf{B} \odot \mathbf{M}$ . 其中  $\odot$  是矩阵的哈达玛算子.

以四个样本、三类问题为例.给定热标签矩阵、模糊隶属度矩阵、极性矩阵如下

$$\mathbf{Y} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \quad \mathbf{M} = \begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{32} & m_{33} \\ m_{41} & m_{42} & m_{43} \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} -1 & +1 & -1 \\ +1 & -1 & -1 \\ -1 & -1 & +1 \\ -1 & +1 & -1 \end{bmatrix},$$

此时松弛标签矩阵为:

$$\mathbf{Y}' = \begin{bmatrix} -m_{11} & 1+m_{12} & -m_{13} \\ 1+m_{21} & -m_{22} & -m_{23} \\ -m_{31} & -m_{32} & 1+m_{33} \\ -m_{41} & 1+m_{42} & -m_{43} \end{bmatrix}.$$

公式(4)可以改写为以下形式:

$$\min_{\mathbf{P}} \left( \sum_{v=1}^V \sum_{i=1}^n \left\| \mathbf{x}_i^v \mathbf{P}^v - (\mathbf{y}_i + \mathbf{b}_i \odot \mathbf{h}_i^v) \right\|_2^2 + \gamma \sum_{v=1}^V \left\| \mathbf{P}^v \right\|_F^2 \right), \quad (5)$$

其中  $\mathbf{P}^v$  表示第  $v$  个视角的投影矩阵,  $\mathbf{b}_i$  表示二值极性矩阵  $\mathbf{B}$  的第  $i$  行向量.为了避免在高维特征映射时出现过拟合现象,我们还在投影矩阵  $\mathbf{P}^v$  上施加了  $L2$  正则化以控制投影矩阵系数的规模.  $\gamma$  是正则化系数.

通过上式表示的附加“标签松弛”的投影方法,有效缓解了原始标签刚性带来的优化困难.使得多视角数据在投影后更贴近真实标签的同时保留了软隶属度所刻画的模糊性与不确定性,为分类任务提供了更具弹性和准确度的表示空间.

### 2.4 目标函数和优化

基于如上介绍的 3 个组件,FC-MVCC 算法的目标函数可以表示为

$$\begin{aligned} \min_{\mathbf{o}_j^v, \mathbf{H}^v, \mathbf{P}, \mathbf{W}} & \left( \sum_{i=1}^n \sum_{j=1}^c h_{ij}^v \| \mathbf{x}_i^v - \mathbf{o}_j^v \|^2 + \alpha \| \mathbf{H}^v \|^2_F \right) + \beta \sum_{i=1}^n \left\| \mathbf{y}_i - \sum_{v=1}^V w_i^v \mathbf{h}_i^v \right\|_2^2 + \\ & \lambda \left( \sum_{v=1}^V \sum_{i=1}^n \| \mathbf{x}_i^v \mathbf{P}^v - (\mathbf{y}_i + \mathbf{b}_i \odot \mathbf{h}_i^v) \|^2 + \gamma \sum_{v=1}^V \| \mathbf{P}^v \|^2_F \right), \\ \text{s.t.} & \sum_{j=1}^c h_{ij}^v = 1, \quad 0 \leq h_{ij}^v \leq 1, \quad \mathbf{W}_i^T \mathbf{1} = 1. \end{aligned} \quad (6)$$

其中  $\beta, \lambda$  为平衡参数且  $>0$ , 以调配目标函数中不同部分的影响.

在优化时,我们采用交替优化策略来解决优化问题. 具体来说,通过固定其余变量,来优化剩下的一个变量. 每个变量的优化过程如下:

(1) 固定  $\mathbf{H}^v, \mathbf{P}, \mathbf{W}$ , 更新  $\mathbf{o}_j^v$

通过固定其他变量,  $\mathbf{o}_j^v$  的优化可以转化为

$$\arg \min_{\mathbf{o}_j^v} \sum_{v=1}^V \sum_{i=1}^n \sum_{j=1}^c h_{ij}^v \| \mathbf{x}_i^v - \mathbf{o}_j^v \|^2, \quad (7)$$

对于每个视角,每个聚类质心的优化都是独立的,因此  $\mathbf{o}_j^v$  的求解过程可以分解为  $V$  个独立的子问题:

$$\arg \min_{\mathbf{o}_j^v} \sum_{i=1}^n \sum_{j=1}^c h_{ij}^v \| \mathbf{x}_i^v - \mathbf{o}_j^v \|^2. \quad (8)$$

由于目标函数是凸函数,因此可以通过将其导数设置为零来求解. 因此,我们有

$$\mathbf{o}_j^v = \frac{\sum_{i=1}^n h_{ij}^v \mathbf{x}_i^v}{\sum_{i=1}^n h_{ij}^v}. \quad (9)$$

(2) 固定  $\mathbf{P}, \mathbf{W}, \mathbf{o}_j^v$ , 更新  $\mathbf{H}^v$

通过固定其他变量,  $\mathbf{H}^v$  的优化可以推导为:

$$\begin{aligned} \arg \min_{\mathbf{H}^v} & \sum_{v=1}^V \left( \sum_{i=1}^n \sum_{j=1}^c h_{ij}^v \| \mathbf{x}_i^v - \mathbf{o}_j^v \|^2 + \alpha \| \mathbf{H}^v \|^2_F \right) + \beta \sum_{i=1}^n \left\| \mathbf{y}_i - \sum_{v=1}^V w_i^v \mathbf{h}_i^v \right\|_2^2 + \\ & \lambda \sum_{v=1}^V \sum_{i=1}^n \| \mathbf{x}_i^v \mathbf{P}^v - (\mathbf{y}_i + \mathbf{b}_i \odot \mathbf{h}_i^v) \|^2, \\ \text{s.t.} & \sum_{j=1}^c h_{ij}^v = 1, \quad 0 \leq h_{ij}^v \leq 1 \end{aligned} \quad (10)$$

在只关心第  $v$  个视角、第  $i$  个样本的  $\mathbf{h}_i^v$  时,可将上式化简为:

$$\begin{aligned} \arg \min_{\mathbf{h}_i^v} & \sum_{j=1}^c d_{ij}^v h_{ij}^v + \alpha \| \mathbf{h}_i^v \|^2 + \beta \| \mathbf{m}_i^v - w_i^v \mathbf{h}_i^v \|^2 + \lambda \| \mathbf{a}_i^v - \mathbf{b}_i \odot \mathbf{h}_i^v \|^2, \\ \text{s.t.} & \sum_{j=1}^c h_{ij}^v = 1, \quad 0 \leq h_{ij}^v \leq 1 \end{aligned} \quad (11)$$

其中  $d_{ij}^v = \| \mathbf{x}_i^v - \mathbf{o}_j^v \|^2$ ,  $\mathbf{m}_i^v = \mathbf{y}_i - \sum_{u \neq v} w_i^u \mathbf{h}_i^u$ ,  $\mathbf{a}_i^v = \mathbf{x}_i^v \mathbf{P}^v - \mathbf{y}_i$ .

为简便,令  $\mathbf{d}_i^v = (d_{i1}^v, \dots, d_{ic}^v)^T$ ,  $\mathbf{h}_i^v = (h_{i1}^v, \dots, h_{ic}^v)^T$ , 并将式(10)展开为对  $\mathbf{h}_i^v$  的二次型,忽略与  $\mathbf{h}_i^v$  无关的常数项后,可得

$$\begin{aligned} f(\mathbf{h}_i^v) &= (\mathbf{d}_i^v)^T \mathbf{h}_i^v + \alpha \| \mathbf{h}_i^v \|^2 + \beta \| \mathbf{m}_i^v - w_i^v \mathbf{h}_i^v \|^2 + \lambda \| \mathbf{a}_i^v - \mathbf{b}_i \odot \mathbf{h}_i^v \|^2 = (\mathbf{d}_i^v)^T \mathbf{h}_i^v + \alpha \| \mathbf{h}_i^v \|^2 + \\ & \beta (\| \mathbf{m}_i^v \|^2 - 2w_i^v (\mathbf{m}_i^v)^T \mathbf{h}_i^v + (w_i^v)^2 \| \mathbf{h}_i^v \|^2) + \lambda (\| \mathbf{a}_i^v \|^2 - 2(\mathbf{a}_i^v)^T (\mathbf{b}_i \odot \mathbf{h}_i^v) + \| (\mathbf{b}_i \odot \mathbf{h}_i^v) \|^2) + C \Rightarrow \\ & f(\mathbf{h}_i^v) = (\alpha + \beta (w_i^v)^2 + \lambda) \mathbf{h}_i^{vT} \mathbf{h}_i^v + [\mathbf{d}_i^v - 2\beta w_i^v \mathbf{m}_i^v - 2\lambda (\mathbf{b}_i \odot \mathbf{a}_i^v)]^T \mathbf{h}_i^v. \end{aligned}$$

对上式求导并设为 0, 可得

$$\nabla_{\mathbf{h}_i^v} f = 2(\alpha + \beta (w_i^v)^2 + \lambda) \mathbf{h}_i^v + [\mathbf{d}_i^v - 2\beta w_i^v \mathbf{m}_i^v - 2\lambda (\mathbf{b}_i \odot \mathbf{a}_i^v)] = 0,$$

整理可得

$$\mathbf{h}_i^v = \frac{\beta w_i^v \mathbf{m}_i^v - \lambda (\mathbf{b}_i \odot \mathbf{a}_i^v) - \frac{1}{2} \mathbf{d}_i^v}{\alpha + \beta (w_i^v)^2 + \lambda}, \quad (12)$$

$$\text{s.t. } \sum_{j=1}^c h_{ij}^v = 1, \quad 0 \leq h_{ij}^v \leq 1.$$

(3) 固定  $\mathbf{o}_j^v$ 、 $\mathbf{H}^v$ 、 $\mathbf{P}$ , 更新  $\mathbf{W}$

通过固定其他变量,  $\mathbf{W}$  的优化如下:

$$\arg \min_{\mathbf{W}_i} \left\| \mathbf{y}_i - \sum_{v=1}^V w_i^v \mathbf{h}_i^v \right\|, \quad (13)$$

$$\text{s.t. } \mathbf{w}_i^T \mathbf{1} = 1.$$

对于每个视角,  $w_i^v$  的优化是相互独立的, 根据式(11)的约束条件, 有

$$\left\| \mathbf{y}_i - \sum_{v=1}^V w_i^v \mathbf{h}_i^v \right\|_2^2 \Leftrightarrow \left\| \sum_{v=1}^V w_i^v - \sum_{v=1}^V w_i^v \mathbf{h}_i^v \right\|_2^2 \Leftrightarrow \left\| \sum_{v=1}^V w_i^v - (\mathbf{y}_i - \mathbf{h}_i^v) \right\|_2^2 \Leftrightarrow \left\| \mathbf{G}_i \mathbf{w}_i \right\|_2^2 \Leftrightarrow \mathbf{w}_i^T \mathbf{G}_i^T \mathbf{G}_i \mathbf{w}_i$$

其中  $\mathbf{g}_i^v = \mathbf{y}_i - \mathbf{h}_i^v$ ,  $\mathbf{G}_i = [\mathbf{g}_i^1, \dots, \mathbf{g}_i^v, \dots, \mathbf{g}_i^V]$ .

式(11)的拉格朗日函数可由下式获得:

$$\mathcal{L}(\mathbf{w}_i, \psi) = \mathbf{w}_i^T \mathbf{G}_i^T \mathbf{G}_i \mathbf{w}_i + \psi (1 - \mathbf{w}_i^T \mathbf{1}), \quad (14)$$

其中  $\psi$  是拉格朗日乘数. 通过用  $\mathbf{w}_i$  计算式(12)的导数并将其设置为 0, 我们可以得到  $\mathbf{w}_i$  的解为

$$\mathbf{w}_i = \frac{(\mathbf{G}_i^T \mathbf{G}_i)^{-1} \mathbf{1}}{\mathbf{1}^T (\mathbf{G}_i^T \mathbf{G}_i)^{-1} \mathbf{1}}. \quad (15)$$

(4) 固定  $\mathbf{o}_j^v$ 、 $\mathbf{H}^v$ 、 $\mathbf{W}$ , 更新  $\mathbf{P}$

通过固定其他变量,  $\mathbf{P}$  的优化可以推导为:

$$\arg \min_{\mathbf{P}^v} \sum_{v=1}^V \left\| \mathbf{X}^v \mathbf{P}^v - (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v) \right\|_2^2 + \gamma \sum_{v=1}^V \left\| \mathbf{P}^v \right\|_F^2, \quad (16)$$

该式可以等价转化为如下形式

$$\arg \min_{\mathbf{P}^v} \sum_{v=1}^V \left\| \mathbf{X}^v \mathbf{P}^v - (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v) \right\|_2^2 + \gamma \sum_{v=1}^V \text{Tr}((\mathbf{P}^v)^T \mathbf{P}^v). \quad (17)$$

此时对式子求偏导并设为 0 得

$$\frac{\partial}{\partial \mathbf{P}^v} \left( \sum_{v=1}^V (\text{Tr}((\mathbf{X}^v \mathbf{P}^v - (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v))^T (\mathbf{X}^v \mathbf{P}^v - (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v))) + \gamma \text{Tr}((\mathbf{P}^v)^T \mathbf{P}^v)) \right), \quad (18)$$

整理可得对于每个视角投影矩阵  $\mathbf{P}^v$ ,

$$2\mathbf{X}^v (\mathbf{X}^v \mathbf{P}^v - (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v)) + 2\gamma \mathbf{P}^v = 0,$$

$$(\mathbf{X}^v)^T \mathbf{X}^v \mathbf{P}^v - (\mathbf{X}^v)^T (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v) + \gamma \mathbf{P}^v = 0,$$

得

$$\mathbf{P}^v = ((\mathbf{X}^v)^T \mathbf{X}^v + \gamma \mathbf{I})^{-1} (\mathbf{X}^v)^T (\mathbf{Y} + \mathbf{B} \odot \mathbf{H}^v). \quad (19)$$

## 2.5 FC-MVCC 算法描述

根据  $\mathbf{o}_j^v$ 、 $\mathbf{H}^v$ 、 $\mathbf{W}$ 、 $\mathbf{P}$  的计算原则, 算法具体计算流程如下.

---

### 算法 1 FC-MVCC 训练

---

输入: 多视角数据矩阵  $\mathbf{X}^v \in \mathbb{R}^{n \times d}$ , 标签  $\mathbf{Y}$ , 簇数量 (类别数)  $c$ , 参数  $\alpha, \beta, \lambda, \gamma$ .

输出: 数据投影矩阵  $\mathbf{P}^v$

初始化: 使用  $1/V$  来初始化各视图的权重, 调用 MATLAB 的 `init fcm()` 函数初始化  $\mathbf{o}_j^v$  和  $\mathbf{H}^v$ , 并随机初始化投影矩阵  $\mathbf{P}^v$ .

重复

- (1) 使用公式(9)更新  $\mathbf{o}_j^v$
- (2) 使用公式(12)更新  $\mathbf{H}^v$
- (3) 使用公式(15)更新  $\mathbf{W}$
- (4) 使用公式(19)更新  $\mathbf{P}^v$

直到收敛

返回  $\mathbf{P}^v$

算法 2 FC-MVCC 测试

输入 测试集  $\hat{\mathbf{X}}^v \in \mathbb{R}^{n \times d}, \mathbf{P}^v$

输出 分类概率

2.6 收敛分析

我们可以通过定理 3.1 从理论上证明优化算法 1 的收敛性.

**定理 3.1** 算法 1 中的替代优化可以单调地减小方程(6)的目标函数值,直到收敛.

**证明** 如定理 3.1 所示,我们知道在每次迭代中更新一个变量会单调地减小方程(6)的目标函数值. 对于  $\mathbf{o}_j^v$  的更新,我们可以得到

$$\Omega(\mathbf{o}_j^{v(t)}, \mathbf{H}^v, \mathbf{W}, \mathbf{P}^v) \geq \Omega(\mathbf{o}_j^{v(t+1)}, \mathbf{H}^v, \mathbf{W}, \mathbf{P}^v), \quad (20)$$

其中  $t$  是迭代次数.

根据替代优化策略,通过在固定其他变量的同时更新一个变量,相应的优化目标函数将对该变量变为凸的. 因此,我们可以得到其余 4 个变量的类似情况.

当固定其他变量以更新  $\mathbf{H}$  时,有

$$\Omega(\mathbf{o}_j^v, \mathbf{H}^{v(t)}, \mathbf{W}, \mathbf{P}^v) \geq \Omega(\mathbf{o}_j^v, \mathbf{H}^{v(t+1)}, \mathbf{W}, \mathbf{P}^v), \quad (21)$$

当固定其他变量以更新  $\mathbf{W}$  时,有

$$\Omega(\mathbf{o}_j^v, \mathbf{H}^v, \mathbf{W}^{(t)}, \mathbf{P}^v) \geq \Omega(\mathbf{o}_j^v, \mathbf{H}^v, \mathbf{W}^{(t+1)}, \mathbf{P}^v), \quad (22)$$

当固定其他变量以更新  $\mathbf{P}^v$  时,我们有

$$\Omega(\mathbf{o}_j^v, \mathbf{H}^v, \mathbf{W}, \mathbf{P}^{v(t)}) \geq \Omega(\mathbf{o}_j^v, \mathbf{H}^v, \mathbf{W}, \mathbf{P}^{v(t+1)}). \quad (23)$$

如上述分析所示,算法 1 中的迭代优化可以在每次迭代中单调递减问题(6)的目标函数值. 因此,经过几次迭代,可以实现算法 1 的收敛. 结合之后的收敛分析实验结果,也可说明我们的方法能够快速收敛.

2.7 计算复杂度分析

在本节,我们将从理论上分析优化算法 FC-MVCC 的计算复杂度. 由于该方法是通过迭代优化策略求解的,我们通过分析求解相应优化子问题的计算复杂性来研究其复杂性.

在本模型中,包含 4 个需要交替优化的变量:聚类中心  $\mathbf{o}_j^v$ 、隶属度矩阵  $\mathbf{H}^v$ 、视角权重矩阵  $\mathbf{W}$ 、特征投影矩阵  $\mathbf{P}^v$ . 其中聚类中心  $\mathbf{o}_j^v$  的涉及对每类样本在多视角下的加权聚合,计算复杂度为  $O(Vncd)$ ,其中  $V$  是视角数, $n$  是样本数, $c$  是类别数, $d$  是特征维度,模糊隶属度  $\mathbf{H}^v$  的更新融合了真实标签残差与投影误差两项,需联合样本权重  $\mathbf{W}$ 、标签  $\mathbf{Y}$  和投影矩阵  $\mathbf{P}^v$ ,整体复杂度为  $O(V^2nc+Vndc)$ . 特征投影矩阵  $\mathbf{P}^v$  通过闭式线性回归方式更新,复杂度为  $O(nd^2+d^3)$ ,样本视角权重  $\mathbf{W}$  利用解析解获得,代价为  $O(nV^2)$ . 综上,每轮迭代的总体复杂度为  $O(V * (nd^2+d^3+ncd+Vnc))$ ,当  $c \leq n$  且  $d \leq n$  时,上述复杂度可以进一步简化(此时  $d^3 \leq nd^2$  且  $nc \leq nd$ ),最终每轮迭代的复杂度可以近似为  $O(V * n * d^2)$ . 从而展现出本方法在多视角高样本量分类任务中的良好计算可扩展性.

3 实验分析

3.1 数据集介绍

本实验采用 4 个真实世界的公共数据集来评估算法的有效性. 4 个真实数据集为 UCI-digit、Outdoor-scene、MSRC\_v1 和 ORL,下面依次介绍各数据集.

(1) UCI-digit

UCI-digit 数据集<sup>[29]</sup>包含从荷兰公用事业地图收集的手写数字(0-9)的特征,每类 200 个,总共有 2 000 个样本. 从字符形状的傅里叶系数(Fou)、轮廓相关性(Fac)、泽尼克矩(ZER)、 $2 \times 3$  窗口中的像素平均值(Pix)、Karhunen-Love 系数(KAR)、形态特征(MOR)共 6 个角度<sup>[30]</sup>计算特征,每个视角的特征数分别为 76、216、64、240、47、6. 在具体实验中,取 fou、fac、kar 三个视角的数据组成多视角数据集.

## (2) Outdoor-scene

Outdoor-scene 数据集<sup>[31]</sup>包含 8 个室外场景,有 2 688 张彩色图像,每张图片都为 256×256 像素. 对于每张图像,提取 512-D GIST、432-D 色矩、256-D HOG 和 48-D LBP 四种不同的特征向量,组成多视角数据集.

## (3) MSRC\_v1

MSRC\_v1 数据集是一个场景识别数据集,包含来自 7 类主题的 210 张图片. 在实验中,通过提取 CM、GIST、HOG、CENT 和 LBP 五种不同的特征,构建多视角数据集,每个视角的特征数分别为 24、576、512、256 和 254.

## (4) ORL

ORL 人脸数据集由 40 类不同主题的图片组成,每类主题有 10 个不同的图像. 这些图像在不同时间拍摄,具有不同的照明、面部表情和面部细节,从四个视角提取不同特征组成特征集合用于实验,每个视角的特征数分别为 512、59、864、254.

## 3.2 实验设置

在具体实现中,数据集的划分为 8:2,除标准化外不做任何预处理,参数  $\alpha$ 、 $\beta$ 、 $\lambda$ 、 $\gamma$  都使用 5 折交叉搜索+网格搜索以确定最佳参数,范围都为  $\{10^{-4}, 10^{-2}, 1, 10^2, 10^4\}$ . 评估指标设定为准确率 (Accuracy, ACC),运行 10 次后取平均值作为最终的实验结果,图 1 为实验流程图. 为了评估 FC-MVCC 算法对于多视角数据的预测性能,选取了 IPMVSC<sup>[32]</sup>、MvCCDA<sup>[33]</sup>、AWDR<sup>[34]</sup> 三种先进多视角分类算法、非负矩阵分解 (nonnegative matrix factorization, NMF)+SVM 的传统组合用于多视角分类作为对比算法. 此外,考虑到我们提出的方法中结合了无监督聚类的思路,我们还选取了 3 种使用聚类算法的多视角分类算法 MLCK、DACK、LACK<sup>[35]</sup> 作为对比算法,以此检验一致性监督的有效性. 每种算法都运行 10 次并取平均值作为最终的实验结果.

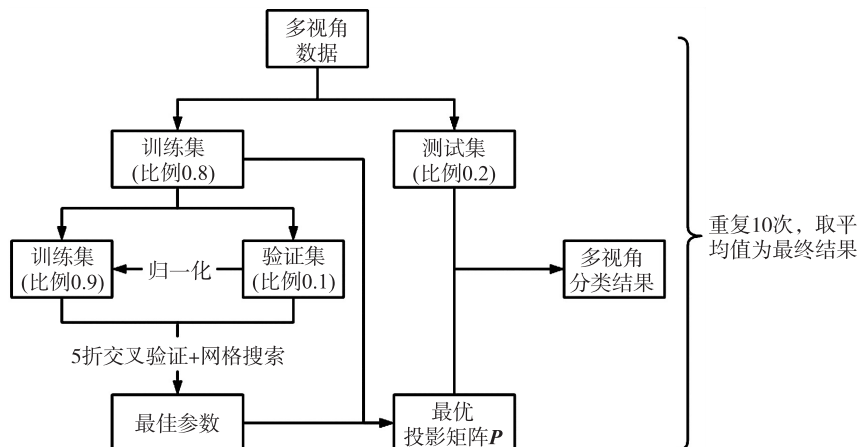


图 1 FC-MVCC 实验流程图

## 3.3 实验结果

在本节中,对我们所提出的方法与六种多视角算法以及传统分类算法进行了对比,结果如表 1 所示.

表 1 对比试验结果

Table 1 Results of the comparison experiment

数据集	UCI-digit	Outdoor-scene	MSRC_v1	ORL
IPMVSC	<b>98.81±0.12</b>	84.36±0.37	94.16±1.06	99.13±0.17
MvCCDA	83.58±1.21	61.07±1.52	72.95±3.69	80.48±1.79
AWDR	98.18±0.71	82.16±1.31	88.34±4.05	99.38±0.63
NMF+SVM	96.35±0.93	84.13±1.74	92.38±2.78	95.15±1.94
MLCK	94.25±0.77	75.87±1.81	93.10±4.45	96.25±1.37
DACK	94.13±0.98	71.42±1.65	90.96±3.50	94.88±2.53
LACK	94.93±1.38	77.05±1.42	91.19±2.14	95.75±1.50
我们提出的方法	98.05±0.35	<b>86.03±1.59</b>	<b>97.07±1.46</b>	<b>99.47±0.84</b>

从整体性能来看,我们提出的方法在 Outdoor-scene、MSRC\_v1 和 ORL 三个数据集上均取得了最优成绩,准确率分别为  $86.03\% \pm 1.59$ 、 $97.07\% \pm 1.46$ 、 $99.47\% \pm 0.84$ , 优于其他所有对比方法。

在 UCI-digit 数据集上,我们方法略逊于 IPMVSC( $98.05\%$  vs  $98.81\%$ ),但值得指出的是,该数据集样本分布相对平衡、视角差异较小,结构较为清晰。在这类较为理想的数据结构中,传统方法已能取得较高性能。然而,我们方法依旧达到  $98.05\% \pm 0.35$ ,且结果波动更小,表现出良好的稳定性。Outdoor-scene 数据集跨越 8 类复杂户外场景,并融合了 GIST、色矩、HOG 和 LBP 等多样性较高的视角特征,对多视角方法的特征融合与鲁棒性提出了更高挑战。相比表现较优的 IPMVSC( $84.36\% \pm 0.37$ ),我们方法在此复杂场景中仍取得超过 1.6% 的准确率提升,体现出其在面对高维、多模态图像特征时的融合能力与泛化性能。在 MSRC\_v1 数据集中,我们方法同样展现出强劲的性能。该数据集具有典型的小样本、高语义复杂度、视角冗余强的特点。在此背景下,我们方法的准确率达到了  $97.07\% \pm 1.46$ ,相较于当前最优的 IPMVSC( $94.16\% \pm 1.06$ )仍有 2.91% 的提升,说明所提出的模糊隶属度建模与标签松弛机制能有效缓解样本稀疏性对多视角融合精度的影响。在 ORL 数据集中,每位受试者拍摄了多张具有不同光照、表情和细节变化的面部图像,所提取的四种视角特征维度差异显著,挑战主要来自视角特征的不均衡与人脸小细节的多样化,但我们的方法仍然取得了最好的结果,证明了在应对小样本、多种类时,所提出的方法的判别能力和鲁棒性同样突出。

为了进一步验证上述性能提升的统计学显著性,我们采用成对  $t$  检验对每种算法与我们方法的准确率进行了显著性分析,结果如表 2 所示,其中正的  $t$  值意味着本方法的平均准确率高于对比方法,负值则相反, $t$  值的绝对值越大对应差异程度越显著。在四个数据集中,我们方法相较于绝大多数对比方法均存在显著差异( $p < 0.05$ )。证明我们方法在不同样本规模、类别数量和特征复杂度下均具有优异的稳定性、适应性与判别能力。

表 2 统计学检验结果(成对  $t$  检验)

Table 2 Results of statistical tests

数据集	UCI-digit		Outdoor-scene		MSRC_v1		ORL	
	$t$ 值	$p$ 值	$t$ 值	$p$ 值	$t$ 值	$p$ 值	$t$ 值	$p$ 值
IPMVSC	-5.398 6	0.000 4	3.202 3	0.010 8	6.042 2	0.000 2	1.288 6	0.229 7
MvCCDA	34.910 4	$\ll 0.05$	62.646 7	$\ll 0.05$	19.056 4	$\ll 0.05$	28.664 3	$\ll 0.05$
AWDR	-0.544 0	0.599 7	5.004 1	0.000 7	5.614 0	0.000 3	0.297 9	0.002 0
NMF+SVM	5.395 9	0.000 4	2.609 7	0.028 3	4.975 9	0.000 8	6.051 2	0.000 2
MLCK	19.008 4	$\ll 0.05$	17.574 7	$\ll 0.05$	2.376 5	0.041 5	5.425 5	0.000 4
DACK	12.773 4	$\ll 0.05$	16.437 7	$\ll 0.05$	5.136 5	0.000 6	7.084 0	0.000 9
LACK	6.080 4	0.000 1	12.319 5	$\ll 0.05$	6.573 6	0.000 1	7.084 0	0.000 1

### 3.4 消融实验

在前文的整体性能验证基础上,我们进一步开展了消融实验。在该实验中,我们将模糊聚类和标签松弛模块从模型中移除,重新在 4 个数据集上评估其性能,以验证这两部分对整体效果的影响。结果表明,消融后的方法性能下降具有统计学显著性。充分证明了模糊聚类在跨视角语义挖掘中的关键作用以及标签松弛策略在缓冲特征与标签偏差、提升模型鲁棒性方面的必要性。

表 3 消融实验结果及统计学检验结果

Table 3 Results of ablation experiments and statistical tests

数据集	ACC	$t$ 值	$p$ 值
UCI-digit	$97.34 \pm 0.66$	3.156 3	0.011 6
Outdoor-scene	$84.34 \pm 0.60$	3.726 9	0.004 7
MSRC_v1	$92.20 \pm 4.47$	2.739 0	0.022 9
ORL	$97.34 \pm 2.00$	4.298 1	0.002 0

### 3.5 参数敏感性分析和收敛分析

为评估模型对关键正则系数( $\alpha$ 、 $\beta$ 、 $\lambda$ 、 $\gamma$ )的鲁棒性,我们在 UCI-digit、Outdoor-scene、MSRC\_v1 和 ORL

四个多视角数据集上, 依次固定  $\alpha, \beta, \lambda; \alpha, \gamma$  以及  $\alpha, \beta, \lambda$  进行参数敏感性分析, 结果如图 2 所示. 综合来看, 四个参数在较小的范围内进行调整即可取得最优实验结果,  $\alpha, \gamma$  两个参数最为重要, 对于结果的影响最大. 在 UCI-digit 数据集这种简单场景下, 模型对于  $\alpha, \beta, \lambda$  参数表现出良好的鲁棒性, 此时控制投影矩阵的正则化参数  $\gamma$  具有关键作用, 但也相对稳定. 在 MSRC\_v1 数据集的场景下, 当  $\alpha$  过小时, 会较严重降低模型的分类 ACC, 同时在这种不同视角特征的维度差异较大的情况下,  $\beta$  的取值也较为关键, 说明赋予不同视角不同权重的重要性. 在 Outdoor scene 这种大样本的场景下,  $\alpha, \beta, \lambda$  整体都较为稳健. 而在 ORL 这种小样本多类的场景下,  $\alpha$  的波动性最大, 但在设置为 10 以后表现也较为稳定.

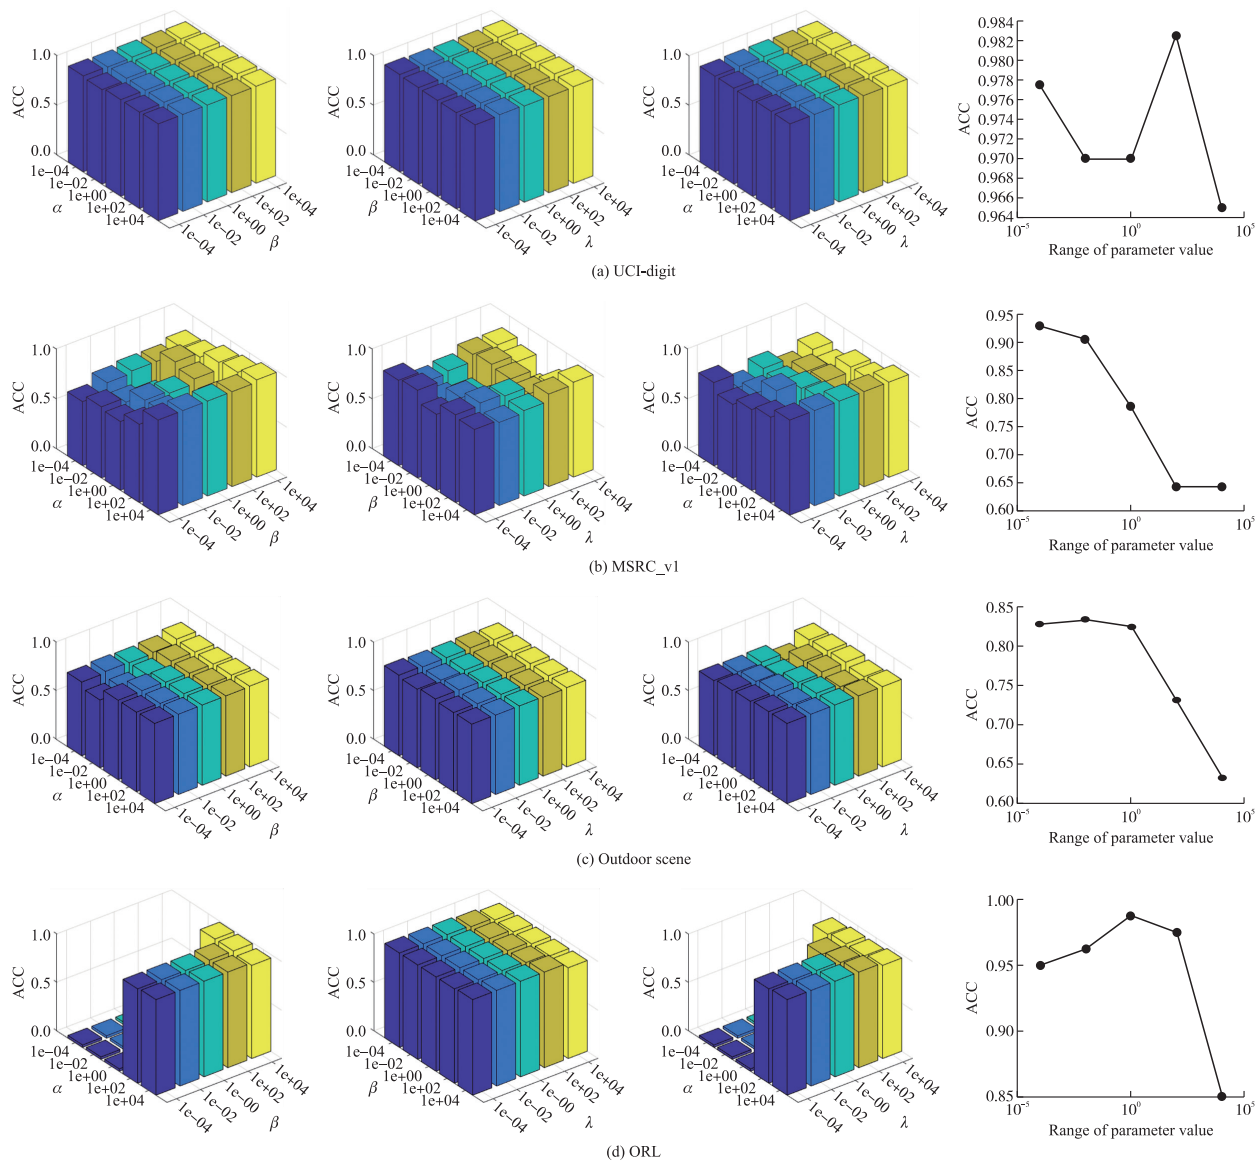


图 2 参数敏感性分析结果图

Fig. 2 Parameter sensitivity analysis

在保证分类效果的同时, 验证算法数值稳定性至关重要. 我们进一步进行了收敛分析, 通过迭代曲线展示所提出的方法在不同数据集下收敛速度与趋势, 证明其在有限步迭代内能够迅速达到稳定状态, 结果如图 3 所示. 实验结果表明, 在 MSRC\_v1、ORL、Outdoor-scene 及 UCI-digit 四个数据集上, 文章提出的方法均能在极少数迭代内迅速完成目标函数的大幅优化: 在 MSRC\_v1 和 ORL 数据集上, 第 1-2 次迭代即完成了绝大部分下降量, 而在 Outdoor-scene 和 UCI-digit 数据集上, 前 3 次迭代即实现了超过 90% 的优化幅度; 此后第 4~5 次迭代起目标值基本趋于平稳且波动极小, 表明交替优化聚类中心、视角权重与投影矩阵的过程能快速进入稳定状态. 尽管 4 个数据集在样本规模、特征维度与分布特性上存在显著差异, 该收敛行为在形态上高度一致, 验证了所提框架在多视角大规模、高维及少样本小规模任务中的通用性与高效性.




图 3 收敛分析结果图  
Fig. 3 Convergence analysis

## 4 结论

本文围绕多视角数据中标签噪声与语义模糊性的问题,提出了一种使用模糊聚类驱动标签松弛的多视角分类算法 FC-MVCC,该方法从模糊 C 均值聚类出发,在各视角中构建每个样本的软隶属度表示,用以刻画标签的不确定性与模糊边界;在此基础上引入真实标签约束与自适应视角权重,引导软标签贴近语义主干,增强对高维异构特征的适应能力;进一步通过构建标签松弛机制,在真实标签与模糊标签之间建立柔性过渡,实现特征-标签协同投影优化,提升模型对噪声与视角差异的鲁棒性. 实验结果显示,FC-MVCC 在 UCI-digit、Outdoor-scene、MSRC\_v1 和 ORL 四个数据集上整体优于六种多视角方法及传统分类基线,特别在视角冗余强、样本稀疏与特征复杂的数据条件下表现出显著优势. 消融实验进一步证实了模糊建模与标签松弛模块对整体性能的关键作用. 综上,本文所提出的 FC-MVCC 算法在多视角数据中实现了从特征层到标签层的双重柔性建模,为处理复杂结构、多源不一致与标注不确定性提供了新范式. 未来将进一步探索其在非共现视角、弱标签学习与临床实际应用中的扩展潜力.

### [ 参考文献 ]

[ 1 ] Yu Z, Dong Z, Yu C, et al. A review on multi-view learning[J]. *Frontiers of Computer Science*, 2025, 19(7): 197334.  
 [ 2 ] Xu C, Tao D, Xu C. A Survey on Multi-view Learning[EB/OL]. arXiv, 1304.5634, [2013-04-20].  
 [ 3 ] Sun X, Sun S. Adversarial robustness and attacks for multi-view deep models[J]. *Engineering Applications of Artificial Intelligence*, 2021, 97: 104085.  
 [ 4 ] Shu T, Zhang B, Tang Y Y. Multi-view classification via a fast and effective multi-view nearest-subspace classifier[J]. *IEEE Access*, 2019, 7: 49669-49679.  
 [ 5 ] Chen Z, Jia Y, Wang S, et al. Image-based methods for automatic identification of elongated and flat aggregate particles[J]. *Construction and Building Materials*, 2023, 382: 131187.  
 [ 6 ] Yang Y, Li X, Fu J, et al. 3D multi-view squeeze-and-excitation convolutional neural network for lung nodule classification[J]. *Medical Physics*, 2023, 50(3): 1905-1916.  
 [ 7 ] Liang N, Yang Z, Li L, et al. Label-noise robust classification with multi-view learning[J]. *Science China Technological Sciences*, 2023, 66(6): 1841-1854.  
 [ 8 ] 李超波, 李洪均, 徐晨. 深度学习在图像识别中的应用[J]. *南通大学学报(自然科学版)*, 2018, 17(1): 1-9.  
 [ 9 ] Hariri R H, Fredericks E M, Bowers K M. Uncertainty in big data analytics: survey, opportunities, and challenges[J]. *Journal*

- of Big Data,2019,6(1):44.
- [10] 顾苏杭,李晨阳,朱培逸. 人类视觉启发的模糊卷积神经网络[J]. 南通大学学报(自然科学版),DOI:10.12194/j.ntu.20241219002.
- [11] Yang Z,Zhang H,Liang N,et al. Semi-supervised multi-view clustering by label relaxation based non-negative matrix factorization[J]. The Visual Computer,2023,39(4):1409–1422.
- [12] Fu Z, Duan L, Xie Y, et al. Eeg-based epilepsy identification using multiple feature spaces consistent fusion with label relaxation[J]. Journal of Mechanics in Medicine and Biology,2025,25(02):2540013.
- [13] Abdi H,Williams L J,Valentin D. Multiple factor analysis:principal component analysis for multitable and multiblock data sets[J]. WIREs Computational Statistics,2013,5(2):149–179.
- [14] Kan M,Shan S,Chen X. Multi-view deep network for cross-view classification[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas,NV,USA:IEEE,2016:4846–4853.
- [15] Tong L,Wu H,Wang M D. Integrating multi-omics data by learning modality invariant representations for improved prediction of overall survival of cancer[J]. Methods,2021,189:74–85.
- [16] Witten D M,Tibshirani R,Hastie T. A penalized matrix decomposition,with applications to sparse principal components and canonical correlation analysis[J]. Biostatistics,2009,10(3):515–534.
- [17] Chen M,Gao C,Ren Z,et al. Sparse CCA via Precision Adjusted Iterative Thresholding[EB/OL]. arXiv:1311.6186,2013.
- [18] Gao C, Ma Z,Zhou H H. Sparse CCA:Adaptive estimation and computational barriers[J]. The Annals of Statistics,2017,45(5):2074–2101.
- [19] Zhang Y,Gaynanova I. Joint association and classification analysis of multi-view data[J]. Biometrics,2022,78(4):1614–1625.
- [20] Witten D M, Tibshirani R J. Extensions of sparse canonical correlation analysis with applications to genomic data[J]. Statistical Applications in Genetics and Molecular Biology,2009,8(1):28.
- [21] Liu X, Zhu X, Li M, et al. Late fusion incomplete multi-view clustering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2019,41(10):2410–2423.
- [22] Liong V E, Nguyen T N T, Widjaja S, et al. AMVNet: assertion-based multi-view fusion network for LiDAR semantic segmentation[Z]. arXiv,2020(2020–12–09).
- [23] Wang S,Liu X,Liu L,et al. Late fusion multiple kernel clustering with proxy graph refinement[J]. IEEE Transactions on Neural Networks and Learning Systems,2023,34(8):4359–4370.
- [24] Zhang T,Liu X,Gong L,et al. Late fusion multiple kernel clustering with local kernel alignment maximization[J]. IEEE Transactions on Multimedia,2023,25:993–1007.
- [25] Zhang Y,Peng S,Xue Z,et al. AMSF:attention-based multi-view slice fusion for early diagnosis of Alzheimer’s disease[J]. Peer Journal Computer Science,2023,9:e1706.
- [26] Song D,Zhang Z,Li W,et al. Judgment of benign and early malignant colorectal tumors from ultrasound images with deep multi-View fusion[J]. Computer Methods and Programs in Biomedicine,2022,215:106634.
- [27] Li Y,Xie X. Two novel deep multi-view support vector machines for multiclass classification[J]. Applied Intelligence,2024,55(3):182.
- [28] Zhang N,Ding S,Sun T,et al. Multi-view RBM with posterior consistency and domain adaptation[J]. Information Sciences,2020,516:142–157.
- [29] Lecun Y,Bottou L,Bengio Y,et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE,1998,86(11):2278–2324.
- [30] Li Y,Nie F,Huang H,et al. Large-scale multi-view spectral clustering via bipartite graph[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Austin,Texas,USA,2015:2750–2756.
- [31] Oliva A,Torralla A. Modeling the shape of the scene:a holistic representation of the spatial envelope[J]. International Journal of Computer Vision,2001,42(3):145–175.
- [32] Hu X,Liu X,Pedrycz W,et al. Multi-view fuzzy classification with subspace clustering and information granules[J]. IEEE Transactions on Knowledge and Data Engineering,2023,35(11):11642–11655.
- [33] You X,Xu J,Yuan W,et al. Multi-view common component discriminant analysis for cross-view classification[J]. Pattern Recognition,2019,92:37–51.
- [34] Yang M,Deng C,Nie F. Adaptive-weighting discriminative regression for multi-view classification[J]. Pattern Recognition,2019,88:236–245.
- [35] Yu Y,Zhou G,Huang H,et al. A semi-supervised label-driven auto-weighted strategy for multi-view data classification[J]. Knowledge-Based Systems,2022,255:109694.